
Benemérita Universidad Autónoma de Puebla

Facultad de Estomatología



SECRETARÍA DE INVESTIGACIÓN Y ESTUDIOS DE POSGRADO
MAESTRÍA EN ESTOMATOLOGÍA TERMINAL EN ENDODONCIA

TESIS PRESENTADA PARA OBTENER EL GRADO DE MAESTRÍA
EN ESTOMATOLOGÍA
CON OPCIÓN TERMINAL EN ENDODONCIA

Red Neuronal Convolutacional para Clasificar Cambios Físicos en el Instrumento Wave One Gold Primary

Presenta:

Alma Angélica García Bocanegra

Matrícula: 221450002

Responsable de Tesis:

**D. C. Miguel Ángel Casillas
Santana**

ID: 100526485

Director Metodológico:

**D. S. P. Rosendo Gerardo
Carrasco Gutiérrez**

ID: 100008655

Director Disciplinario:

**D. C. Brenda Eréndida Castillo
Silva**

ID: NSS526469

Asesor externo:

**D.C.C. Elías Jesús Ventura
Molina**

Instituto Politécnico Nacional

Puebla Pue. Mayo 2023



BUAP

Oficio No. FESIEP/CIFE/052/2023

C. Alma Angélica García Bocanegra
Alumna de la Maestría en Estomatología
con opción en Terminal en Endodoncia
Matrícula No.: 221450002
Facultad de Estomatología
Benemérita Universidad Autónoma de Puebla
PRESENTE

Sirva este medio para enviarle un cordial saludo, asimismo, **el que suscribe MO. Farid Alfonso Dipp Velázquez Secretario de Investigación y Estudios de Posgrado de la Facultad de Estomatología de la Benemérita Universidad Autónoma de Puebla; por este medio me permito informar a Usted, que, está Secretaría de Posgrado aprueba la impresión de la Tesis titulada:**

"Red Neuronal Convolutiva para Clasificar Cambios Físicos en el Instrumento Wave One Gold Primary"

misma que presentará para realizar su examen profesional y obtener el grado de Maestra en Estomatología con opción en Terminal en Endodoncia; para su conocimiento y atención correspondiente.

Sin otro particular, reitero a Usted mi más atenta y distinguida consideración.

Atentamente

"Pensar bien, para vivir mejor"

H. Puebla de Z., 29 de mayo de 2023

MO. Farid Alfonso Dipp Velázquez
Secretario de Investigación y Estudios de Posgrado
Facultad de Estomatología



*Se anexa: Formato de Impresión de Tesis (Original) - p.s.c y a.

*C.c.p. Archivo

*NITRO. FJMA/DR.FADV/yaneth

Facultad
de Estomatología

31 Poniente 1304, Col. Volcanes,
Puebla, Pue. C. P. 72410
01 (222) 229 55 00 Ext. 6400

**BENEMÉRITA UNIVERSIDAD AUTÓNOMA DE PUEBLA FACULTAD DE
ESTOMATOLOGÍA
SOLICITUD DE AUTORIZACIÓN DE IMPRESIÓN DE TESIS RECEPCIONAL**

Para obtener el Grado de: **Maestra en Estomatología con opción terminal en Endodoncia**

Registro CIFE: 2020143 **Fecha:** miércoles 31 de mayo del 2023

Título de la Tesis: "Red Neuronal Convolutiva para Clasificar Cambios Físicos en el Instrumento Wave One Gold Primary"

Nombre del alumno: Alma Angélica García Bocanegra

Matrícula: 221450002

Domicilio: Calle 12 de octubre 11717 Col. Granjas Puebla Pue.

Tel: 22*26 81 41 35

Fecha de ingreso a la Facultad: lunes 04 de enero del 2021.

Firma: 

Director de Tesis: DC. Miguel Ángel Casillas Santana **Grado académico:** Doctor en Ciencias Odontológicas

Adscripción: Facultad de Estomatología

ID: 100526485


Tel: 44*48 46 76 45

Firma: 

Director Disciplinario: DC. Brenda Eréndida Castillo Silva **Grado académico:** Doctorado en Ciencias Odontológicas.

Adscripción: Facultad de Estomatología **ID:** NSS526469

Tel: 44*42 42 60 77

Firma: 

Director Metodológico: Dr. Rosendo Gerardo Carrasco Gutiérrez **Grado académico:** Doctorado en Salud Pública

Adscripción: Facultad de Estomatología

ID: 100008655

Tel: 22*25 05 30 84

Firma: 

Lector: ME. Francisco Javier Castillo Cano

Grado académico: Maestría en Ciencias Odontológicas.

Adscripción: Facultad de Estomatología

ID: 100445599

Tel: 22*11 17 72 21


Firma: 

Nombre y firma de aprobación del Responsable de la Maestría en Estomatología con Opción terminal en Endodoncia.

ME. Alejandro Gerardo Martínez Guerrero.

Firma: 

La Secretaría de Investigación y Estudios de Posgrado de la Facultad de Estomatología, autoriza la impresión de la Tesis


MG. Farid Alfonso Dipp Velázquez

Fecha: miércoles 31 de mayo del 2023

Sello



AGRADECIMIENTOS

Agradezco infinitamente a Dios por permitirme concluir esta bella etapa de mi vida profesional. A mis padres Gregorio y Alma, por impulsarme, gracias por cada signo de amor y por estar siempre para mí, gracias por su esfuerzo y todo el sacrificio que significó para ustedes apoyarme durante esta Maestría. Sin duda son quienes han velado por mis sueños y los de mis hermanos; me siento muy orgullosa de ustedes y les agradezco por acompañarme en todos los momentos especiales de mi vida.

Al Dr. Miguel Casillas, a la Dra. Brenda Castillo y al Dr. Rosendo Carrasco, quienes formaron parte importante de esta historia, con sus aportes profesionales que los caracterizan. Muchas gracias por sus palabras, por sus orientaciones y su apoyo constante e incondicional. A mi asesor externo el Dr. Elías Ventura, gracias por compartir su conocimiento de manera profesional y precisa, gracias por su dedicación. Al Dr. Alejandro Martínez a quien no solo le agradezco mi formación académica, sino también su apoyo para el logro de esta tesis.

Gracias a mis compañeras y amigas del posgrado, por su apoyo durante esta investigación, por su cariño y amistad. Gracias a cada docente que hizo posible mi preparación durante el posgrado de Endodoncia en clínica y aulas, sin ustedes y sin sus virtudes, paciencia y constancia no sería lo que hoy he logrado. Sus consejos fueron siempre útiles, sabios, rigurosos y precisos, les debo mi formación. A ustedes y a mi comité de tesis donde quiera que vaya los llevaré conmigo en mí transitar profesional.

DEDICATORIAS

Dedico este logro a ustedes amados padres Gregorio, Alma, como una meta más conquistada, reconozco que sin su apoyo no estaría concluyendo este sueño. Este logro también lo dedico a mis hermanos, Valeria, Fausto, Mauricio y a mi novio Rafael, quienes me brindaron su apoyo en palabras y en obras, gracias por creer en mí y por su amor incondicional, los amo.

ÍNDICE

ÍNDICE DE FIGURAS	5
ÍNDICE TABLAS	5
ABREVIATURAS	6
INTRODUCCIÓN	8
ANTECEDENTES GENERALES	9
INSTRUMENTACIÓN EN ENDODONCIA	9
AVANCES TECNOLÓGICOS	11
INTELIGENCIA ARTIFICIAL	12
RED NEURONAL CONVOLUCIONAL VGG16	15
ANTECEDENTES ESPECÍFICOS	18
PLANTEAMIENTO DEL PROBLEMA	21
PREGUNTA DE INVESTIGACIÓN	22
JUSTIFICACIÓN	22
VIABILIDAD	23
CONSECUENCIAS DE LA INVESTIGACIÓN	23
HIPÓTESIS	25
OBJETIVOS	25
OBJETIVO GENERAL	25
OBJETIVOS ESPECÍFICOS	25
MATERIALES Y MÉTODOS	26
DISEÑO DE ESTUDIO	26
TAMAÑO DE MUESTRA	26
CRITERIOS DE SELECCIÓN PARA INSTRUMENTOS	27
INCLUSIÓN	27
EXCLUSIÓN	27
ELIMINACIÓN	28
VARIABLES	29
CONCORDANCIA Y FIABILIDAD	30
UBICACIÓN ESPACIO TEMPORAL	30
PROCEDIMIENTOS, TÉCNICAS Y FUENTES DE RECOLECCIÓN	30
ANÁLISIS ESTADÍSTICO	41
LOGÍSTICA	41
RECURSOS HUMANOS	41
RECURSOS MATERIALES	41
RECURSOS FINANCIEROS	42
CRONOGRAMA DE ACTIVIDADES	43
BIOÉTICA	43
RESULTADOS	43

DISCUSIÓN	47
CONCLUSIÓN	53
BIBLIOGRAFÍA	54
ANEXOS	65
ANEXO 1.- CONSENTIMIENTO INFORMADO.	65
ANEXO 2.- TABLA PARA LA RECOLECCIÓN DE DATOS.	66

ÍNDICE DE FIGURAS

FIGURA 1. INTELIGENCIA ARTIFICIAL.....	13
FIGURA 2. ESTRUCTURA DE NEURONA BIOLÓGICA.....	14
FIGURA 3. PERCEPTRON.....	15
FIGURA 4. ARQUITECTURA DE VGG16.....	16
FIGURA 5. BASE PARA FOTOGRAFÍAS.....	31
FIGURA 6. IMAGEN OBTENIDA DE PRUEBAS PILOTO.....	32
FIGURA 7. FASE DE CAPTURA DE IMÁGENES.....	33
FIGURA 8. PROCESO DE DESINFECCIÓN Y ESTERILIZACIÓN.....	35
FIGURA 9. INSTRUMENTACIÓN DE ÓRGANOS DENTARIOS EXTRAÍDOS.....	36
FIGURA 10. SECUENCIA DE K-FOLD CROSS-VALIDATION.....	39
FIGURA 11. PROCESO PRINCIPAL DE K-FOLD CROSS VALIDATION.....	40
FIGURA 12. FÓRMULA PARA CALCULAR EXACTITUD DE TRES CLASES.....	41
FIGURA 13. MATRIZ DE CONFUSIÓN.....	44
FIGURA 14. IMAGEN DE INSTRUMENTOS FRACTURADOS.....	46

ÍNDICE TABLAS

TABLA 1. CONV/NET DE VGG16	17
TABLA 2. TAMAÑO DE MUESTRA.....	27
TABLA 3. IMÁGENES TOTALES PARA ENTRENAMIENTO DE CNN.....	37
TABLA 4. CRONOGRAMA DE ACTIVIDADES.....	43
TABLA 5. CARACTERÍSTICAS DE OD DE INSTRUMENTOS FRACTURADOS.....	46
TABLA 6. NÚMERO DE CONDUCTOS INSTRUMENTADOS POR INSTRUMENTOS WOG PRIMARY.....	47

ABREVIATURAS

AI	Artificial Intelligence o Inteligencia Artificial (IA).
CBCT	Tomografías computarizadas de haz cono.
CNN	Convolutional Neural Networks o Red Neuronal Convolutacional.
CNNs	Redes Neuronales Convolucionales.
DL	Deep Learning o Aprendizaje Profundo.
FEBUAP	Facultad de Estomatología de la Benemérita Universidad Autónoma de Puebla.
FN	Falso Negativo.
FP	Falso positivo.
ML	Machine Learning o Aprendizaje Máquina.
NaOCl	Hipoclorito de Sodio.
NiTi	Níquel Titanio.
OD	Órgano Dentario.
TN	Verdadero Negativo.
TP	Verdadero positivo.
WOG	Wave One Gold.

RESUMEN

El uso de instrumentos rotatorios reciprocantes NiTi como el Sistema Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), son fundamentales durante la instrumentación en el tratamiento de conductos, sin embargo uno de los grandes desafíos clínicos para los especialistas en endodoncia es la controversia para determinar la cantidad de veces que es posible reutilizar un instrumento antes de que éste falle o pierda sus propiedades. Actualmente no existe ningún sistema que pueda expresar las condiciones reales de un instrumento rotatorio NiTi antes de reemplazarlo. Sin embargo sabemos que la Inteligencia Artificial, está ganando territorio en diferentes áreas, y la odontología no es la excepción, actualmente ya existe investigación sobre el uso de Redes Neuronales Convolucionales en la detección de lesiones cariosas o periapicales a través del análisis de imágenes por medio del entrenamiento de un Software. Debido a esto se planteó la posibilidad de generar un primer acercamiento y determinar si una Red Neuronal Convolutiva podría clasificar los instrumentos Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), por sus cambios físicos en instrumentos nuevos, después del primer y tercer uso. Durante esta investigación se entrenó una Red Neuronal Convolutiva llamada VGG16, frente a un conjunto de datos que constan de 5,460 imágenes (obtenida de 27 instrumentos Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), que fueron sometidos a tres temporalidades distintas y en diferentes órganos dentarios *in vivo y ex vivo*). Los resultados arrojaron un 83.26 % de exactitud lo cual muestran la posibilidad de identificar y clasificar automáticamente un instrumento rotatorio (nuevo, de uno y tres usos) con ayuda de una Red Neuronal Convolutiva, estos resultados plantean la posibilidad de seguir con futuras investigaciones.

INTRODUCCIÓN

Los instrumentos rotatorios y reciprocantes son parte fundamental para un endodoncista en cada tratamiento de conductos. Sin embargo, existe controversia entre la cantidad de veces que es posible reutilizar un instrumento antes de que éste falle o pierda sus propiedades, por lo que el endodoncista no sabe realmente si su instrumento continúa en buenas condiciones antes de reemplazarlo.

En un estudio del 2002 del doctor Li et al. se observó que los instrumentos rotatorios se dañan progresivamente cuando están sometidos a estrés en movimientos cíclicos, y después de suficientes ciclos, dichos daños micro-estructurales se vuelven acumulativos, lo que eventualmente llevan a la fractura del instrumento. La fatiga cíclica está involucrada en el 50%-90% de las fallas mecánicas de los metales. La fractura de un instrumento endodóntico dentro del sistema de conductos radicular representa un contratiempo indeseable para el endodoncista y para el paciente, ya que los procedimientos para retirar este instrumento son largos, además de que el procedimiento de remoción genera riesgos innecesarios, como el desgaste inevitable de la pared del conducto radicular, así como el impedimento de realizar un protocolo de desinfección ideal. En algunas ocasiones es imposible su remoción, por lo que las bacterias remanentes en el conducto pudiesen provocar una patología periapical, para la cual, es necesario un tratamiento de microcirugía endodóntica con el fin de retirar el factor etiológico de la patología, lo que, a su vez, aumenta los costos de tratamiento para el paciente, así como reduce el pronóstico a largo plazo del órgano dentario. Se plantea un nuevo método mediante el análisis óptico por inteligencia artificial previamente entrenada para detectar cambios físicos en los instrumentos reciprocantes endodónticos, con el fin de determinar si esta inteligencia artificial tiene la capacidad de detectar dichos cambios, por medio del entrenamiento y posterior análisis de una Red Neuronal Convolucional (CNN), sobre fotografías digitales del instrumento

reciprocante, Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), obtenidas con un Microscopio odontológico USA OM-100 (Ecleris©, San Diego, California, USA), con la finalidad a largo plazo de que en estudios posteriores esta tecnología permita al endodoncista saber con confianza si puede continuar con la utilización del instrumento o reemplazarlo, para evitar posibles contratiempos en los tratamientos, con esto se puede promover el uso de los instrumentos en buen estado, se evitarían indeseables separaciones de instrumentos en los tratamientos de conductos, y por lo tanto, se incitará al uso de instrumentos en mejor estado y se obtendría un mejor pronóstico de los tratamientos.

ANTECEDENTES GENERALES

INSTRUMENTACIÓN EN ENDODONCIA

La periodontitis apical es consecuencia de la presencia de bacterias y sus subproductos dentro del sistema de conductos endodóntico (1), por lo tanto, los tratamientos endodónticos con instrumentación químico-mecánica tienen como objetivo disminuir la carga bacteriana dentro del conducto, ya que este enfoque ha demostrado mejorar el pronóstico de los tratamientos a largo plazo (2). La utilización de instrumentos rotatorios ha logrado disminuir los tiempos de procedimiento comparado con técnicas manuales, así como también ha permitido preparaciones más centradas, con menos área de dentina removida y con menos transporte de la anatomía original del conducto radicular principal (3-6). Existe una gran variedad de instrumentos rotatorios y reciprocantes para uso endodóntico en el mercado, de los cuales, el instrumento Wave One (Dentsply Maillefer©, Ballaigues, Suiza), se ha destacado por su movimiento reciprocante variante, la sencillez de su sistema de instrumento única y su aleación de níquel-titanio (Ni-Ti) en fase M de última generación, con lo que se logró un aumento de fuerza, flexibilidad y resistencia a la fatiga cíclica y torsional (7). La fatiga cíclica se desarrolla cuando ocurren ciclos de tensión-relajación al

momento de la rotación del instrumento endodóntico (8). La fatiga torsional ocurre cuando una parte del instrumento, generalmente la punta, queda atrapada por la dentina radicular mientras el cuerpo del instrumento sigue en rotación (9). Este sistema reciprocante fue mejorado con la introducción de la línea “GOLD”, que tiene un diseño transversal diferente y un nuevo tratamiento térmico que mejora la flexibilidad de la instrumento (10-12).

Según diversos autores, la resistencia frente a la fractura del sistema, es debido a la utilización única del instrumento antes de ser desechado, como lo recomienda tanto el fabricante como el director dental de Inglaterra del 2007, quien basa principalmente su inquietud en cuanto la transmisión de enfermedades relacionadas a proteínas priónicas por los instrumentos endodónticos (11,13). Esto es controversial, debido a que, hoy en día, no se ha reportado ningún caso en la literatura de transmisión de paciente a paciente en endodoncia (14), así como no se han encontrado priones en la pulpa. Esto en conjunto con una correcta historia clínica personal y familiar hacen que el riesgo de transmisión en Norteamérica sea extremadamente bajo (15). Otro aspecto por lo que se sugiere el uso único del sistema es la preocupación por la separación del instrumento dentro del sistema de conductos. Numerosos estudios han reportado que la resistencia a la separación de este sistema reciprocante es debido a su aleación (16), a su forma transversal (17) y a la utilización de movimientos reciprocantes (18,19). La mayoría de los estudios que observan las consecuencias de los instrumentos fracturados reportan una mínima influencia sobre el éxito del tratamiento endodóntico (20). Se ha observado en la literatura que los movimientos reciprocantes mejoran la resistencia fatiga cíclica de los instrumentos comparado con el movimiento rotatorio continuo (21). Algunos artículos concluyen que no existe diferencia significativa entre la utilización única del instrumento versus múltiples usos (22), y que el principal factor para la separación de un instrumento es la experiencia y capacidad del operador, más no el tiempo de utilización como se había sugerido

anteriormente (23,24). La mayoría de los estudios coinciden en que los instrumentos visiblemente distorsionados deben ser desechados (25). Existe evidencia de cambios físicos específicos en el cuerpo del instrumento endodóntico que se pueden observar visualmente, cómo por ejemplo, la presencia de fisuras, la elongación o la deformación de la forma original, entre otros, que pudiesen sugerir la deterioración de la resistencia a la fractura del instrumento (26,27). Se ha sugerido que al menos de que se observen distorsiones en el instrumento endodóntico, los instrumentos se pueden utilizar múltiples veces sin riesgo a fractura, inclusive en los instrumentos delgados (25).

AVANCES TECNOLÓGICOS

Con los avances de la tecnología, existe una tendencia por resolver problemáticas a través del apoyo de inteligencia artificial alrededor del mundo, debido a que solucionar problemas a través del avance y desarrollo de nuevo software permite realizar las tareas de manera automatizada con eficiencia y eficacia, gracias a un planteamiento y procesamiento matemático, por lo que se obtiene un resultado casi instantáneo de los mismos. Y en muchos de los casos, más certero de lo que se pudiese efectuar con métodos convencionales (28).

La endodoncia como parte de la odontología ha sido una de las ciencias que más beneficios ha obtenido del avance tecnológico, ya que actualmente en la clínica es posible realizar diagnóstico y tratamientos más eficientes gracias a estos avances tecnológicos; ejemplos muy puntuales de ellos, son la utilización cámaras intraorales, radiografías digitales, tomografías computarizadas de haz cono (CBCT), micromotores electrónicos endodónticos, aparatos ultrasónicos, pistolas de inyección de gutapercha termoplastificada, transportadores de calor, entre otros (29-31).

Utilizar estos avances en la práctica del endodoncista permite acortar tiempos de trabajo, así como mejora en el diagnóstico y, por tanto, el

pronóstico de todos los tratamientos realizados apoyados a partir de la utilización de esos avances, por lo cual, se vuelve indispensable, para el endodoncista, el desarrollo de estas tecnologías emergentes (32).

INTELIGENCIA ARTIFICIAL

Es una rama de la ciencia de la computación que se enfoca en proporcionar a un software, con la capacidad de mostrar un comportamiento “inteligente” al momento de determinar una decisión. Se necesitan diferentes maneras para poder “representar el conocimiento” de interés a un software de tal manera de que este la pueda “Razonar” (33). El razonamiento de la inteligencia artificial permite dar como resultados nueva información relevante (34) y la correcta implementación de la representación del conocimiento junto con un buen razonamiento en el campo de la inteligencia artificial permite a un software resolver o analizar problemas que hubiesen requerido la intervención de un experto humano (33). En las ciencias de la computación se sabe que el primer trabajo donde se modela una red neuronal artificial es en el artículo clásico de John McCarthy titulado como “Programs with Common Sense” de 1959 declara que “Para que un programa sea capaz de aprender algo, primero se le tiene que poder decir” (33). Esto quiere decir que se debe proporcionar las instrucciones de forma completamente clara a través de la escritura de un código sin ambigüedades para que el programa tenga el comportamiento deseado (35). Esto crea la “lógica” de un programa, y siempre tiene como objetivo guiar al programa hacia un razonamiento adecuado sobre un área específica (35).

Escribir un código para crear un nuevo programa, es un proceso complejo (35). Se necesita conocimiento de un avanzado lenguaje de programación que pueda ser leído, comprendido procesado y ejecutado por la línea de comandos de un sistema operativo (36). Estos lenguajes, se rigen bajo su propia sintaxis para poder ser interpretados correctamente por el compilador del programa. Uno de los métodos más prominentes de Machine Learning es aprendizaje profundo (Deep Learning), el cual es ampliamente

utilizado en la resolución de problemas por Inteligencia Artificial (Figura 1.) (35).




Figura 1. A) Artificial Intelligence (AI) o Inteligencia Artificial (IA) es una disciplina de las ciencias de la computación que permite a las computadoras –a través de algoritmos- imitar el comportamiento humano. B) Machine Learning (ML) o Aprendizaje Máquina es un subconjunto de IA que tiene la capacidad de aprender sin ser explícitamente programado. C) Deep Learning (DL) o Aprendizaje Profundo es una sub-rama de las Redes Neuronales Artificiales, la cual es uno de los métodos de ML; de la cual, uno de los principales métodos son las Redes Neuronales Convolucionales (37).

Existen varias arquitecturas de redes computacionales, y entre ellas destacan las Redes Neuronales Convolucionales (CNN por sus siglas en inglés), ya que han mostrado gran desempeño en la tarea de clasificación de imágenes (28,38). Esta configuración de red multicapa y multilineal extrae en una primera fase las características de una imagen, para luego clasificarla a través del recorrido por una red entrenada por retropropagación (39). Este método de aprendizaje supervisado permite a través del análisis de un amplio banco de datos, el refinamiento de un modelo entrenado (algoritmo), el cual mejora conforme más datos procesa, lo que le permite obtener con el tiempo resultados cada vez más optimizados para cumplir con una tarea

deseada (10). La inspiración de la creación y funcionamiento de las redes neuronales artificiales fue a partir de un proceso similar a la fisiología neuronal cerebral (Figura 2.) ya que utiliza una serie de nodos interconectados entre sí que, al cumplir ciertos criterios, se estimulan de manera no lineal lo que finalmente llega a la determinación de resultados, esta unidad básica es llamada perceptrón (40)(41).




Figura 2. Estructura de una neurona biológica (46).

A través de este elemento computacional básico (Figura 3) y otros procedimientos, las mejores características para resolver un problema son aprendidas al momento del entrenamiento del modelo, por lo que se requiere precisar exactamente las características que se deben aprender, lo que resulta en un modelo más competente cuando existen variaciones en los datos proporcionados (39).




Figura 3. *Perceptrón. El elemento computacional básico (neurona) llamado nodo (o unidad) que recibe entradas de fuentes externas y tiene algunos parámetros internos (incluidos pesos y sesgos que se aprenden durante la capacitación) produciendo resultados (42).*

RED NEURONAL CONVOLUCIONAL VGG16

Uno de los modelos de la Red Neuronal Convolutiva (CCN, por sus siglas en inglés) es VGG16 (47). Esta es de las arquitecturas más utilizadas para el manejo de macrodatos en CCN (47), fue publicada e introducida por Simonyan y Zisserman en 2014 (43).

La arquitectura de la Red Neuronal VGG16, es lineal y principalmente usa bloques compuestos por cierto número de capas convolucionales, ellas presentan filtros de 3x3, intercalándose con maxpooling entre cada bloque, para reducir a la mitad los mapas de activación que se van obteniendo de las capas de convolución, se emplea ReLu y al final se utiliza un bloque de clasificación compuesto por dos capas densas de 4,096 neuronas cada una y 1,000 neuronas la última capa (Figura 4.) (43).




Figura 4. Arquitectura VGG16. Presenta capas con filtros de 3x3 (negro), posteriormente las capas de maxpooling intercalándose (rojo) consecutivamente se presentan las capas densas de 4096 neuronas (azul) para finalizar con la última capa de 1000 neuronas (morado), esta red utiliza ReLu (Unidad Lineal Rectificada) debido a sus mejoras de rendimiento para su activación (44).

El número 16 en VGG16 expresa el número de capas con peso que tiene cada red (sin contar las pooling, sólo se cuentan las convoluciones y las capas densas), como se muestra en la (Tabla 1.) en las columnas D (43).

Estas red Neuronal Convolutiva VGG16, ya ha tenido su aparición en un enfoque de aprendizaje profundo para la clasificación del desgaste de herramientas en metalurgia obteniendo un alto porcentaje de exactitud (44,45). Sin embargo, actualmente no se ha empleado para el uso endodóntico, actualmente no existe ningún equipo o técnica que le permita saber clínicamente al endodoncista si hay cambios en un instrumento endodóntico, a menos que el instrumento se encuentre fracturado o muy deformado.

Tabla 1. Configuración de Redes neuronales convolucionales de VGG16.

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224×224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

Tabla 1. Conv/Net (Redes neuronales convolucionales) de VGG16 en columna D). Se muestran las configuraciones de las Conv/Net en las columnas. La profundidad de las configuraciones aumenta de izquierda a derecha a medida que se agregan más capas (en negrita se presentan las capas agregadas). Los parámetros de la capa convolucional se detonan como “conv (receptive field size)-(number of channels)” o “convolución (tamaño del campo receptivo)-(número de canales)” (43). Esta tabla es tomada del artículo de Simonyan y Zisserman 2014 (43).

ANTECEDENTES ESPECÍFICOS

En un artículo publicado en 2020 por Elashiry et al. donde evaluaron a través de tomografía computarizada la habilidad de conformación de los conductos por 4 diferentes sistemas de instrumentación endodóntica concluyeron que el sistema Wave One Gold Primary (Dentsply Maillefer®, Ballaigues, Suiza), produjo la conformación más centralizada y con la menor cantidad de transportación a nivel apical (45).

En otro estudio por Topcuoglu et al. donde evaluaron y compararon 3 diferentes sistemas de instrumentación endodóntica NiTi en dobles curvaturas artificiales determinaron que el instrumento Wave One Gold Primary (Dentsply Maillefer®, Ballaigues, Suiza), tuvo una mayor resistencia a la fatiga cíclica vs los otros sistemas(46). Arens et al. observaron que los instrumentos nuevos tienen una incidencia de 0.9% de fracturarse, inclusive en manos de endodoncistas experimentados, por lo que concluyeron que las fracturas son independientes al número de usos (47). En la serie de publicaciones de 5 partes de Shen et al. en el 2004 concluyeron que la experiencia del operador y la forma de uso del instrumento endodóntico tiene más influencia sobre fractura de los instrumentos que el número de usos (48). Plotino et al. después de la instrumentación de 210 conductos distales en molares inferiores humanos *ex vivo* con un instrumento endodóntico NiTi concluyó que se puede realizar con seguridad hasta 10 veces en conductos ovales (49). En la última revisión sistemática y meta-análisis del International Journal of Dentistry del 2020 por el doctor Dioguardi et al. revisaron diferentes procedimientos para la desinfección y esterilización de los instrumentos endodónticos publicados durante los últimos 40 años y determinaron que el método más efectivo en la esterilización es el autoclave, que todos los instrumentos antes del primer uso requieren de un procedimiento de pre-esterilización o esterilización, y que la esterilización caliente en autoclave no altera las propiedades mecánicas y físicas de la mayoría de los instrumentos NiTi (14). Plotino et

al. declaró que los instrumentos NiTi pueden mejorar su flexibilidad debido al proceso de esterilización (22), así como Zinelis et al. observó que los instrumentos pueden recuperar la deformación causada por su utilización (50). En un estudio de Blanquet-Grossard et al donde se buscaron proteínas priónicas en la pulpa dental en pacientes con enfermedad de Creutzfeldt-Jakob, no fueron capaces de detectar estas proteínas en ninguno de los 8 casos, y recomiendan desinfectar rigurosamente cualquier instrumento sospechosos con NaOCl por 1 hora, para luego esterilizarlo en autoclave a 134°C, o bien, desecharlo (51).

En el artículo clásico de McCulloch & Pitts de 1943 se observó que la actividad neuronal se podía replicar en un modelo matemático, debido a que funcionan de manera binaria, plantearon los fundamentos de las redes neuronales y lograron combinarlas para lograr una máquina de Turing (52). En 1985 Hinton et al. crearon un algoritmo llamado “Boltzmann Machine” que es capaz a través del entrenamiento de modificar la fuerza de sus conexiones internas entre los nodos (peso) que le permiten crear un modelo interno que quedará optimizado para resolver un problema, lo cual, se creía imposible en esos tiempos (53). A partir de estas bases, Hinton, Rumelhart & Williams en 1986 publicaron el método de retropropagación de errores (backpropagation) para el entrenamiento de los algoritmos de las redes neuronales, este entrenamiento ajusta el peso individual entre cada nodo de la red al comparar el resultado final a través de la red contra el resultado esperado, crearon error en caso de diferir, y programaron este error de regreso a través de la red, lo cual hace que el peso de los nodos se ajusten por si solos conforme al error, para intentar producir un resultado con menor error y este proceso se repite varias veces durante el entrenamiento (53). Este proceso tiene el fin de que después del entrenamiento de la red se logren resultados correctos al procesar datos nuevos a través de la red entrenada (54). En otra publicación clásica, por Fukushima en 1980, se propone un modelo neuronal llamado “Neocognitron”, que busca replicar el

patrón de reconocimiento óptico de un cerebro biológico, y concluye que su red neuronal “tiene la capacidad de reconocer patrones estimulantes, sin ser afectada por los cambios en posición o pequeñas distorsiones en la forma de los patrones estimulantes” (44), 8 años después (1988) él mismo logra el entrenamiento exitoso de una red neuronal jerárquica, y demuestra que esta es capaz de reconocer números escritos a mano, esto a través de una serie de capas de nodos neuronales interconectados capaces de reconocer únicamente pequeños patrones antes de avanzar a la siguiente capa aún más compleja, y , al final de esta serie de capas, el nodo más estimulado dicta el resultado (55). En ese mismo estudio se comenta que esta red tiene la capacidad de ser entrenada para lograr reconocer cualquier patrón (55).

LeCun et al en 1998 logra por primera vez entrenar una CNN por medio de un entrenamiento retropropagado, y se observa que las CNN son excelentes para el reconocimiento de imágenes (56). En cuanto la utilización de este tipo de tecnología en ciencias de la salud, en el 2016 Gao et al. lograron clasificar correctamente a través del entrenamiento de redes neuronales tomografías cerebrales de pacientes con Alzheimer (57). Song et al. en el 2017 observaron que una CNN tiene un mejor rendimiento versus otras redes neuronales para clasificar nódulos pulmonares benignos y malignos (58). Sugimori et al. clasificaron imágenes tomográficas con diferentes cortes con una inteligencia artificial entrenada por Deep Learning (59). Una nueva técnica de segmentación de imágenes tomográficas en el diagnóstico de tumores cerebrales fue establecida a partir de la utilización de inteligencia artificial con redes neuronales en el 2017 por Zhao et al. (60). En el campo de la endodoncia, un estudio publicado el año 2019 en el Journal of Endodontics, por Eker et al. entrenaron y utilizaron con resultados satisfactorios una CNN para la detección de lesiones apicales sobre radiografías panorámicas (61). Sabemos que la primera aparición de un enfoque de aprendizaje profundo para la clasificación del desgaste de herramientas con una arquitectura VGG-16 produce una tasa de precisión

del 96 % al diferenciar cuatro formas de desgaste y un error porcentual absoluto medio en la medición del desgaste de menos del 5 % utilizando métodos tradicionales de procesamiento de imágenes (62), por lo que sabemos y con base a la búsqueda que se ha realizado en la bibliografía no se ha encontrado ningún artículo publicado sobre temas aplicados en instrumentos rotatorios endodónticos.

Este acercamiento novedoso permite la creación a futuro de una nueva técnica, para determinar los cambios físicos del instrumento, la cual plantea utilizar inteligencia artificial para determinar cambios físicos, tal vez imperceptibles para el ojo humano, de un instrumento endodóntico, y compararlo contra un instrumento nuevo, esto permite detectar la alteración sufrida por el instrumento utilizado, con la finalidad de que en una segunda etapa poder continuar por el proyecto y así poder proporcionar como objetivo final un nuevo método clínico para el endodoncista, a través de un software, con información relevante para determinar si es conveniente desechar o continuar con la utilización del instrumento endodóntico con un margen de seguridad, antes de ser utilizado en el paciente.

PLANTEAMIENTO DEL PROBLEMA

El endodoncista no sabe realmente si su instrumento reciprocante continúa en buenas condiciones antes de remplazarlo, debido a que no existe una manera clínica de verificar su estado. Un instrumento puede presentar cambios físicos con el uso, como elongaciones o fisuras, lo que puede llevarlo a la fractura dentro del sistema de conductos radicular, lo que representa un contratiempo indeseable para el endodoncista y para el paciente, ya que los procedimientos para retirar este instrumento consumen mucho tiempo, además de que el procedimiento de remoción genera riesgos innecesarios, como el desgaste inevitable de la pared del conducto radicular, así como el impedimento de realizar un protocolo de desinfección ideal. En algunas ocasiones, es imposible su remoción, por lo que las bacterias remanentes

en el conducto pudiesen provocar una patología periapical, para la cual, es necesario un tratamiento de microcirugía endodóntica con el fin de retirar el factor etiológico de la patología, lo que, a su vez, aumenta los costos de tratamiento para el paciente, así como reduce el pronóstico a largo plazo del órgano dentario. Las CNN han mostrado un gran desempeño para el análisis y clasificación de imágenes, lo que las hace ideales para la identificación de cambios físicos sobre los instrumentos reciprocantes endodónticos Wave One Gold Primary (Dentsply Maillefer®, Ballaigues, Suiza), que pudiesen surgir debido al uso. Con todo lo anterior en consideración, surge la siguiente pregunta.

PREGUNTA DE INVESTIGACIÓN

¿Es posible clasificar un instrumento Wave One Gold Primary, por sus cambios físicos a través de una Red Neuronal Convolutacional?

JUSTIFICACIÓN

Este proyecto propone un potencial nuevo método para el reconocimiento de cambios físicos sobre un instrumento endodóntico recíprocante, se plantea utilizar el excelente rendimiento de las CNN en la identificación y clasificación visual para poder lograrlo, y busca concluir si es posible determinar con este acercamiento los cambios físicos sufridos por un instrumento después del uso o bien, no es posible determinarlo con esta tecnología. El proyecto tiene como finalidad a largo plazo, utilizar este acercamiento en un estudio posterior y finalmente lograr la determinación clínica de los cambios sufridos por un instrumento y observar si es posible con esa información recolectada, discernir si un instrumento se puede volver utilizar con seguridad o es mejor desecharlo. Esto lograría solucionar la inseguridad que actualmente tiene el endodoncista al momento de tomar la decisión de utilizar un instrumento previamente utilizado, para instrumentar un nuevo conducto endodóntico, puesto que, hoy en día, no existe un método clínico que permita verificar los posibles cambios sufridos

por un instrumento por el uso, por lo que el endodoncista no sabe el estado físico real del instrumento. Con este proyecto se podría abrir una nueva línea de investigación para la facultad de odontología de la BUAP (FEBUAP), sobre el desarrollo de inteligencia artificial enfocado a la odontología, que tiene un fuerte potencial de crecimiento e investigación. El desarrollo de esta tecnología podría generar la creación de nuevas patentes, permitiría a la FEBUAP destacar gracias a la investigación y desarrollo de tecnologías de vanguardia, además de que permitiría continuar con esta rama de la investigación tanto en el campo de la endodoncia, como en diferentes especialidades de la odontología, por ejemplo, se podría utilizar una CNN en el área de ortodoncia para analizar malposiciones dentales, así como la ubicación de la colocación de los aparatos dentales; en el área de rehabilitación, para analizar los modelos de los pacientes, al reconocer sus características y al proporcionar información útil para elaborar planes de tratamiento y simulaciones de cada paciente en específico, a través inteligencia artificial, entre otras aplicaciones.

VIABILIDAD

Para la realización de este proyecto se gestionó y acordó una colaboración con un asesor externo experto en el área, el Doctor en Ciencias de la Computación Elías Jesús Ventura Molina del Instituto Politécnico Nacional para brindar al proyecto con la evaluación intelectual, técnica y metodológica, especializada en inteligencia artificial; además, en la clínica de endodoncia de la FEBUAP se cuenta con microscopios operatorios con capacidad de captura de fotografías, a disposición de los estudiantes y necesarios para el proyecto.

CONSECUENCIAS DE LA INVESTIGACIÓN

Se ha observado que, en el proceso de instrumentación de un tratamiento endodóntico, los instrumentos NiTi pueden sufrir cambios físicos debido al uso, y existe controversia actual entre los endodoncistas sobre el número de tratamientos en los que se puede utilizar el mismo instrumento antes de

desecharlo, una de las principales complicaciones del proceso de instrumentación endodóntico es la separación de instrumentos, y estas separaciones se han atribuido a la reutilización de los instrumentos. Estas separaciones pueden complicar y retrasar los tratamientos endodónticos, lo que puede comprometer el éxito del tratamiento y a la vez, disminuye la confianza del paciente en el endodoncista.

Debido a lo expuesto anteriormente, surge el presente proyecto de investigación que tiene la finalidad de comprobar si se puede o no determinar los cambios físicos en un instrumento endodóntico a través del entrenamiento y utilización de una CNN y, en el caso de tener resultados favorables, en una segunda etapa se podrá determinar clínicamente el estado físico actual de un instrumento endodóntico antes de ser utilizado, y esto será sumamente beneficioso, ya que se tendrá una manera objetiva para que el endodoncista determine si siguen en buen estado las propiedades físicas y mecánicas del instrumento en cuestión, lo cual impactará en la comunidad endodóntica debido a que actualmente no existe ninguna técnica que permita saberlo, además, de que se propiciará la utilización de instrumentos de buen estado. El desarrollo de esta tecnología podría generar la creación de nuevas patentes, permitiría también destacar a la FEBUAP gracias a la investigación y desarrollo de tecnologías de vanguardia, así como abrir una nueva línea de investigación con este tipo de acercamiento. Este primer acercamiento en el diseño y uso del análisis por inteligencia artificial sobre el estado de los instrumentos endodónticos en odontología podrá generar una herramienta muy útil para las diferentes ramas del campo odontológico, y en cuanto al campo de la endodoncia se refiere, permitirá a futuro disminuir la controversia actual entre los endodoncistas acerca del número de tratamientos en los que se puede utilizar el mismo instrumento antes de desecharlo.

Cabe destacar que se cuenta con el apoyo de un asesor externo experto en el área para brindar al proyecto la evaluación intelectual, técnica y

metodológica, especializada en inteligencia artificial; se cuenta con microscopios operatorios en la clínica de endodoncia de la FEBUAP capaces de tomar las imágenes necesarias para el entrenamiento de la CNN y útiles para concluir si es posible determinar con este acercamiento los cambios físicos sufridos por un instrumento después del uso o bien, no es posible determinarlo con esta tecnología.

HIPÓTESIS

Hi: Es posible clasificar a través de una Red Neuronal Convolutacional los instrumentos Wave One Gold Primary, por sus cambios físicos.

Ho: No es posible clasificar a través de una Red Neuronal Convolutacional los instrumentos Wave One Gold Primary, por sus cambios físicos.

OBJETIVOS

OBJETIVO GENERAL

Determinar si una Red Neuronal Convolutacional puede clasificar los instrumentos Wave One Gold Primary, por sus cambios físicos después del primer y tercer uso.

OBJETIVOS ESPECÍFICOS

- Entrenar a una Red Neuronal Convolutacional para que sea capaz de clasificar al instrumento reciprocante Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), por sus cambios físicos a partir de fotografías digitales obtenidas de un microscopio operatorio.
- Establecer si es posible reconocer a partir del entrenamiento de una Red Neuronal diferencias físicas observables entre un instrumento endodóntico nuevo, y después del primer y tercer uso a partir de 5,460 imágenes.

MATERIALES Y MÉTODOS

DISEÑO DE ESTUDIO

Estudio prospectivo, longitudinal, experimental, analítico, cegado.

TAMAÑO DE MUESTRA

Se obtuvieron 5,460 mediciones totales en 3 temporalidades diferentes de 27 Instrumentos reciprocantes Wave One Gold Primary (Dentsply Maillefer®, Ballaigues, Suiza), (n=27) que cumplieron los criterios de inclusión, fotografiados 70 veces cada uno en la primera, segunda y tercera temporalidad, al finalizar las capturas se eliminaron las imágenes que se encontraron desenfocadas. Lo que dio un total de 1,820 mediciones por temporalidad por los 27 instrumentos (Tabla 2.).

TIPO DE MUESTREO

Se realizó un muestreo no probabilístico por conveniencia, por secuencia de pacientes que cumplieron los criterios de inclusión para la instrumentación (*in vivo*), y se realizó una asignación aleatoria para los instrumentos WOG Primary y los dientes extraídos humano para la instrumentación (*ex vivo*).

Tabla 2. *Tamaño de muestra.*

Instrumento (a)	Temporalidad (b)	Total de instrumentos (c)	Foto (ejemplos) (d)	No. total de fotos (e)
Nuevo	Primera	27		1,820
Primer Uso	Segunda	27		1,820
Tercer Uso	Tercera	27		1,820
Total		27		5,460

Tabla 2. *Tamaño de la muestra y las temporalidades de captura de fotos para cada instrumento. En la columna d) se muestran ejemplos de las imágenes obtenidas en dichas temporalidades. Fuente propia.*

CRITERIOS DE SELECCIÓN PARA INSTRUMENTOS

INCLUSIÓN

- Instrumentos nuevos, empaquetados y del mismo lote.
- Instrumentos Wave One Gold Primary (Dentsply Maillefer®, Ballaigues, Suiza).
- Instrumentos Tamaño 25 mm y conicidad “Primary” 0.25/07 variable.

EXCLUSIÓN

- Instrumentos con defectos de fábrica observables a simple vista.
- Instrumentos que sobrepasen su fecha de caducidad.

ELIMINACIÓN

- Instrumentos que se fracturen durante fase experimental.

CRITERIOS DE SELECCIÓN PARA ÓRGANOS DENTARIOS *IN VIVO* Y *EX VIVO*

INCLUSIÓN

- Longitud de trabajo menor a 25mm.
- Diagnóstico previo de pulpitis irreversible asintomática y sintomática y necrosis pulpar.
- Órganos dentarios permanentes sin tratamiento de conductos.
- Contar con radiografía de conductometría.

EXCLUSIÓN

- Órganos dentarios que requieran tratamientos, u O.D. fracturados.
- Terceras molares.
- Dentición temporal o ápice inmaduro.
- Longitud de trabajo mayor a 25 mm.
- Previa instrumentación rotatoria.
- Presencia de instrumentos fracturados.

VARIABLES

VARIABLES	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL	CATEGORÍA	ESCALA
IMAGEN JPG (INDEPENDIENTE)	Archivo digital que contiene una imagen en alta definición del instrumento a analizar.	Imagen JPG, capturada en alta definición a través de la cámara Nikon de un microscopio operatorio.		
CAMBIOS FISICOS (DEPENDIENTE)	Detección de cualquier cambio físico del instrumento observable por la red neuronal.	Examinación y clasificación de imagen JPG a través de una CNN	Cualitativa Nominal Policotómica.	A. Nuevos B. Dos usos. C. Tres usos.
VERDADEROS POSITIVOS (DEPENDIENTE)	La red neuronal convolucional clasifica correctamente un instrumento alterado.	Comparación de los resultados del software con el estándar de oro	Cuantitativa por razón discreta.	Números absolutos.
VERDADEROS NEGATIVOS (DEPENDIENTE)	La red neuronal convolucional clasifica al instrumento sin alteraciones, sin embargo, si las presenta.	Comparación de los resultados del software con el estándar de oro.	Cuantitativa por razón discreta.	Números absolutos
FALSOS POSITIVOS EN EL SOFTWARE (DEPENDIENTE)	La red neuronal convolucional clasifica al instrumento sin alteraciones, sin embargo, si las presenta.	Comparación de los resultados del Software con el estándar de oro.	Cuantitativa por razón discreta.	Números absolutos
FALSOS NEGATIVOS EN EL SOFTWARE (DEPENDIENTE)	La red neuronal convolucional clasifica al instrumento como Alterado, sin embargo, no lo está.	Comparación de los resultados del software con el estándar de oro.	Cuantitativa por razón discreta.	Números absolutos
EXACTITUD (DEPENDIENTE)	La exactitud mide cuánto se aproximan los resultados al valor verdadero o conocido.	Comparación de los resultados del software con el estándar de oro.	Cuantitativa	0-100%

CONCORDANCIA Y FIABILIDAD

El alumno se estandarizó con experto por coeficiente de correlación intraclase o R^2 de Pearson.

UBICACIÓN ESPACIO TEMPORAL

1. Clínica de endodoncia de la Maestría en Estomatología con opción terminal en Endodoncia de la Benemérita Universidad Autónoma de Puebla, Puebla, México.
2. OIO ODONTOLOGIA INTEGRAL Y ORTODONCIA, con ubicación en 39 Oriente, 1813 El mirador.
3. Instituto Politécnico Nacional.

PROCEDIMIENTOS, TÉCNICAS Y FUENTES DE RECOLECCIÓN

PRUEBAS PILOTO Y CREACIÓN DE BASE PARA CAPTURAS DE IMAGEN.

Se creó un aditamento, para estabilizar al instrumento Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), durante la captura de imágenes, con el fin de brindar estabilidad y reproducibilidad, de esa manera se capturaron diferentes imágenes, durante la fase de fotografías bajo microscopio (Figura 5).




Figura 5. Base con aditamento para toma de fotografías. Consiste en una jeringa de 20 ml, sobre una base de plástico delgado y rígido, envuelta por dos esponjas en media luna que permitiera estabilizar y al mismo tiempo la posibilidad de rotar la jeringa, se realizaron 70 líneas sobre la circunferencia de la jeringa para girar intermitentemente la jeringa y por ende obtener 70 imágenes diferentes. Fuente propia.

Se realizaron diversas pruebas piloto para la obtención de imágenes en:

- Microscopio Seiler Alpha Air 3, (Seiler Medical©, Missouri, USA), y cámara GoPro Hero10 (San Mateo, CA, USA).
- Cámara Canon Rebel T7 (Canon, Inc., Ōta, Tokio), con Lente Canon EF 100mm f/2.8L Macro IS USM (Canon, Inc., Ōta, Tokio).
- Microscopio odontológico USA OM-100 (Ecleris©, San Diego, California, USA), con Cámara Digital Nikon D5300 (Nikon©, Tokio, Japón). Siendo este equipo el que se eligió para la investigación, debido a la calidad de imagen obtenida, esto incluye definición, claridad, aumento (Figura 6.).




Figura 6. Imágenes obtenidas durante prueba piloto. **A)** Imagen obtenida durante prueba piloto con Microscopio Seiler Alpha Air 3, (Seiler Medical©, Missouri, USA), y cámara GoPro Hero10 (San Mateo, CA, USA). **B)** Imagen obtenida durante prueba piloto con Cámara Canon Rebel T7 (Canon, Inc., Ōta, Tokio) con Lente Canon EF 100mm f/2.8L Macro IS USM (Canon, Inc., Ōta, Tokio) **C)** Imagen obtenida durante prueba piloto con Microscopio odontológico USA OM-100 (Ecleris©, San Diego, California, USA), y Cámara Digital Nikon D5300 (Nikon©, Tokio, Japón). Fuente propia.

Fase 1. Toma de fotografías de instrumentos Wave One Gold Primary Nuevos.

Junto con el Microscopio odontológico USA OM-100 (Ecleris©, San Diego, California, USA), (iluminación de LED 80 Watts con luz fría y blanca de alta intensidad,) con aumento de 25x y su cámara Nikon 6 (con una resolución de 24 megapíxeles, ISO 200, velocidad 1/60), se tomaron 2,100 fotografías digitales. Las imágenes se obtuvieron en formato JPG de los 30 instrumentos nuevos. (Figura 7.)




Figura 7. Captura de imágenes de los 30 instrumentos nuevos Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), con Microscopio odontológico USA OM-100 (Ecleris©, San Diego, California, USA), y su cámara Nikon. Fuente propia.

Esterilización (Fase 1).

Cada instrumento Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), fue designado a un esterclave y etiquetado con un número para todo el proceso experimental. Después se colocaron en autoclave Lorma© durante 30 minutos a 121°C.

- **Asignación aleatoria de instrumentos**, para probar la causalidad y asegurar la efectividad del instrumento, los 30 instrumento Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), fueron sometidos a este proceso por medio de software Excel 365© (Microsoft©), permitiendo controlar todos los factores conocidos y desconocidos que pudieran afectar los resultados en los diferentes instrumentos.
- **Consentimiento informado.** Los participantes recibieron y firmaron

un consentimiento informado, el cual se les proporciono antes de ingresar a la clínica de Endodoncia (Anexo 1).

Fase 2. Primer uso de instrumentos endodónticos Wave One Gold Primary (*in vivo*).

Se incluyeron cinco estudiantes y un especialista pertenecientes al posgrado de endodoncia, de la Benemérita Universidad Autónoma de Puebla, para el procedimiento endodóntico e instrumentación con Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), y Micro-motor X-SMART® PLUS (Dentsply Maillefer©, Ballaigues, Suiza), en pacientes que acudieron a la clínica de Endodoncia del Posgrado de la Benemérita Universidad Autónoma de Puebla. Cada instrumento, fue asignado de manera aleatoria entre los 6 participantes, para un total de 30 órganos dentarios instrumentados (*In vivo*), considerando las siguientes indicaciones:

Se realizó bajo aislamiento absoluto, la preparación del acceso fue en línea recta al orificio del conducto, la instrumentación se acompañó con irrigación abundante de NaOCl al 5.25%, corroborando intermitentemente la permeabilidad del conducto con un instrumento manual de acero inoxidable K ISO 010.

El protocolo previo al uso del instrumento consistió en explorar el (los) conducto(s) con instrumentos manuales K ISO 010 y K ISO 015 en presencia de hipoclorito de sodio, se estableció longitud de trabajo y posteriormente se realizaron movimientos de picoteo suave hacia adentro del conducto radicular, con avances pasivos de poca profundidad con el instrumento Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza). Finalmente, el endodoncista contestó un formulario con datos del paciente y del órgano dentario (Anexo 2).

Desinfección y esterilización (Fase 2). Los instrumentos se colocaron en un proceso de desinfección y esterilización ultrasónico con XZYME limpiador enzimático (Vamasa, Cd. México, México),

durante 20 min (Figura 8.), cada instrumento se colocó en su esterclave asignado y etiquetado con un número, para después colocarlos en la autoclave (Lorma©, México, México), durante 30min a 121°C.




Figura 8. *Proceso de desinfección y esterilización en las instalaciones de la clínica de posgrado endodoncia de la Benemérita Universidad Autónoma de Puebla. Fuente propia.*

Fase 3. Toma de fotografías de los instrumentos después del primer uso.

En un Microscopio odontológico USA OM-100 (Ecleris©, San Diego, California, USA), y su Cámara Digital Nikon D5300 (Nikon©, Tokio, Japón), enfocado a 2.5 potencias (2.5X), se tomaron 70 fotografías digitales con su cámara integrada con una resolución de 24 megapíxeles, ISO 200, velocidad 1/60, en formato JPG de cada uno de los 30 instrumentos, para un total de 2,100 observaciones en la temporalidad cursante.

Fase 4. Segundo y tercer uso de los instrumentos (*ex vivo*)

Se repitió el procedimiento descrito en la Fase 2 durante 2 ocasiones, pero se realizó en piezas muertas, las cuales fueron previamente desinfectadas en formalina al 10% durante 7 días. (Figura 9.)



Figura 9. Manejo e Instrumentación de órganos dentarios extraídos previamente contenidos en formalina al 10%. Se muestra la asignación por aleatorización de los órganos dentarios respecto a los instrumentos Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza). Fuente propia.

FORMALINA AL 10%

Conociendo el riesgo de fractura del instrumento se decidió utilizar dientes humanos extraídos, ya que son una valiosa fuente de material biológico y son indispensables para fines de investigación (63). Sandhu et al. Demostraron que la inmersión en formalina al 10% durante 5 días, fue un método exitoso para esterilizar los dientes humanos extraídos (64,65). Dominici et al. Mencionan que este método no provoca daño a la estructura o microdureza dentinaria comparado con el hipoclorito de sodio (65,66), no se colocaron en autoclave a pesar de ser un estándar de oro para la esterilización ya que Salem et al. demostraron que la autoclave reduce el 12% de la microdureza de la dentina (67). Se optó por dientes extraídos humanos siendo el estándar de oro ya que la microestructura del tejido animal es bastante similar pero no idéntica (67). Para el almacenamiento

posterior se optó por agua desionizada (hasta 2 meses) sugerido por Berdan et al. (68).

Después del segundo y tercer uso, se repitió el proceso de esterilización y desinfección de la fase 2. Cabe señalar que durante la fase experimental de tercer uso se fracturaron 3 instrumentos de los 30 instrumentos rotatorios Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza) que se pretendían estudiar, por lo que solo se incluyeron 27 instrumentos para la fase del entrenamiento de la CNN, dando un total de 5,460 imágenes como se muestra en la (Tabla 3.).

Tabla 3. *Imágenes totales para el entrenamiento de la CNN.*

Instrumentos rotatorio WOG Primary	Total de imágenes
27 Nuevos	1820
27 Un uso	1820
27 Tres usos	1820
Total	5460

Tabla 3. *Total de imágenes, debido a la eliminación de las imágenes obtenidas de los 3 instrumentos fracturados. Fuente propia.*

Fase 5. Entrenamiento de la Red Neuronal Convolutacional y prueba de validación de la Red Neuronal Convolutacional.

Se entrenó a la Red Neuronal Convolutacional, a partir de las 5, 460 imágenes JPG recolectadas de la suma de las 1,820 fotografías obtenidas en la primer temporalidad que corresponden a los instrumentos nuevos, las 1,820 fotografías obtenidas de la segunda temporalidad de instrumentos de primer uso y 1,820 fotografías tercera temporalidad correspondientes al tercer uso,

de los 27 instrumentos restantes, para poder generar el aprendizaje del algoritmo. El conjunto de aprendizaje obtenido en la partición se utilizó para realizar la fase de prueba del algoritmo.

Después de que se entrenó el modelo de aprendizaje a través de la Red Neuronal Convolucional VGG16, fue necesario averiguar qué tan bien funcionó este modelo, Saber: ¿Si es suficientemente exacto para ser utilizado? Existen varios métodos de validación que lo podían determinar, el que se eligió fue K-Fold Cross-Validation (43).

Durante la prueba de validación (K-Fold Cross-Validation) se realizó un procedimiento donde a la letra K se le asigna un valor, comúnmente es 5 o 10, para esta investigación se eligió K=5, basándonos en el documento de Bruce G. & Anca, donde demuestran que “k=5” fue suficiente para usar en muestras grandes (n=5000), y por consiguiente efectiva para esta muestra de 5,460 imágenes (69).

Los pasos que se siguieron durante esta validación fueron los siguientes.

1. Se aleatorizó el banco de datos y se realizó la división del banco de datos en k partes.
2. Como el valor de K=5, cada temporalidad o clase fue dividida en 5 folds (numerados del 1 al 5) con 364 imágenes cada uno. Posteriormente cada fold fue asignado a un fold numerado del 1 al 5, correspondiendo al número designado inicialmente (Figura 10).




Figura 10. Secuencia de K-Fold Cross-Validation. Se muestra la aleatorización del banco de datos y la división del banco de datos en K partes iguales. Fuente propia.

3. Posteriormente se realizaron 5 ejecuciones.
 - a. En la primer ejecución se mostraron al programa los 4 primeros folds que corresponden al conjunto de aprendizaje (CA), y se preguntó por el quinto fold que corresponde al Conjunto de prueba (C.P). Posteriormente se calculó la exactitud de dicha ejecución.
 - b. En la segunda ejecución se mostró al algoritmo los folds 1, 2, 3 y 5 los cuales eran el CA, y se preguntó por el cuarto fold o C.P. Posteriormente se calculó la exactitud de dicha ejecución.
 - c. En la tercera ejecución se mostró al algoritmo los folds 1, 2, 4 y 5 los cuales eran el CA, y se preguntó por el tercer fold o C.P. Posteriormente se calculó la exactitud de dicha ejecución.
 - d. En la cuarta ejecución se mostró al algoritmo los folds 1, 3, 4 y 5 los

- cuales eran el CA, y se preguntó por el segundo fold o C.P. Posteriormente se calculó la exactitud de dicha ejecución.
- e. En la quinta ejecución se mostró al algoritmo los folds 2, 3,4 y 5 y los cuales eran el CA, y se preguntó por el primer fold o C.P. Posteriormente se calculó la exactitud de dicha ejecución (Figura 11).
4. Al concluir con un número k de puntajes de evaluación, estos resultados se promediaron y con ello se obtuvo la exactitud.
 5. La exactitud también se obtuvo de la fórmula para tres clases la cual se presentará más adelante.




Figura 11. Proceso principal de K-Fold Cross-Validation, del lado izquierdo se presenta el número de ejecución, en rojo se muestran los conjuntos de aprendizaje (C.A.) y en verde el conjunto de prueba (C.P.), cada imagen representa a 365 imágenes que fueron aleatorizadas previamente en la división del banco de datos. Fuente propia.

ANÁLISIS ESTADÍSTICO

Calcular el Verdadero positivo, verdadero negativo, falso positivo y falso negativo para tres conjuntos de imágenes, y obtener la exactitud.

Para calcular el desempeño del algoritmo se calcula la exactitud con la fórmula para tres clases (Figura 12.), a través de la matriz de confusión.

$$Exactitud = \frac{\sum_{i=1}^l TP_i}{n} * 100$$

Figura 12. Fórmula para calcular la exactitud en matriz de 3 clases.

LOGÍSTICA

RECURSOS HUMANOS

- Investigador:
Alma Angélica García Bocanegra.
- Responsable de Tesis:
D. C. Miguel Ángel Casillas Santana.
- Director Disciplinario:
D. C. Brenda Eréndida Castillo Silva.
- Director Metodológico:
M. S. P. Rosendo Gerardo Carrasco Gutiérrez.
- Asesor interdisciplinario externo (Inteligencia Artificial):
D.C.C. Elías Jesús Ventura Molina.

RECURSOS MATERIALES

- 30 Instrumentos, Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza).
- Micro-motor X-SMART® PLUS (Dentsply Maillefer©, Ballaigues, Suiza).

- Cámara Digital Nikon D5300 (Nikon©, Tokio, Japón).
- Microscopio odontológico USA OM-100 (Ecleris©, San Diego, California, USA).
- XZYME limpiador enzimático (Vamasa, Cd. México, México).
- Autoclave (Lorma©, México, México).
- Excel 365© versión 16.38 (Microsoft®).

RECURSOS FINANCIEROS

- Beneficios otorgados por el Programa Presupuestario Becas de Posgrado y Apoyos a la Calidad de CONACYT
- Beneficios otorgados por el posgrado de Estomatología con terminal en Endodoncia y el Dr. Alejandro Martínez (quien otorgo acceso a sus instalaciones y permitió la utilización de su Microscopio odontológico USA OM-100 (Ecleris©, San Diego, California, USA), integrado con Cámara Digital Nikon D5300 (Nikon©, Tokio, Japón).
- Aportación financiera por parte de la investigadora.

CRONOGRAMA DE ACTIVIDADES

	Año 2021		Año 2022		Año 2023				
ACTIVIDADES	Ene- Jun	Jul-Dic	Ene- Jun	Jul-Dic	Ene	Feb	Mar	Abr	May
Elaboración protocolo de investigación.									
Diseño de prototipo del software.									
Revisión y aprobación de protocolo.									
Pruebas de imagen.									
Recolección de la información.									
Organización de la información y capturas de imagen.									
Análisis de la información.									
Interpretación.									
Elaborar conclusiones.									
Presentación y difusión.									

Tabla 4. Cronograma de actividades.

BIOÉTICA

Este estudio se apega a la Ley General de salud en materia de investigación y a los principios de Helsinki que garantiza la integridad física y mental de los pacientes. Con respecto a la instrumentación *ex vivo*, se considera sin riesgo, cumpliendo las normas de bioseguridad y éticas con la posibilidad de cumplir necesidades académicas y de investigación. (65,70,71).

RESULTADOS

La Red Neuronal Convolucional llamada VGG16, frente a un conjunto de datos para la clasificación del número de usos por sus cambios físicos, en el instrumento rotatorio Wave One Gold Primary© (Dentsply Maillefer,

Ballaigues, Suiza), cumple con la tarea prevista. El conjunto de datos constó de 5,460 imágenes de instrumentos WOG Primary, los cuales pueden ser clasificados por el algoritmo en instrumentos nuevos, de un uso y de tres usos, reconociendo los cambios físicos y permitiendo su clasificación con una exactitud del 83.26 % (Figura 13.), dicho porcentaje también expresa los resultados obtenidos de K-Fold Cross-Validation.

		Real		
		Clase A	Clase B	Clase C
Predicción	Clase A	1637	160	23
	Clase B	331	1151	338
	Clase C	28	34	1758

$$Exactitud = \frac{\sum_{i=1}^n TP_i}{n} * 100$$

$$= \frac{4546}{5460} * 100 = 83.26\%$$

Figura 13. Matriz de confusión de 3 clases, cada clase representa a los instrumentos WOG Primary, siendo la Clase A) nuevos, B) un uso, C) tres usos. Está matriz de confusión se obtuvo del promedio de datos obtenidos de la prueba de validación que posteriormente se emplearon en la fórmula donde se obtuvo el 83.26 % de exactitud para esta prueba. Fuente propia.

El haber entrenado una red neuronal en esta investigación, demuestra por primera vez, que es posible clasificar un instrumento rotatorio Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), por sus cambios físicos a partir de una CNN llamada VGG16, a partir de un entrenamiento

con imágenes obtenidas de un Microscopio odontológico USA OM-100 (Ecleris©, San Diego, California, USA). Estableciendo la posibilidad de reconocer diferencias físicas en un instrumento nuevo, de un uso y tres usos a partir de 5,460 imágenes.

Los resultados obtenidos en la matriz de confusión de 3 clases, muestra la eficacia de la clasificación de esta CNN, en la temporalidad de instrumentos “nuevos”, en ella se obtuvieron 1,637 verdaderos positivos (VP) de una muestra de 1,820, con respecto a la suma de las muestras obtenidas de verdaderos negativos (VN) falsos positivos (FP) y falsos negativos (FN) se obtuvieron 183 muestras totales. En la temporalidad de instrumentos de “un uso” se obtuvieron 1,151 VP y 669 errores que (VN, FP, FN.) En la temporalidad de instrumentos de “tres usos” se obtuvieron 1758 VP y un total de 62 errores (VN, FP y FN). Todas en contraste de una muestra total de 1, 820 imágenes por temporalidad.

Para expresar los cambios físicos del instrumento Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), la CNN de un total 1820 muestras, detecto 1,637 instrumentos correctamente como “instrumentos nuevos”, 1,758 “instrumentos de tercer uso” y 1,151 los “instrumentos un uso”.

Inicialmente se instrumentaron 90 órganos dentarios (30 *in vivo*, 60 *ex vivo*) con 30 instrumentos, en tres temporalidades distintas. Durante la última fase de instrumentación se fracturaron 3 instrumentos y fueron eliminados (Figura 14.) (Tabla 5.), Solo se consideraron 27 instrumentos para la captura de fotografías, para el entrenamiento de la CNN con un total de 5,460 imágenes diferentes. Finalmente se instrumentaron 19 incisivos, 10 caninos, 33 premolares y 19 molares. En la temporalidad de un uso la mayoría de los instrumentos WOG Primary instrumentaron de 1 a 3 conductos, mientras que en la tercera temporalidad la mayoría de los instrumentos WOG Primary instrumentaron de 5 a 7 conductos. (Tabla 6.)




Figura 14. Se presentan los tres instrumentos fracturados. a) Fotografía de instrumento No.8 fracturado, b) fotografía de instrumento No.10 fracturado. C) fotografía de instrumento No.17 fracturado. Fuente Propia.

Tabla 5. Características de Órganos dentarios correspondientes a instrumentos fracturados.

No. de Instrumento WOG Primary Primary	OD y número de conductos instrumentados				No. de conductos instrumentados en total
	Temporalidad Primer uso	Temporalidad Segundo uso	Temporalidad Tercer Uso	Observación	
8	Premolar 2 conductos	Molar inferior 3 conductos	Premolar 2 conductos	Estrechos y curvos	7
10	Incisivo superior 1 conducto	Premolar 2 conductos	Molar superior 4 conductos	Estrechos y curvos	7
17	Premolar 1 conducto	Premolar 2 conductos	Premolar 2 conductos	Estrechos y curvos	5

Tabla 5. Características de Órganos dentarios correspondientes a los instrumentos fracturados durante la fase experimental, observándose la similitud en sus observaciones. Fuente propia.

Tabla 6. Número de conductos instrumentados por los instrumentos Wave One Gold Primary.

a) Temporalidad de Primer uso		b) Temporalidad de Tercer uso	
No de Conductos instrumentados	Total de limas	No de Conductos instrumentados	Total de limas
1	9	3	5
2	8	4	4
3	9	5	8
4	1	6	4
		7	6

Tabla 6. Número de conductos instrumentados por los instrumentos Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), en temporalidad uno (a) y tres (b). Fuente propia.

DISCUSIÓN

En esta tesis se propone un enfoque para clasificar instrumentos endodónticos rotatorios Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), a través de una CNN llamada VGG16, en un primer acercamiento y determinar si está puede clasificarlos por sus cambios físicos en instrumentos nuevos, después del primer y tercer uso (43,72).

Actualmente no existen estudios similares en la rama de la endodoncia, solo se cuenta con referencias que presentan objetivos y estrategias similares. Estas investigaciones abordan temas como, manufactura, industriales, metalurgia, con IA y hacen uso de CNNs, por lo que se usarán esos artículos como los reportes de comparativa más cercanos al modelo que estudiamos (62,73,74).

Por el momento sabemos que esta investigación es prometedora ya que se obtuvo un 83.26 % de exactitud, este resultado es comparable con los estudios de Arellano et al. quienes presentan un enfoque novedoso de big data para la clasificación, conforme al desgaste que tuvieron herramientas de corte de la industria manufacturera, basado en imágenes de señales y

aprendizaje profundo, logrando una exactitud del 83%, similar a este estudio (73).

También se observa que la exactitud obtenida en esta investigación se encuentra ligeramente por debajo de los resultados de Bergs et al. quienes se enfocaron en la industria de corte de metales, logrando una exactitud del 95.6% con una CNN simple; ellos clasificaron los tipos de herramientas, como la fresa de bola, esférica, escariadora, brocas, herramientas de inserción y perforación. Aunque la tarea de clasificar es la misma, comparando la CNN utilizada por Bergs et al. podríamos pensar que la CNN VGG16 utilizada en esta investigación se enfrentó a una tarea más compleja, por la dificultad que tuvo para detectar cambios minúsculos y casi imperceptibles en las imágenes de los instrumentos WOG Primary, dando como resultados una exactitud menor (83.26%) (62).

En general, el porcentaje de casos clasificados con exactitud en el conjunto de estudios es alto, sobrepasando en la mayoría de los casos el 80 % lo que permite posicionar a nuestro estudio con un desempeño del algoritmo eficaz, comparándolo con los estándares de otros resultados. También debemos mencionar que no hay estudios previos sobre Instrumentos WOG con base a eso y comparándolo a estudios similares, el resultados de la exactitud es considerado alto, esto también se puede deber a la red ya que existen similitudes por que utilizan la misma fase de aprendizaje, por otra parte el porcentaje de exactitud si podría depender del tipo de variable que se busca entrenar, como se mencionó anteriormente, no es lo mismo detectar cambios en un instrumento con diferencias a veces imperceptibles, comparado con la tarea de diferenciar imágenes con mayores diferencias por ejemplo una broca y una fresa esférica. De acuerdo a la literatura el porcentaje se encuentra en el rango de exactitud bueno y con posibilidad de mejorar resultados ya que los investigadores hacen investigación en las CNNs y estas van avanzando día con día, mejorando sus capacidades (73,75,76).

La exactitud se eligió como parámetro de referencia a evaluar debido a que las investigaciones previas en el área y similitudes con otros estudios relacionadas a la endodoncia, ha sido utilizado, aunque no involucran instrumentos rotatorios, por ejemplo, el estudio de Liwen Zheng et al, quienes analizan las imágenes como radiografías periapicales en la búsqueda del diagnóstico de caries profunda y pulpitis, obteniendo un 82% de exactitud con ayuda de CNN (34). También es el caso de Chun-Wei Li et al. quienes buscaron detectar lesiones apicales dentales mediante CNN en radiografías periapicales logrando un 92% de exactitud, también otros estudios mencionados anteriormente, que aunque no son del área tiene similitudes con esta investigación, Bergs et al. y Arellano et al. obtenido un 95.6% y 83% de exactitud respectivamente (62,73). La exactitud también se eligió como parámetro ya que es referida a una sola medición, el grado de aproximación entre un valor medido y el valor real que se pretende medir; y es referida a una serie de mediciones, el grado de aproximación entre la media de los valores medidos y el valor real que se pretende medir. Además, "exactitud" nos dice qué conclusiones se pueden sacar sobre un equipo, persona o en este caso de la CNN en función de un resultado de prueba(77).

En la Matriz de confusión la alta tasa de éxito es del 83.26% de exactitud, en ella se observa una clasificación asertiva de 1,637 muestras de las 1,820 muestras totales para “instrumentos nuevos”, eso quiere decir que el algoritmo solo tuvo un total de 183 muestras con falla (FP, VN FN), clasificando 160 muestras en instrumentos de un uso y 23 muestras en “instrumentos de tres usos”, eso significa que la red tiene una buena capacidad para diferenciar un instrumento nuevo de uno que fue utilizado por tercera ocasión (53).

Cabe mencionar que hubo un mejor acierto en la clasificación de instrumentos de “tres usos”, ya que de las 1,820 muestras, 1,758 fueron clasificadas correctamente (VP) y 62 muestras clasificadas incorrectamente (FP, VN, FN), eso quiere decir que para la CNN es mucho más fácil clasificar

los instrumentos que han tenido más usos, esto podría deberse a que existe una mayor deformación en el instrumento, también se observa que de esas 62 muestras incorrectas, 34 están clasificadas en instrumentos de un uso, y esto lo podemos asociar a algo, probablemente la CNN no esté errando, quizás estos instrumentos de tres usos podrían tener un desgaste similar a un instrumento de un uso que fue sometido a un molar con 4 o 5 conductos, y por tanto registró una mayor deformación (para su fotografía de un uso), valdría la pena continuar con esta línea de investigación para obtener mayores resultados, recordando que esté es un primer acercamiento a las CNN en el área, donde se pretende explorar la posibilidad de obtener una respuesta para clasificar un instrumento pequeño y complejo estructuralmente (78-80).

Por otra parte los resultados no fueron tan asertivos al clasificar instrumentos de “un uso”, ya que de las 1,820 muestras solo 1,151 fueron correctas (VP) y 669 tuvieron falla (FP, VN, FN), al momento de clasificar 331 muestras se clasificaron en “instrumentos nuevos”, y 338 muestras en “instrumentos de tres usos”, eso quiere decir que es más complejo para el algoritmo clasificar un instrumento de un uso, que un instrumento de tres usos o sin ningún uso (nuevos), esto puede deberse al número de conductos que se instrumentó en primera instancia lo que podría ser similar al desgaste obtenido en un instrumento de tres usos, por ejemplo, un instrumento que fue sometido en 3 conductos en total hasta su tercera temporalidad y un instrumento que instrumento 3 conductos en su primera temporalidad (78-80). También podría deberse a la anatomía radicular, el grado de curvatura de la raíz, el número de conductos al que el instrumento es sometido, cálculos pulpares presentes, o si el conducto estaba obliterado incluyendo la experiencia o manejo por parte del operador (81).

Conociendo estos resultados donde una CNN puede detectar y clasificar un instrumento endodóntico, y en la conciencia de que existen múltiples

posibilidades en las que un instrumento puede deformarse (74) desde el uso uno, se podría entrenar una CNN para predecir una posible fractura (46).

Una posible debilidad del presente trabajo es la selección de órganos dentarios ya que no se consideró homologarlos, entonces ¿Porque no se homologó a un tipo de órganos dentarios, por ejemplo porque no solo se realizó en primeras molares inferiores o se homologó el número de conductos? En éste estudio se consideró que de ser así el algoritmo sólo hubiera sido entrenado para clasificar instrumentos que fueran sometidos a un solo tipo de características. Por esa razón se decidió que los instrumentos fueran sometidos a diferentes órganos dentarios y número de conductos para ver si la CNN sería capaz de aprender a diferenciarlos para clasificarlos de acuerdo al número de usos (82,83).

En el ámbito clínico el uso de instrumentos en múltiples veces puede ser factible sin riesgos, a menos que se observen distorsiones en el instrumento endodóntico (25)(81) o ya haya sido utilizado en varias ocasiones. La relevancia de estos resultados pioneros y favorables con una alta tasa de exactitud del 83.26% permiten la posibilidad de abrir una línea de investigación y así, seguir entrenando la CNN, a través de una base de datos más robusta, con objetivos bien estructurados y más ambiciosos, para lograr incluso la predicción de un posible riesgo de fractura en un instrumento Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), a través de una imagen, de esa manera podrían evitarse contratiempos malos procedimientos en la consulta (23).

Se analizó en el instrumento Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), por ser un instrumento único y así evitar la instrumentación previa permitiendo homologar el proceso de instrumentación, por otra parte, su diámetro en D0 es 025/07 lo que podría registrarse visiblemente más en la fotografía bajo microscopio comparado

con sistema BlueShaper® Murcia España, que tiene un instrumento Z1 Y Z2, que tiene diámetros en D0 DE 0.14 Y 0.17 respectivamente (84,85).

Durante la fase experimental se utilizó el motor de endodoncia X-SMART® PLUS, Dentsply Sirona Maillefer, el cual está programado para sistema Wave One Gold Primary (Dentsply Maillefer®, Ballaigues, Suiza), una ventaja de esto es que ya posee un torque controlado y ajustado individualmente para cada instrumento, reduciendo así el riesgo de fractura del instrumento (86). Sin embargo, en este estudio se presentaron 3 instrumentos fracturados. Fangli et al. mencionan que la falla puede deberse a que los sistemas de un solo instrumento están sujetos a grandes tensiones al dar forma a los conductos radiculares con un solo instrumento. Especialmente ocurre en molares con al menos tres conductos radiculares que pueden ser complejos, curvos y estrechos (84). En esta investigación concordamos con dicho estudio ya que los instrumentos fueron sometidos a órganos dentarios con más de un conducto, estrechos y curvos, por lo que este u otro algoritmo podría ser entrenado para predicción y así servirnos de gran utilidad ante una posible fractura.

POSIBILIDAD DE FUTURA INVESTIGACIÓN

Este proyecto al ser pionero en esta área, se enfocó en determinar si una CNN llamada VGG16, sería capaz de clasificar un instrumento rotatorio por su número de usos de acuerdo al tipo de desgaste, viendo el resultado obtenido, se abre una línea de investigación, para obtener una base de datos más robusta, buscar entrenar la red neuronal convolucional para una tarea más compleja, modificando el algoritmo, obteniendo fotos de mayor calidad y así determinar en qué tipo de dientes fue utilizado el instrumento, la modificación de la red para realizar predicción sobre una posible fractura en el instrumento, entrenar la CNN para otros sistema, o comparar los resultados de este estudio con el sistema de instrumento único Excalibur®, de Zarc4endo, Murcia España, (85) con un probable resultado satisfactorio

debido a la similitud que este instrumento (Excalibur) tiene con el Sistema Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza).

La Inteligencia Artificial está abriendo puertas de oportunidad, donde antes parecía casi imposible de lograr. Hasta la fecha no hay forma de saber a través de una imagen, si un instrumento se puede reutilizar antes de que este se fracture, y todavía no llegamos a resolver esa respuesta, pero se ha puesto en marcha la obtención de ella a través de las CNNs.

CONCLUSIÓN

Comparando con otros estudios que involucran clasificación y desgaste de metales, en esta investigación se determinó la búsqueda de exactitud de la CNN para la clasificación de instrumentos Wave One Gold Primary (Dentsply Maillefer©, Ballaigues, Suiza), la cual expresó un 83.26% de tasa de éxito. Los resultados presentados por la CNN en esta investigación muestran la posibilidad de identificar y clasificar automáticamente un instrumento rotatorio de acuerdo a su número de usos. La capacidad de esta CNN es mayor para clasificar instrumentos nuevos y de tercer uso, y menor para clasificar instrumentos de un uso. La presencia de instrumentos fracturados durante este estudio expresa la necesidad de entrenar una CN para predecir posible fractura del instrumento. Se cree que se puede aumentar la tasa de éxito en el desempeño del algoritmo y la exactitud, obteniendo una base de datos más robusta mejorando la base de datos, cambiando el algoritmo y la adquisición de fotos de mayor calidad.

BIBLIOGRAFÍA

1. Kakehashi S, Stanley HR, Fitzgerald RJ. The effects of surgical exposures of dental pulps in germ-free and conventional laboratory rats. *Oral Surgery, Oral Med Oral Pathol.* 1965;20(3):340–9.
2. BYSTRÖM A, SUNDQVIST G. Bacteriologic evaluation of the efficacy of mechanical root canal instrumentation in endodontic therapy. *Eur J Oral Sci.* 1981;89(4):321–8.
3. Glosson CR, Hailer RH, Dove SB, Rio CE. A Comparison of Root Canal Preparations Using Ni-Ti Hand, Ni-Ti Engine-Driven, and K-Flex Instruments. *Joe.* 1995;21(3):146–51.
4. Poulsen WB, Dove SB, del Rio CE. Effect of nickel-titanium engine-driven instrument rotational speed on root canal morphology. *J Endod.* 1995;21(12):609–12.
5. Samyn JA, Nicholls JI, Steiner JC. Comparison of stainless steel and nickel-titanium instruments in molar root canal preparation. *J Endod.* 1996;22(4):177–81.
6. Melo Ribeiro MV De, Silva-Sousa YT, Versiani MA, Lamira A, Steier L, Pécora JD, et al. Comparison of the cleaning efficacy of self-adjusting file and rotary systems in the apical third of oval-shaped canals. *J Endod.* 2013;39(3):398–401.
7. Webber J, Machtou P, Pertot W, Kuttler S, West J. The WaveOne™ single-file reciprocating system. *Roots.* 2011;2(1):1–9.
8. Boreak N. Effectiveness of Artificial Intelligence Applications Designed for Endodontic Diagnosis, Decision-making, and Prediction of Prognosis: A Systematic Review. *J Contemp Dent Pract.* 2020;21(8):926–34.
9. Palareti G, Legnani C, Cosmi B, Antonucci E, Erba N, Poli D, et al.

Comparison between different D-Dimer cutoff values to assess the individual risk of recurrent venous thromboembolism: Analysis of results obtained in the DULCIS study. *Int J Lab Hematol.* 2016;38(1):42-9.

10. Alcalde MP, Duarte MAH, Bramante CM, Tanomaru-filho M, Vasconcelos BC, Só MVR, et al. Torsional fatigue resistance of pathfinding instruments manufactured from several nickel-titanium alloys. *Int Endod J*. 2018;51(6):697–704.
11. Webber J. Shaping canals with confidence: WaveOne GOLD single-file reciprocating system. *Int Dent Ed*. 2015;6(3):34–40.
12. Adıgüzel M, Capar ID. Comparison of Cyclic Fatigue Resistance of WaveOne and WaveOne Gold Small, Primary, and Large Instruments. *J Endod*. 2017;43(4):623–7.
13. Cockroft B, Burns H, Watkins R. IMPORTANT: ADVICE FOR DENTISTS ON RE-USE OF ENDODONTIC INSTRUMENTS AND VARIANT CREUTZFELDT-JAKOB DISEASE (vCJD) [Internet]. DOH. 2007. Disponible en: https://www.gov.uk/government/uploads/system/uploads/attachment_data/file/170689/HTM_01-05_2013.pdf
14. Dioguardi M, Sovereto D, Illuzzi G, Laneve E, Raddato B, Arena C, et al. Management of Instrument Sterilization Workflow in Endodontics: A Systematic Review and Meta-Analysis. *Int J Dent*. 2020;2020.
15. Azarpazhooh A, Fillery ED. Prion Disease: The Implications for Dentistry. *J Endod*. 2008;34(10):1158–66.
16. Walia H, Brantley WA, Gerstein H. An initial investigation of the bending and torsional properties of nitinol root canal files. *J Endod*. 1988;14(7):346–51.
17. Schäfer E. Relationship between design features of endodontic

instruments and their properties. Part 2. Instrumentation of curved canals. *J Endod*. 1999;25(1):56–9.

18. Millones-Gómez P, Huamaní-Muñoz W. Efectividad de la antibioticoterapia en la reducción de la frecuencia de alveolitis seca postexodoncia simple. Ensayo clínico aleatorizado de grupos en paralelo, controlado y ciego simple. *Rev Esp Cir Oral y Maxilofac*. 2016;38(4):181–7.
19. Johnson E, Lloyd A, Kuttler S, Namerow K. Comparison between a Novel Nickel-Titanium Alloy and 508 Nitinol on the Cyclic Fatigue Life of ProFile 25/.04 Rotary Instruments. *J Endod* [Internet]. 2008;34(11):1406–9. Disponible en: <http://dx.doi.org/10.1016/j.joen.2008.07.029>
20. Tabassum S, Khan FR. Failure of endodontic treatment: The usual suspects. *Eur J Dent*. 2016;10(1):144–7.
21. Ferreira F, Adeodato C, Barbosa I, Aboud L, Scelza P, Zaccaro Scelza M. Movement kinematics and cyclic fatigue of NiTi rotary instruments: a systematic review. *Int Endod J*. 2017;50(2):143–52.
22. Plotino G, Costanzo A, Grande NM, Petrovic R, Testarelli L, Gambarini G. Experimental evaluation on the influence of autoclave sterilization on the cyclic fatigue of new nickel-titanium rotary instruments. *J Endod* [Internet]. 2012;38(2):222–5. Disponible en: <http://dx.doi.org/10.1016/j.joen.2011.10.017>
23. Madarati AA, Watts DC, Qualtrough AJE. Factors contributing to the separation of endodontic files. *Br Dent J*. 2008;204(5):241–5.
24. Parashos P, Gordon I, Messer HH. Factors influencing defects of rotary nickel-titanium endodontic instruments after clinical use. *J Endod*. 2004;30(10):722–5.
25. Svec TA, Powers JM. The deterioration of rotary nickel-titanium files

- under controlled conditions. *J Endod.* 2002;28(2):105–7.
26. Alapati SB, Brantley WA, Svec TA, Powers JM, Mitchell JC. Scanning electron microscope observations of new and used nickel-titanium rotary files. *J Endod.* 2003;29(10):667–9.
 27. Li UM, Lee BS, Shih CT, Lan WH, Lin CP. Cyclic fatigue of endodontic nickel titanium rotary instruments: Static and dynamic tests. *J Endod.* 2002;28(6):448–51.
 28. LeCun1 Y. Convolutional networks for images, speech, and time series. 1998;The Handbo(MIT Press):255–258.
 29. Shoaib BF, Alshahrani2 R, Alhamdan3 M, Aldagriri4 L, Aldanah Alwoseamer5. Comparison of instrumentation time and cleaning efficacy of manual instrumentation, rotary systems in permanent teeth: A literature review. *J Adv Med Dent Scie Res* [Internet]. 2020;8(1):184–6. Disponible en: www.jamdsr.com
 30. Patel S, Brown J, Pimentel T, Kelly RD, Abella F, Durack C. Cone beam computed tomography in Endodontics – a review of the literature. *Int Endod J.* 2019;52(8):1138–52.
 31. Căpută PE, Retsas A, Kuijk L, Chávez de Paz LE, Boutsoukis C. Ultrasonic Irrigant Activation during Root Canal Treatment: A Systematic Review. *J Endod.* 2019;45(1):31-44.e13.
 32. G. LM. Cracking the Coding Interview. 2014;12(2007):15–9, 56-61.
 33. McCarthy J. Programs with common sense. *Proc Symp Mech Thought Process* [Internet]. 1963;1–15. Disponible en: <http://www-formal.stanford.edu/jmc/mcc59.ps%5Cnhttp://aitopics.org/sites/default/files/classic/TeddingtonConference/Teddington-1.3-McCarthy.pdf>
 34. Zheng L, Wang H, Mei L, Chen Q, Zhang Y, Zhang H. Artificial

intelligence in digital cariology: a new tool for the diagnosis of deep caries and pulpitis using convolutional neural networks. *Ann Transl Med.* 2021;9(9):763–763.

35. 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. *Dentomaxillofacial Radiol.* 2019;48(3):1–7.
36. Ye JC. Convolutional Neural Networks. *Math Ind.* 2022;37(Icectt):113–34.
37. Matich Damián. *Redes Neuronales: Conceptos Básicos y Aplicaciones.* Historia Santiago [Internet]. 2001;55. Disponible en: <ftp://decsai.ugr.es/pub/usuarios/castro/Material-Redes-Neuronales/Libros/matich-redesneuronales.pdf>
38. Guest O. Levels of Representation in a Deep Learning Model of Categorization. *Pap Knowl Towar a Media Hist Doc.* 2019;7(1):1–33.
39. Alom MZ, Taha TM, Yakopcic C, Westberg S, Sidike P, Nasrin MS, et al. A state-of-the-art survey on deep learning theory and architectures. *Electron.* 2019;8(3).
40. Fukushima K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biol Cybern.* 1980;36(4):193–202.
41. Matsugu M, Mori K, Mitari Y, Kaneda Y. Subject independent facial expression recognition with robust face detection using a convolutional neural network. *Neural Networks.* 2003;16(5–6):555–9.
42. Shin HC, Roth HR, Gao M, Lu L, Xu Z, Nogues I, et al. Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning. *IEEE Trans Med Imaging.* 2016;35(5):1285–98.

43. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. 3rd Int Conf Learn Represent ICLR 2015 - Conf Track Proc. 2015;1–14.
44. BARHOOM AMA, AL-HIEALY MRJ, ABU-NASER SS. Bone Abnormalities Detection and Classification Using Deep Learning-Vgg16 Algorithm. J Theor Appl Inf Technol. 2022;100(20):6173–84.
45. Elashiry MM, Saber SE, Elashry SH. Comparison of Shaping Ability of Different Single-File Systems Using Microcomputed Tomography. Eur J Dent. 2020;14(1):70–6.
46. Topçuoğlu HS, Düzgün S, Aktı A, Topçuoğlu G. Laboratory comparison of cyclic fatigue resistance of WaveOne Gold, Reciproc and WaveOne files in canals with a double curvature. Int Endod J. 2017;50(7):713–7.
47. Arens FC, Hoen MM, Steiman HR, Dietz GC. Evaluation of single-use rotary nickel-titanium instruments. J Endod. 2003;29(10):664–6.
48. Shen Y, Haapasalo M, Cheung GS pan, Peng B. Defects in Nickel-Titanium Instruments after Clinical Use. Part 1: Relationship between Observed Imperfections and Factors Leading to Such Defects in a Cohort Study. J Endod [Internet]. 2009;35(1):129–32. Disponible en: <http://dx.doi.org/10.1016/j.joen.2008.10.014>
49. Plotino G, Grande NM, Sorci E, Malagnino VA, Somma F. Influence of a brushing working motion on the fatigue life of NiTi rotary instruments. Int Endod J. 2007;40(1):45–51.
50. S Z. Mechanisms of Instrument Failure. Vol. 4, In Lambradis T, editor. Management of Fractured Endodontic Instruments. Cham: Springer International Publishing AG. 2017. 61–73 p.
51. Blanquet-Grossard F, Sazdovitch V, Jean A, Deslys JP, Dormont D, Hauw JJ, et al. Prion protein is not detectable in dental pulp from

- patients with Creutzfeldt-Jakob disease. *J Dent Res*. 2000;79(2):700.
52. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity (reprinted from bulletin of mathematical biophysics, vol 5, pg 115-133, 1943). *Bull Math Biol* [Internet]. 1990;52(1--2):99–115. Disponible en: http://journals2.scholarsportal.info/pdf/00928240/v52i1-2/99_alcottiina.xml
 53. Rumelhart DE, Hintont GE. Learning Representations by Back-Propagating Errors. *Cogn Model*. 2019;(2):3–6.
 54. Pauwels R, Brasil DM, Yamasaki MC, Jacobs R, Bosmans H, Freitas DQ, et al. Artificial intelligence for detection of periapical lesions on intraoral radiographs: Comparison between convolutional neural networks and human observers. *Oral Surg Oral Med Oral Pathol Oral Radiol* [Internet]. 2021;131(5):610–6. Disponible en: <https://doi.org/10.1016/j.oooo.2021.01.018>
 55. Fukushima K. Neocognitron: A hierarchical neural network capable of visual pattern recognition. *Neural Networks*. 1988;1(2):119–30.
 56. LECUN Y, MEMBER, IEEE L, BOTTOU E, BENGIO Y. Gradient-Based Learning Applied to Document Recognition. *Proc IEEE*. 1998;86(4):2278–324.
 57. Gao XW, Hui R, Tian Z. Classification of CT brain images based on deep learning networks. *Comput Methods Programs Biomed* [Internet]. 2017;138:49–56. Disponible en: <http://dx.doi.org/10.1016/j.cmpb.2016.10.007>
 58. Song QZ, Zhao L, Luo XK, Dou XC. Using Deep Learning for Classification of Lung Nodules on Computed Tomography Images. *J Healthc Eng*. 2017;2017.
 59. Sugimori H. Classification of Computed Tomography Images in

Different Slice Positions Using Deep Learning. J Healthc Eng. 2018;2018.

60. Zhao X, Wu Y, Song G, Li Z, Zhang Y, Fan Y. A deep learning model integrating FCNNs and CRFs for brain tumor segmentation. Med Image Anal. 2018;43:98–111.
61. Ekert T, Krois J, Meinhold L, Elhennawy K, Emara R, Golla T, et al. Deep Learning for the Radiographic Detection of Apical Lesions. J Endod [Internet]. 2019;45(7):917-922.e5. Disponible en: <https://doi.org/10.1016/j.joen.2019.03.016>
62. Bergs T, Holst C, Gupta P, Augspurger T. Digital image processing with deep learning for automated cutting tool wear detection. Procedia Manuf [Internet]. 2020;48:947–58. Disponible en: <https://doi.org/10.1016/j.promfg.2020.05.134>
63. D ANA, A MŁ. Pautas para el almacenamiento de muestras : revisión de la literatura Introducción Esterilización de dientes humanos extraídos. 2019;
64. Sandhu S V., Tiwari R, Bhullar RPK, Bansal H, Bhandari R, Kakkar T, et al. Sterilization of extracted human teeth: A comparative analysis. J Oral Biol Craniofacial Res [Internet]. 2012;2(3):170–5. Disponible en: <http://dx.doi.org/10.1016/j.jobcr.2012.09.002>
65. Nawrocka A, Łukomska-Szymańska M. Extracted human teeth and their utility in dental research. Recommendations on proper preservation: A literature review. Dent Med Probl. 2019;56(2):185–90.
66. Dominici JT, Eleazer PD, Clark SJ, Staat RH, Scheetz JP. Disinfection/Sterilization of Extracted Teeth for Dental Student Use. J Dent Educ. 2001;65(11):1278–81.
67. Salem-Milani A, Zand V, Asghari-Jafarabadi M, Zakeri-Milani P, Banifateme A. The effect of protocol for disinfection of extracted teeth

- recommended by center for disease control (CDC) on microhardness of enamel and dentin. *J Clin Exp Dent*. 2015;7(5):e552–6.
68. Aydin B, Pamir T, Baltaci A, Orman MN, Turk T. Effect of storage solutions on microhardness of crown enamel and dentin. *Eur J Dent*. 2015;9(2):262–6.
 69. Marcot BG, Hanea AM. What is an optimal value of k in k-fold cross-validation in discrete Bayesian network analysis? *Comput Stat [Internet]*. 2021;36(3):2009–31. Disponible en: <https://doi.org/10.1007/s00180-020-00999-9>
 70. Manzini JL. Declaración De Helsinki: Principios Éticos Para La Investigación Médica Sobre Sujetos Humanos. *Acta Bioeth*. 2000;6(2):321–34.
 71. Valdespino Gómez JL, García García MDL. Declaración de Helsinki. *Gac Med Mex*. 2001;137(4):391.
 72. Garcia PR, Resende PD, Lopes NIA, Peixoto IF da C, Buono VTL, Viana ACD. Structural Characteristics and Torsional Resistance Evaluation of WaveOne and WaveOne Gold Instruments after Simulated Clinical Use. *J Endod [Internet]*. 2019;45(8):1041–6. Disponible en: <https://doi.org/10.1016/j.joen.2019.04.009>
 73. Martínez-Arellano G, Terrazas G, Ratchev S. Tool wear classification using time series imaging and deep learning. *Int J Adv Manuf Technol*. 2019;104(9–12):3647–62.
 74. Twardowski P, Tabaszewski M, Felusiak-Czyryca A, Kieruj P, Wiciak-pikuła M, Czyżycki J. Identification of Tool Wear During Cast Iron Drilling Using Machine Learning Methods. *Adv Sci Technol Res J*. 2022;16(6):126–39.
 75. Hinton G. The Forward-Forward Algorithm: Some Preliminary Investigations. 2022; Disponible en:

<http://arxiv.org/abs/2212.13345>

76. Li CW, Lin SY, Chou HS, Chen TY, Chen YA, Liu SY, et al. Detection of dental apical lesions using cnns on periapical radiograph. *Sensors*. 2021;21(21).
77. Streiner DL, Norman GR. “Precision” and “accuracy”: Two terms that are neither. *J Clin Epidemiol*. 2006;59(4):327–30.
78. Camilo Pinzón. Robótica aplicada a la elaboración de un brazo robótico solucionador de SUDOKUS por medio de redes neuronales Institución Universitaria Politécnico Grancolombiano Ingeniería Industrial. Bogotá D.C., Colombia 2018 2018;6(1):1–8.
79. Abu-Mahfouz I. Drilling wear detection and classification using vibration signals and artificial neural network. *Int J Mach Tools Manuf*. 2003;43(7):707–20.
80. Frajlich S, Ballachino M. Evaluación de la superficie de un instrumento rotatorio de níquel-titanio con control de memoria en relación al número de usos. 2018;8–12.
81. Özyürek T. Cyclic Fatigue Resistance of Reciproc, WaveOne, and WaveOne Gold Nickel-Titanium Instruments. *J Endod*. 2016;42(10):1536–9.
82. Mashyakhy M, Awawdeh M, Abu-Melha A, Alotaibi B, Altuwaijri N, Alazzam N, et al. Anatomical Evaluation of Root and Root Canal Configuration of Permanent Maxillary Dentition in the Population of the Kingdom of Saudi Arabia. *Biomed Res Int*. 2022;2022.
83. Magalhães J, Velozo C, Albuquerque D, Soares C, Oliveira H, Pontual ML, et al. Morphological Study of Root Canals of Maxillary Molars by Cone-Beam Computed Tomography. *Sci World J*. 2022;2022.
84. Fangli T, Maki K, Kimura S, Nishijo M, Tokita D, Ebihara A, et al.

Assessment of mechanical properties of waveone gold primary reciprocating instruments. Dent Mater J. 2019;38(3):490–5.

85. Goldenberg PA. Minimally invasive endodontics. The 6th generation in endodontic files, Pink and Blue, in a single BlueShaper system. Canal Abierto. 2022;45:4–10.
86. Dentsply S. Sistema WaveOne Gold®. Suiza [Internet]. 2017;3–7. Disponible en: http://www.dentsplymaillefer.com/wp-content/uploads/2017/03/Dentsply_Maillefer_WAVEONE_GOLD_SYSTEM_DFU_0117_WEB_DSE_ES.pdf

ANEXO 1.- CONSENTIMIENTO INFORMADO.

	Nombre: _____ Edad: _____ Expediente Número: _____
PACIENTE: _____ No. Individual _____	
1.- Por el presente, autorizo al Dr. _____ y/o al facultativo, que él designe para que lleve a cabo el (los) procedimiento (s): _____ _____ en _____ nombre del paciente	
2.- Si surgiera cualquier circunstancia imprevisible durante el proceso que requiera, a su juicio, procedimientos adicionales o diferentes de aquellos que se contemplan en este momento, le solicito y lo autorizo para que de la manera que considere aconsejable.	
3.- El (los) procedimiento (s) indicado(s) en el párrafo 1, los riesgos que implica y la posibilidad de complicaciones, me han sido explicados por el facultativo a cargo y comprendo perfectamente la naturaleza y consecuencias del (los) procedimiento(s). Quede entendido que no se me ha garantizado ni dado seguridad alguna acerca de los resultados que puedan obtener.	
4.-Consiente que se me administre anestesia a aplicarse bajo la dirección del Dr. Responsable, así como para que se utilicen aquellas formas de anestesia que el considere semejantes.	
5.- Por el presente autorizo, para que preserve con fines científicos o didácticos o para que disponga de cualquiera otra manera de aquellos tejidos, partes u órganos extraídos como resultado de los procedimientos autorizados arriba.	
6.- Consiento para que se utilicen fotografías, películas, televisión con fines educativos o investigativos o para publicación en publicaciones científicas siempre que mi (su) nombre no sea mencionado en relación con dichos usos.	
7.- Lo que antecede me ha sido detalladamente explicado y certifico que comprendo su contenido.	
_____ Fecha _____ Hora _____	
Testigo _____ Facultativo a cargo	Firmado _____ Paciente o personal responsable
Testigo _____ Parentesco _____	

ANEXO 2. TABLA PARA RECOLECCION DE DATOS

1 ER USO LIMA WOG PRIMARY										Rx
Lima	Dr.	Nombre de Px	Edad	O.D.	Dx. pulpar	No. De conductos	LT	Fecha	Obervación	
1	Alma									
2										
3										
4										
5										
6										
7										
8										
9										
10										
11										
12										
13										
14										
15										
16										
17										
18										
19										
20										
21										
22										
23										
24										