BENEMÉRITA UNIVERSIDAD AUTÓNOMA DE PUEBLA

SECRETARÍA DE INVESTIGACIÓN Y ESTUDIOS DE POSGRADO

MAESTRÍA EN ESTOMATOLOGÍA CON OPCIÓN TERMINAL EN ORTODONCIA

TESIS

RED NEURONAL CONVOLUCIONAL PARA LA DETECCIÓN DE FACTORES PREDISPONENTES A RESPIRACIÓN BUCAL EN CBCT.

PARA OBTENER EL GRADO DE MAESTRÍA EN ESTOMATOLOGÍA
CON OPCIÓN TERMINAL EN ORTODONCIA

Presenta:
Oscar Hernández Ruiz
Matrícula: 223450007

Responsable de Tesis:
D. C. Miguel Ángel Casillas Santana
ID: 100526485

Director Disciplinario:
M.O. Yareli Hernández Ávila
ID: 100426099

Director Metodológico:
M.O. Estela del Carmen Velasco León
ID: 100225455

Asesor externo:
D.C.C. Elías Jesús Ventura Molina
Instituto Politécnico Nacional

Puebla, Pue. Mayo, 2025.

I. DICTAMEN DE APROBACIÓN DE TESIS

Oficio No. FESIEP/CIFE/074/2025

C. Oscar Hernández Ruiz
Estudiante de la Maestría en Estomatología con opción en Terminal en Ortodoncia
Matrícula No.: 223450007
Secretaría de Investigación y Estudios de Posgrado
Facultad de Estomatología
Benemérita Universidad Autónoma de Puebla
PRESENTE

Sirva este medio para enviarle un cordial saludo, asimismo, en mi doble calidad de Secretaria de Investigación y Estudios de Posgrado y Presidenta del Comité de Investigación de la Facultad de Estomatología de la Benemérita Universidad Autónoma de Puebla; aprovecho para felicitarla por el avance significativo en su proceso académico. En atención a su solicitud, me permito notificarle que su tesis titulada.

"Red neuronal convolucional para la detección de factores predisponentes a respiración bucal en CBCT",

ha recibido la aprobación oficial para su impresión.

Su trabajo ha sido registrado en el Libro de Registros No. 10, página 01, con el No. de Asignación 2025285, quedando debidamente documentado en esta Secretaría de Investigación. Esta tesis será presentada como parte del procedimiento para su examen profesional, necesario para obtener el grado de Maestría en Estomatología.

Próximos pasos:

1. *Impresión de la tesis: Proceda con los trámites de impresión conforme a los lineamientos establecidos por la Facultad.*
2. *Revisión del documento: Asegúrese de que el texto cumpla con los estándares académicos y formales.*
3. *Coordinación del examen profesional: Comuníquese con el Responsable de la Etapa Terminal de la Maestría de su elección para programar su examen de grado y gestionar los trámites administrativos correspondientes*

Le recordamos que el cumplimiento de los plazos y requisitos establecidos es fundamental para garantizar la fluidez del proceso.

Reconocimiento y mensaje final:

Este logro refleja su esfuerzo, dedicación y el impacto de su investigación en el ámbito de la Estomatología. Le felicitamos por este avance significativo y confiamos en que continuará demostrando su compromiso académico y profesional.

Para cualquier consulta o información adicional, no dude en comunicarse con nosotros. Estamos a su disposición para acompañarla en esta etapa crucial de su formación.

Sin otro particular, le reitero mi más atenta y distinguida consideración y le deseo éxito en la etapa final de esta carrera académica.

A t e n t a m e n t e
"Pensar bien, para vivir mejor"
H. Puebla de Z., a lunes 02 de junio del 2025

MEP. Gisele Nataly Rubin de Celis Quintana
Secretaria de Investigación y Estudios de Posgrado
Facultad de Estomato logía

***Nota:** Se anexa Formato de Impresión de Tesis – C. Oscar Hernández Ruiz – Maestría en Estomatología – Terminal en Ortodoncia – S.I.E.P. – Facultad de Estomatología - B.U.A.P. (origina) - p.s.c.y a.*
**C.c.p. Archivo*
**MCO. FJMA/MEP. GNRCQ/~~yaneth~~*

Secretaría de Investigación y Estudios de Posgrado
Facultad de Estomatología
31 poniente 1304, Col. Volcanes
Puebla, Pue.
C.P. 72410
Tel. Of. 22*22 29 55 00
Ext. 5526

II. AUTORIZACIÓN DE IMPRESIÓN DE TESIS

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

Para obtener el Grado de: ***Maestría en Estomatología con opción en Terminal en Ortodoncia.***

No. Registro CIFE: *2025285.* ***Fecha de Registro ante CIFE:*** *martes 06 de mayo del 2025.*

Título de la Tesis*: "Red neuronal convolucional para la detección de factores predisponentes a respiración bucal en CBCT".*

Nombre del estudiante*: Oscar Hernández Ruiz.* ***Matrícula:*** *223450007.*

Domicilio*: Blvd. Independencia 12150, dpto. D306, Fraccionamiento Haus Angelópolis, CP 72480, Heroica Puebla de Zaragoza, Pue.*

No. Cel.*: 22*21 74 76 02.* ***Fecha de ingreso a la Facultad:*** *jueves 05 de enero 2023.*

Firma: _____

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

Adscripción: *Facultad de Estomatología.* ***ID****: 100526485.* ***No. Cel.*** *44*48 46 76 45.*

Firma: _____

Director Disciplinario: *MO. Yareli Hernández Ávila.* ***Grado académico:*** *Maestría en Ortodoncia.*

Adscripción: *Facultad de Estomatología.* ***ID:*** *100426099.* ***No. Cel.*** *22*21 99 20 62.*

Firma: _____

Director Metodológico: *MO. Estela del Carmen Velasco León.* ***Grado académico:*** *Maestría en Ortodoncia.*

Adscripción: *Facultad de Estomatología.* ***ID:*** *100225455.* ***No. Cel.*** *22*23 23 48 42.*

Firma: _____

Lector: *MO. Víctor Hernández Vidal.* ***Grado académico:*** *Maestría en Ortodoncia.*

Adscripción: *Facultad de Estomatología.* ***ID:*** *100378833.* ***No. Cel.*** *22*21 74 19 16.*

Firma: _____

Nombre y firma de aprobación por parte del responsable de la Maestría en Estomatología en Terminal en Ortodoncia.

MO. Farid Alfonso Dipp Velázquez. ***Firma:*** _____

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

MEP. Gisela Nataly Rubin de Celis Quintana

Fecha oficial de emisión: *lunes 02 de junio del 2025.* ***Sello*** _____

BENEMÉRITA UNIVERSIDAD AUTÓNOMA DE PUEBLA · FACULTAD DE ESTOMATOLOGÍA · SECRETARÍA DE INVESTIGACIÓN Y ESTUDIOS DE POSGRADO · 1578

III. OFICIO DE ACEPTACIÓN DE PROYECYO C.I.F.E.

BUAP

Constancia No. FESIEP/CIFE/132/2025

DC. Miguel Ángel Casillas Santana
Director y Responsable del Proyecto de Investigación
Secretaría de Investigación y Estudios de Posgrado
Facultad de Estomatología
Benemérita Universidad Autónoma de Puebla
PRESENTE

Sirva este medio para enviarle un cordial saludo, asimismo, en mi responsabilidad conjunta de Secretaria de Investigación y Estudios de Posgrado y Presidenta del Comité de Investigación de la Facultad de Estomatología de la Benemérita Universidad Autónoma de Puebla, y tras realizar un minucioso análisis y evaluación de su proyecto de investigación (colectivo):

Nombre del Titulo del Proyecto:

"Red neuronal convolucional para la detección de factores predisponentes a respiración bucal en CBCT".

No.	Cargos	Nombres	ID y/o Matrícula
1	Director y Responsable del Proyecto de Investigación:	DC. Miguel Ángel Casillas Santana	100526485
2	Directora Disciplinaria:	MO. Yareli Hernández Ávila	100426099
3	Directora Metodológica:	MO. Estela del Carmen Velásco León	100225455
4	Asesor Externo:	DCC. Elías Ventura Molina Instituto Politécnico Nacional, Cuidad de México; México.	S'N
5	Estudiante de Maestría en Estomatología Terminal en Ortodoncia	C. Oscar Hernández Ruiz	223450007

Por este medio HAGO CONSTAR, que dicho proyecto, ha sido oficialmente ACEPTADO y registrado ante el Comité de Investigación de la Facultad de Estomatología (C.I.F.E), con los siguientes datos de registro:

- *Libro de registros No. 10,*
- *Página 01,*
- *No. de asignación 2025285*

Este asentamiento se realiza en la Secretaría de Investigación y Estudios de Posgrado de esta Unidad Académica, y queda constancia de su validez para los fines legales y administrativos que los interesados estimen pertinentes.

Sin más por el momento, reitero mi disposición para atender cualquier consulta adicional y le extiendo mi más atenta y distinguida consideración.

A t e n t a m e n t e
"Pensar bien, para vivir mejor"
H. Puebla de Z., a martes 06 de mayo del 2025

MEP. Gisela Nataly Rubin de Celis Quintana
Secretaria de Investigación y Estudios de Posgrado
Facultad de Estomatología

**C.c.p. Archivo*
**MCO. FJMA/MEP. GNRCQ/~~Yaneth~~*

Secretaría de Investigación y Estudios de Posgrado
Facultad de Estomatología
31 poniente 1304, Col. Volcanes
Puebla, Pue.
C.P. 72410
Tel. Of. 22*22 29 55 00
Ext. 5526

IV. REPORTE DE SIMILITUD ANTI PLAGIO.

Top Sources

2% Internet sources
0% Publications
10% Submitted works (Student Papers)

Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1	Student papers	
BENEMERITA UNIVERSIDAD AUTONOMA DE PUEBLA BIBLIOTECA		10%
2	Student papers	
Politécnico Colombiano Jaime Isaza Cadavid		<1%
3	Internet	
hdl.handle.net		<1%
4	Student papers	
Universidad Carlos III de Madrid - EUR		<1%
5	Internet	
dehesa.unex.es		<1%
6	Student papers	
Unviersidad de Granada		<1%

V. EVIDENCIA DE PRODUCTOS ACADÉMICOS DERIVADOS DEL PROYECTO.

AMO

ASOCIACIÓN MEXICANA DE ORTODONCIA
COLEGIO DE ORTODONCISTAS, A.C.

Otorga el presente

Reconocimiento a:

Hernández Ruiz Oscar, Casillas Santana Miguel Ángel, Ventura Molina Elías Jesús, Hernández Ávila Yareli, Velasco León Estela del Carmen, Romero Navarro María Paola

Por haber obtenido el ***PRIMER LUGAR*** con el trabajo titulado:

IDENTIFICACIÓN CON INTELIGENCIA ARTIFICIAL DE FACTORES DE RIESGO PARA APNEA OBSTRUCTIVA DEL SUEÑO EN CBCT

En la categoría Investigación modalidad E-Poster, del ***Concurso Interposgrados*** realizado en la ciudad de León Guanajuato, el día 8 de marzo de 2024.

Dr. Gabriel Amador Peña
Presidente de A.M.O

AMO | LEON

LVI CONGRESO INTERNACIONAL

SCiMed
SIMPOSIO DE CÓMPUTO INTELIGENTE EN LA MEDICINA
Instituto Politécnico Nacional
"La Técnica al Servicio de la Patria"
Centro de Investigación en Computación
Instituto Politécnico Nacional
Cómputo Inteligente
El Instituto Politécnico Nacional y
el Centro de investigación en Computación
otorgan la presente
CONSTANCIA
al:
C.D. Oscar Hernández Ruiz
Por su participación como ponente en la conferencia magistal:
Red neuronal convolucional para la detección de factores predisponentes a respiración bucal en CBCT,
en el Simposio de Cómputo Inteligente en la Medicina,
celebrado del 19 al 21 de noviembre de 2024
en las instalaciones del Centro de Investigación en Computación.
Ciudad de México, 19 de noviembre de 2024.
INSTITUTO POLITÉCNICO NACIONAL
CENTRO DE INVESTIGACIÓN EN COMPUTACIÓN
DIRECCIÓN
IPN-CIC
Dr. Juan Humberto Sossa Azuela
Director del CIC
Dr. Cornelio Yáñez Márquez
Jefe de laboratorio de Cómputo Inteligente
Dr. Antonio Alarcón Paredes
Organizador

VI. AGRADECIMIENTOS

Agradezco profundamente Dios, por haberme otorgado la sabiduría, la fortaleza y la serenidad necesarias para culminar este sueño. Su guía ha sido fundamental en cada paso del camino.

A mis padres, por ser el pilar y el mayor amor de mi vida; a mi hermano, mi cuñada y mis sobrinos, por ser mi mayor inspiración y motivación constante. Su amor me sostuvo incluso en los momentos más difíciles.

A Daniela, por ser mi apoyo incondicional durante estos dos años, por su compañía constante, por cada palabra de aliento y por estar siempre presente, aún en la dificultad o el cansancio.

A mis compañeras de maestría Dalia y Liliana, quienes se convirtieron en una segunda familia, gracias por no soltarnos nunca, por caminar juntos en esta lucha y recordarme que la amistad, unión y la empatía pueden con todo.

A la Dra. Moni, por su cercanía, su guía y por corregirnos siempre desde el cariño y el compromiso. Al Dr. Farid, nuestro coordinador, por su acompañamiento académico a lo largo del proceso. Al Dr. Casillas, por cada enseñanza y por su disposición para compartir conocimiento de manera generosa.

En especial al Dr. Elías, por su paciencia, dedicación y por haberme acompañado en cada etapa de este trabajo. Gracias por enseñarme, exigirme y sacar lo mejor de mí con respeto, entrega y humanidad.

Finalmente, a mi querida y prestigiada universidad, por brindarme una formación de excelencia, con los mejores docentes y un entorno que favorece el crecimiento profesional y personal.

A todos ustedes, gracias por ser parte de este logro.

VII. ÍNDICE GENERAL

1. RESUMEN, PALABRAS CLAVE 12
2. INTRODUCCIÓN 13
3. ANTECEDENTES 14
3.1 GENERALES 14
3.2 ESPECÍFICOS 21
4. PLANTEAMIENTO DEL PROBLEMA 24
4.1 PREGUNTA DE INVESTIGACIÓN 24
5. JUSTIFICACIÓN 25
6. HIPÓTESIS 25
7. OBJETIVOS 26
7.1 OBJETIVO GENERAL 25
7.2 OBJETIVOS ESPECÍFICOS 26
8. MATERIALES Y MÉTODOS 27
8.1 DISEÑO DEL ESTUDIO 29
8.2 POBLACIÓN Y MUESTRA 29
8.3 CRITERIOS DE SELECCIÓN 29
8.3.1 CRITERIOS DE INCLUSIÓN 29
8.3.2 CRITERIOS DE EXCLUSIÓN 30
8.3.3 CRITERIOS DE ELIMINACIÓN 30
8.4 VARIABLES 30
8.5 CONCORDANCIA Y FIABILIDAD 31
8.6 UBICACIÓN ESPACIO - TEMPORAL 31
8.7 PROCEDIMIENTOS, TECNICAS Y FUENTES DE RECOLECCIÓN 32
8.7.1 PRIMERA ETAPA – "Prueba Piloto" 32
8.7.2 SEGUNDA ETAPA – "Aumento de datos" 34
8.7.3 TERCERA ETAPA – Prueba experimental" 35
8.8 ANÁLISIS ESTADÍSTICO 39
9. RESULTADOS 40
10. DISCUSIÓN 45
11. CONCLUSIONES 50
12. BIBLIOGRAFÍA 51
13. ANEXOS 55

VIII. ÍNDICE DE TABLAS Y FIGURAS

Figura 1……15

Figura 2……18

Figura 3……20

Tabla 1……41

Tabla 2……41

Tabla 3……42

Tabla 4…….....43

Tabla 5…….....44

IX. ABREVIATURAS

CBCT. Cone Beam Computed Tomography (tomografía computarizada de haz cónico)

DICOM. Digital Imaging and Communications in Medicine (imágenes médicas digitales)

SAOS. Síndrome de Apnea Obstructiva del Sueño

AOS. Apnea Obstructiva del Sueño

HA. Hipertrofia Adenoidea

AJO-DO. American Journal of Orthodontics and Dentofacial Orthopedics (revista especializada en ortodoncia y ortopedia dentofacial de la Sociedad Americana de Ortodoncia)

IA. Inteligencia Artificial

IBM. International Business Machines (empresa tecnológica multinacional)

DL. Deep Learning (aprendizaje profundo)

CNN. Convolutional Neuronal Network (redes neuronales convolucionales)

3D. Tridimensional

TC. Computed Tomography (tomografía computarizada)

CCI. Coeficiente de Correlación Intraclase

FEBUAP. Facultad de Estomatología de la Benemérita Universidad Autónoma de Puebla

CDMX. Ciudad de México

IR. Índice de desbalance

TPc. True Positive Class (verdadero positivo)

RED NEURONAL CONVOLUCIONAL PARA LA DETECCIÓN DE FACTORES PREDISPONENTES A RESPIRACIÓN BUCAL EN CBCT.

1. RESUMEN

Introducción: La respiración bucal constituye un patrón respiratorio alterado que puede generar alteraciones dentofaciales, posturales, funcionales y sistémicas si no se identifica y trata oportunamente. La detección temprana representa un desafío clínico, particularmente cuando coexisten múltiples factores de riesgo. En este contexto, el uso de redes neuronales artificiales ofrece una alternativa diagnóstica prometedora debido a su capacidad de aprendizaje y clasificación compleja. **Objetivo:** Evaluar la exactitud de diversas arquitecturas de redes neuronales artificiales para la identificación de factores de riesgo asociados a la respiración bucal. **Materiales y métodos:** El estudio se desarrolló en tres etapas. En la primera etapa (prueba piloto) se entrenaron modelos preliminares de redes neuronales con un conjunto limitado de datos de CBCT. En la segunda etapa (aumento de datos) se expandió la base de datos incluyendo nuevas imágenes para conseguir registros adicionales, permitiendo un entrenamiento más robusto. En la tercera etapa (prueba experimental) se aplicaron los modelos entrenados con unas muestras aumentadas para validar su desempeño. Se evaluaron cinco arquitecturas de redes neuronales, siendo seleccionadas para análisis detallado aquellas con los mejores índices de exactitud y sensibilidad. **Resultados:** Las redes neuronales convolucionales evaluadas alcanzaron niveles de exactitud superiores al 89% en la clasificación de factores asociados a respiradores bucales. Los modelos presentaron un rendimiento consistente en la muestra experimental, con una precisión final del 91.28% con la red EfficentNet. El análisis se centró en las redes con mejor desempeño, dadas las características computacionales del estudio y el número de variables evaluadas. **Conclusión:** Los resultados obtenidos evidencian que las redes neuronales artificiales, en particular las redes convolucionales, constituyen una herramienta efectiva para apoyar el diagnóstico de la respiración bucal mediante el análisis de múltiples factores de riesgo. Su implementación podría optimizar el proceso diagnóstico en ortodoncia y favorecer la detección temprana de patrones respiratorios disfuncionales.

PALABRAS CLAVE

Redes neuronales convolucionales, inteligencia artificial, respiración bucal, maloclusión, facies adenoideas.

2. INTRODUCCIÓN

El diagnóstico es parte esencial y clave en el tratamiento de Ortodoncia, se ha comprobado que comenzar con un tratamiento sin un correcto diagnóstico eleva las posibilidades de fracaso, recidiva y daños irreversibles al paciente. Sin embargo, existe una gran controversia ya que muchos profesionales basan sus decisiones diagnósticas de manera subjetiva y no medible, debido a la falta de algunos protocolos interdisciplinarios. Tecnologías como la inteligencia artificial podrían ayudar a unificar criterios y protocolos de forma objetiva, ya que la inteligencia artificial ha abarcado diversas áreas de la vida diaria, el área de la salud no es una excepción y se ha visto ampliamente beneficiada de la rapidez, exactitud y ayuda en el diagnóstico o tratamiento de pacientes. Específicamente las redes neuronales convolucionales, que son un método de aprendizaje profundo para inteligencia artificial, han demostrado ser de gran ayuda en la identificación y clasificación de imágenes. Siendo ésta una de las tareas más demandantes de tiempo y concentración para los ortodoncistas a la hora de evaluar estudios de rutina como las radiografías, panorámicas, laterales de cráneo o bien las tomografías en las que normalmente se requiere una inversión considerable de tiempo y experiencia en manejo de software para poder identificar los más de 50 puntos anatómicos, esqueléticos, espacios o tejidos blandos de interés para realizar un correcto análisis, es por esa falta de tiempo o experiencia que en numerosas ocasiones se llega a omitir la revisión de ciertas áreas, tejidos y órganos que conforman la vía respiratoria, los cuales pueden ser factores predisponentes a una respiración bucal cuando se encuentran alterados causando alguna obstrucción, como es el caso de los cornetes hipertróficos, tabique desviado, adenoides hipertróficas y el volumen de la faringe reducido, el omitir la detección de estos factores ocasiona un gran sesgo en el diagnóstico y la etiología de ciertas alteraciones que terminan desembocando en patologías oclusales o craneofaciales siendo que la omisión de éstas patologías provoca que no se elimine la etiología y por lo tanto el nivel de recidiva y fracaso del tratamiento es alto. Es por eso que actualmente se han hecho esfuerzos de incorporar ayudas diagnósticas con el fin de aumentar la exactitud, rapidez y automatización de los procesos diagnósticos, siendo cada vez más común el uso de tecnología e inteligencia artificial en nuestra área para solventar estas necesidades.

3. ANTECEDENTES

3.1 GENERALES

Desde tiempos inmemorables, los dientes apiñados, con posiciones irregulares y proinclinados han sido un problema constante para gran parte de las civilizaciones, así mismo, los intentos para solucionar estos problemas se remontan como mínimo unos 1000 años a.C. Incluso, se han encontrado en excavaciones griegas y etruscas lo que parecieran ser aparatos ortodóncicos primitivos, lo cual, sugiere la relevancia de corregir estas alteraciones a través de la mayoria de civilizaciones (1).

A lo largo de la historia una gran cantidad de personajes han aportado conceptos, estudios, desarrollos e innovaciones para poder diagnosticar o tratar diferentes alteraciones de la cavidad oral, las cuales, hoy en día, conocemos como maloclusiones. Esto ha dado lugar a la creación de la primera especialidad odontológica, la Ortodoncia, la cual, es la especialidad encargada de evaluar, detectar, diagnosticar y tratar las anomalías craneofaciales, con particular énfasis en la región dentofacial (1). Fue a través de esta serie de evoluciones constantes que surgió la ortodoncia contemporánea, que, a diferencia de las primeras soluciones ortodóncicas, dejó de tener como objetivo principal enfocarse únicamente en el problema dental o esqueletal evidente, al poner mayor énfasis en descubrir la etiología que causó dichos problemas y poder erradicarla, para posteriormente corregir la secuela de esa etilogía, la cual se ve reflejada en un problema dental o esqueletal (1).

A lo largo del tiempo, esta constante mejoría en el enfoque ha permitido y demostrado una necesaria cooperación multidisciplinaria entre varias especialidades odontológicas e inclusive médicas, para el abordaje de los tratamientos. Entre ellas, se encuentra la especialidad en Otorrinolaringología, la cual, mantiene una estrecha relación con la especialidad en Ortodoncia, pues se ha observado que el trabajo multidisciplinario entre estas especialidades puede resolver las secuelas de problemas originados en espacios anatómicos compartidos, además de diagnosticar y tratar algunas afecciones. De esta manera, existe un punto de convergencia muy importante entre ambas especialidades, ya que el estudio de la vía respiratoria superior ha demostrado que los tratamientos de cada especialidad se complementan para un mejor pronóstico y resultado clínico (2).

Se define como vía respiratoria superior a una compleja área anatómica, que lleva un trayecto desde las fosas nasales anteriores hasta la laringe, en ese trayecto se encuentra la nariz, cornetes, tabique nasal, los senos paranasales, el velo del

paladar, el oído medio, la faringe, las adenoides, la laringe, la lengua y las estructuras amigdalares (3) (Figura 1).

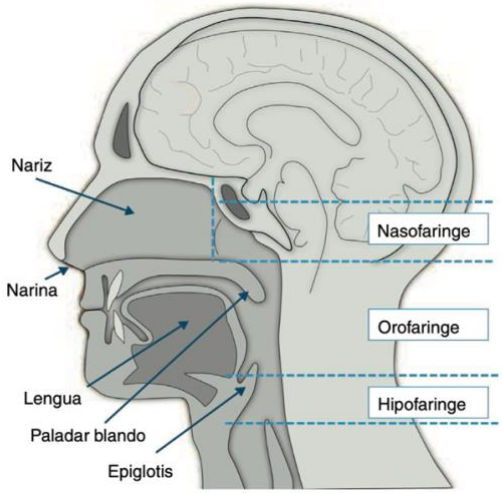

Figura 1. Anatomía de la vía respiratoria superior

Tomado de: Ferré A, Vila et al.. Utilidad de la exploración básica de la vía aérea superior y estructuras vecinas en los pacientes adultos con síndrome de apnea-hipopnea obstructiva del sueño. Med Clin (Barc). 2014;142(7):310-6. (4).

En la vía respiratoria superior, en el área de la nasofaringe, se encuentran algunos órganos claves para la adecuada respiración nasal: los cornetes, ubicados en las paredes internas de la cavidad nasal, tienen 3 pares de huesos largos delgados cubiertos con tejido, se encargan de calentar y humidificar el aire, sin embargo, en presencia de alteraciones de crecimiento o alergias pueden hipertrofiarse, y dificultar el paso del aire, el tabique nasal que forma la pared que divide a las fosas nasales, está conformado de cartílago y hueso, los cuales ante algún trauma, alteraciones de función o crecimiento pueden deformarse y desviarse de su forma recta para causar una obstrucción en la fosa nasal, por último tenemos a las adenoides, las cuales se definen como un componente linfoide del anillo faríngeo, que están situadas en la superficie posterior y superior de la nasofaringe. El tamaño de las adenoides aumenta durante la infancia y puede duplicarse en la edad adulta creando un patrón de crecimiento característico. Además, según el estado físico, las adenoides suelen aumentar su tamaño a los 6 años e involucionar a los 10 años. Sin embargo, las infecciones persistentes de las vías respiratorias superiores, alergias o algunos hábitos pueden provocar su hipertrofia, la cual, se considera una condición patológica, por lo que mantendrá la hipertrofia adenoidea hasta la adultez. En la orofaringe e hipofaringe también existen órganos de tejido blando que pueden provocar un colapso o disminución del tamaño de la vía aérea lo que dificulta el paso del aire, las alteraciones de estos órganos clave pueden reducir el paso del

aire en todo el trayecto de la vía aérea y convertirse en los factores predisponentes para respiración bucal (5).

Dichas hipertrofias, desviaciones y obstrucciones tienen múltiples y diversas repercusiones en los pacientes que la padecen, por ejemplo, son una de las causas más frecuentes de obstrucción de las vías respiratorias superiores, la cual es un factor predisponente a respiración bucal y/o el síndrome de apnea obstructiva del sueño (SAOS) (6,7). La SAOS se considera una patología con poco tiempo de descubrimiento que se caracteriza por un aumento prolongado en la resistencia al paso del aire a través de la vía aérea, ya sea por una obstrucción parcial o completa a cualquier nivel de la vía aérea superior. Esta obstrucción hace que se interrumpa la ventilación pulmonar y la oxigenación, por lo que la calidad del sueño es deficiente. Así mismo, sucede de forma más aguda durante el periodo de sueño profundo. Por otra parte, se ha reportado que, la obstrucción crónica de las vías aéreas también tiene efectos indeseados en el sistema cardiovascular, anomalías en el crecimiento del maxilar y/o desarrollo craneofacial, anomalías neuroconductuales, además de propiciar cuadros de inflamación perisistentes a lo largo de la vía aérea (8).

Debido a esto, se ha demostrado que, la adenotonsilectomía, definida como la remoción de las adenoides hipertróficas, la septoplastía, que es la corrección quirúrgica de la desviación del tabique nasal, la turbinoplastía, definida como la remoción del tejido hipertrófico en los cornetes nasales (realizadas por Otorrinolaringólogos o Cirujanos Maxilofaciales) así como la expansión maxilar asistida por mini implantes o el avance mandibular asistida por un dispositivo de reposicionamiento (realizada por un Ortodoncista), se consideran como algunos de los principales tratamientos de elección para la SAOS y para tratar la respiración bucal cuando es ocasionada por hipertrofias y/o desviaciones, ya que al tratar o mejorar la etiología de la obstrucción, se logra una considerable desobstrucción de la vía aérea. Sin embargo, está demostrado que existe una baja frecuencia de realización de estos tratamientos con el fin de mejorar o erradicar la respiración bucal debido a la omisión del diagnóstico de los factores de riesgo, de igual manera se ha observado que el tratamiento de ortodoncia puede complementarlos al corregir las secuelas dento-craneo-faciales de la respiración bucal, entre las cuales se encuentran la falta de desarrollo tranversal o protrusión del maxilar, apiñamiento dental, incompetencia labial, perfil indeseable, ojeras, etc. A estas secuelas se les conoce como facies adenoideas. De igual manera, se ha demostrado que tratar de eliminar las facies adenoideas únicamente con tratamiento ortodóncico sin recibir tratamiento integral previo, arroja resultados poco satisfactorios con altos índices de recidiva ortodóncica debido a que la etiología de la respiración bucal sigue presente, lo que provoca diversas alteraciones y secuelas (2, 9, 10).

Las características clínicas, morfológicas y las patologías otorrinolaringológicas que causa la obstrucción de las vías respiratorias en cualquiera de los órganos claves son muy similares entre niños y adultos, incluso si la etiología se encontrara en las adenoides, que se espera que involucionen antes de llegar a la adultez, esto no siempre sucede y existe un gran número de población adulta que vive con HA (11). Por lo tanto, es de vital importancia hacer una detección oportuna y accesible de las hipertrofias, desviaciones y obstrucciones que son factores predisponentes a respiración bucal tanto en niños como en adultos. Sin embargo, el reciente descubrimiento de estas patologías, la poca información, difusión sobre las mismas vuelve difícil la detección temprana, la cual podría ayudar a evitar las alteraciones o secuelas antes mencionadas, así como también, evitaría la realización de tratamientos ortodóncicos poco exitosos con alta incidencia de recidiva. Respecto a esto, se ha observado que la población tiene un alto grado de desconocimiento de estas patologías, ya que generalmente su diagnóstico se hace por casualidad cuando el paciente es sometido a estudios de imagen como la Cone Beam Computed Tomography (CBCT por sus siglas en inglés), la cual, se considera uno de los estudios indispensables y el “Gold Standard” para la realización de un diagnóstico Ortodóncico de calidad y exacto. Este estudio ha demostrado un muy buen desempeño en la toma de medidas cuantitativas de todos los órganos clave de la vía aérea, así como la clasificación objetiva de su tamaño, de acuerdo con una revisión sistemática publicada en la AJO-DO (11,12).

A pesar de que, la CBCT no es el auxiliar diagnóstico considerado como “Gold Standard” para la detección de la apnea obstructiva del sueño (como lo es la polisomnografía), tiene como ventaja que, es el estudio que más se utiliza en el diagnóstico y manejo de pacientes candidatos a ortodoncia por su fácil acceso, alta precisión en la detección, así como para evaluar los resultados de los tratamientos quirúrgicos a través de ciertas medidas (Figura 2). Que, a diferencia de la polisomnografía, no identifica el lugar de la obstrucción ni predice los resultados quirúrgicos (13,14).

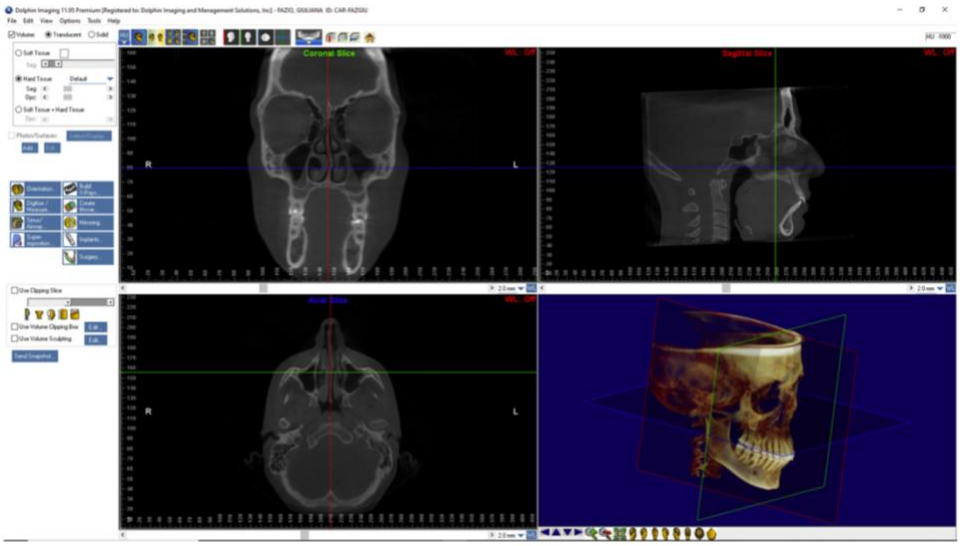

Figura 2. Vistas sagital, axial y coronal en CBCT de la vía aérea (En donde se encuentran los órganos que pueden ser factores de riesgo a respiración bucal)

Tomado de: Leonardi R, et al. Fully automatic segmentation of sinonasal cavity and pharyngeal airway based on convolutional neural networks. Am J Orthod Dentofacial Orthop. 2021;159(6):824-35.e1 (15).

La CBCT permite detectar el tamaño de los órganos claves a través de mediciones cuantitativas, sin embargo, este proceso conlleva demasiado tiempo, ya que se deben etiquetar diversos puntos anatómicos, además de requerir de cierta experiencia por parte del ortodoncista u operador, aunado a que, el número de ortodoncistas es reducido en comparación a la cantidad de pacientes, es por eso que es urgente y de vital importancia desarrollar un método automatizado asistido por algún tipo de tecnología o inteligencia artificial, que sea exacto y más rápido en detectar la condición de estos órganos clave (16).

Así mismo, se ha observado que la tecnología avanza a un nivel impresionante, genera nuevas mejoras en productos o utensilios ya conocidos, innovadoras aplicaciones, actualizaciones e incluso creaciones que hace algunos años solamente estaban en la imaginación. Estos avances se deben en gran medida a toda la información que ahora se tiene y que es relativamente de fácil acceso. En los últimos 50 años se ha generado más información que en los 5000 años anteriores; en este sentido es importante e incluso indispensable conocer los nuevos medios de acceso a las fuentes de información, pero aún mucho más relevante aprovechar todos los beneficios y ventajas que ofrece el acumulo de información (17).

Gracias a todos los nuevos conocimientos, en la actualidad, existen diferentes herramientas tecnológicas que buscan simplificar las tareas cotidianas aplicables

en distintos campos de la actividad humana, incluido el área de la salud (18). Desde hace más de 20 años, la odontología, ha aceptado como parte de su innovación, el uso de la tecnología, desde que se decidió empezar con algo tan sencillo como el uso de una computadora para facilitar algunas actividades de la práctica profesional, como la organización y almacenamiento de datos de los pacientes, administración financiera, gestión de citas y hasta algo tan complejo como lo es la planificación de un tratamiento (19).

El uso y progreso de la tecnología ha dado pie a lo que hoy en día se conoce como inteligencia artificial (IA) que, en el año de 1956, algunos investigadores de las Universidades de Darthmouth, Harvard, International Business Machines (IBM) y del Instituto de Telefonía aceptaron dicho término como un campo académico. De igual forma, Aristóteles, fue uno de los primeros en hablar acerca de la posibilidad de sistematizar el pensamiento humano y es ahí precisamente donde radica la diferencia entre tecnología e inteligencia artificial (20).

El término "inteligencia artificial" (IA) se refiere a la inteligencia mostrada por máquinas que pueden imitar la cognición y el comportamiento humanos (21). La inteligencia artificial busca sustituir de cierta manera la intervención humana, al lograr que, mediante una serie de algoritmos, sea capaz de realizar tareas igual o mucho mejor, mientras que la tecnología, por su parte, reconoce la necesidad de que sea manipulada por un ser humano (20).

En el ámbito de la salud, surge una interrogante, ¿Es posible en un futuro cercano que la inteligencia artificial sea indispensable para la toma de decisiones o incluso responsable de algunos tratamientos o diagnósticos? Específicamente, la odontología se ha beneficiado con su uso al momento de analizar conjuntos de imágenes, por ejemplo, un programa puede entender la espacialidad y escala entre los pixeles, la organización de la base de datos con elementos parecidos para así segmentar la información, imitar la lógica de un experto en el área para la toma de decisiones, y hacer predicciones finales en un tratamiento (22).

La odontología en general ha aprovechado todos estos avances para perfeccionarse en cada una de las ramas de ésta; al mostrar innovaciones que facilitan y modernizan la manera de atender a los pacientes. En la ortodoncia, específicamente, hay un aumento increíble en el uso y desarrollo de la inteligencia artificial que, como consecuencia, permite simplificar algunas tareas, así como el incremento del acierto en la elección de tratamiento, lo que genera, a su vez, hacer más predecible la práctica clínica (23).

Al hablar de inteligencia artificial en la ortodoncia, existen muy pocos antecedentes de su incorporación sin embargo las redes neuronales tienen una gran influencia en los avances tecnológicos e incorporaciones; Dichas redes neuronales buscan imitar las interacciones neuronales que se llevan a nivel cerebral al relacionar cada conexión o sinapsis que ocurre con una fórmula matemática específica (24). Su función se basa en una serie de capas (mínimo 3), una de entrada, una capa oculta y una de salida. Fue en el año 2000 cuando se empezaron a utilizar algoritmos más complejos con nuevos métodos de aprendizaje y redes neuronales de múltiples capas, por lo que se le dio el nombre de “aprendizaje profundo” (Deep Learning) (24).

El aprendizaje profundo es un tipo de técnica de aprendizaje automático que hace uso de operaciones matemáticas de capacidad múltiple para el aprendizaje automatizado y la inferencia de conjuntos de datos complejos, como las imágenes. Las estructuras de aprendizaje profundo, como las redes neuronales convolucionales (CNN), se han utilizado ampliamente para la clasificación automática de imágenes (Figura 3). Por lo tanto, podrían ser una excelente herramienta para automatizar el proceso de la detección de los factores de riesgo en una CBCT (21).

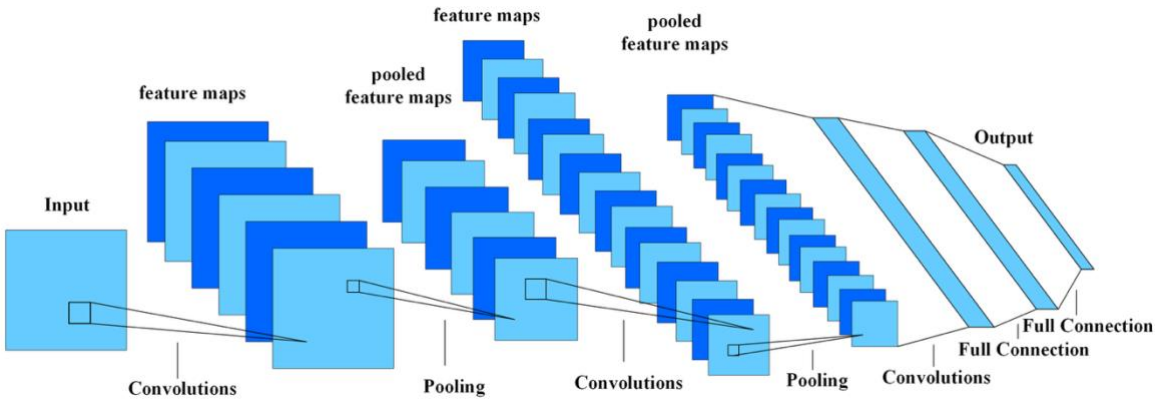

Figura 3. Esquema de la red neuronal convolucional y sus capas.
Tomada de Yang J. A New Improved Learning Algorithm for Convolutional Neural Networks. Processes. 2020; 1(8); 295.

Diversos investigadores, han intentado que la planificación del tratamiento de ortodoncia sea más objetivo mediante métodos de predicción, ya que los ortodoncistas pueden tener distintos caminos o criterios a seguir en un caso específico. Así mismo, la planificación del tratamiento de ortodoncia basado en las redes neuronales artificiales de multicapa permite determinar si es pertinente realizar extracciones o no y en caso de que, si sean necesarias, qué patrones de extracciones y qué tipo de anclaje será necesario. La red neuronal abre un

panorama de posibles tratamientos que dan flexibilidad en la toma de decisiones. Los modelos de redes neuronales han mostrado una exactitud del 94% para la predicción de extracción - no extracción, un 84.2% de los patrones de extracción y una exactitud del 92.8% de los anclajes; estos resultados demuestran que el plan ortodóncico basado en las redes neuronales artificiales es una buena guía para facilitar la toma de decisiones de los ortodoncistas menos experimentados o de estudiantes enfocados a esta área (26).

Como ya se ha explicado, para el diagnóstico y planificación del tratamiento de ortodoncia se utiliza la CBCT como un “Gold Standard” que, aunque es un sistema innovador, requiere un rastreo manual de puntos de referencia individuales, conocimiento en el manejo del visor, en el cual, pueden generarse errores, además de requerir mucho tiempo en su realización. Por lo que la incorporación de una red neuronal convolucional puede proporcionar un sistema de diagnóstico exacto y robusto. Estas redes han demostrado estadísticas prometedoras al realizar diagnóstico en ortodoncia, más del 90% de sensibilidad, especificidad y exactitud para el diagnóstico esquelético vertical, coronal y sagital; de esta manera, el uso de una red neuronal convolucional demuestra ser una ayuda potencial para el diagnóstico en ortodoncia al evitar pasos intermedios que necesitan procedimientos complicados (27).

Ortodoncistas y Cirujanos Maxilofaciales utilizan de manera regular los puntos cefalométricos en imágenes tridimensionales de las CBCTs para analizar deformidades dentofaciales y para la planificación de cirugías ortognáticas. La inteligencia artificial ha permitido encontrar modelos prometedores con la función de detectar de manera automática los puntos de referencia 3D, con buena robustez. Para la mayor parte de los profesionales es una tecnología que no se tiene a la mano por lo que sigue siendo indispensable que operadores altamente capacitados sean quienes lo realizan manualmente (28).

3.2 ESPECÍFICOS

Debido a la naturaleza del estudio en el área de la inteligencia artificial que aún es muy nueva en la Odontología y en la Ortodoncia, existen muy pocos estudios que antecedan la detección de los factores de riesgo en conjunto como lo haremos en este estudio, sin embargo, comienza a existir la incorporación de inteligencia artificial en la localización automatizada de puntos anátomicos, especificamente cefalométricos en CBCT, asi como estudios que utilizan la segmentación automatizada de la vía aérea y algunos otros estudios relacionados con el análisis del volumen de la vía aérea en CBCT, siendo estos estudios de los pocos que llegan

a tener similitudes con nuestro proyecto de investigación de los cuales analizaremos a continuación.

En el año 2021, Leonardi y cols. utilizaron un modelo de redes neuronales convolucionales para segmentar las vías aéreas con una alta precisión, al utilizar un total 40 CBCT (de 20 de mujeres y 20 de hombres) que fueron previamente trazadas por expertos de forma manual y de las cuales se escogieron 20 de ellas al azar para entrenar al archivo del modelo de inteligencia artificial y otras 20 para probar la presición del modelo totalmente automático de CNN al comparar los volúmenes de segmentación de los modelos tridimensionales obtenidos con las segmentaciones automáticas y manuales. Además, se utilizó la prueba T de Student independiente para la comparación volumétrica entre grupos. En cuanto a los resultados, se encontró una diferencia media de 1,93 ± 0,73 cm3 entre las metodologías, la cual no fue estadísticamente significativa ($p > 0,05$) por lo que se comprobó que el nuevo método basado en el aprendizaje profundo para la segmentación automatizada de la cavidad sinunasal y las vías respiratorias faríngeas en las exploraciones de CBCT es preciso y funciona igual de bien como si la segmentación la hiciera un lector de imágenes experimentado (15).

En el año 2021, Shujaat S et al., utilizaron 103 CBCT para medir el rendimiento del modelo CNN 3D basado en aprendizaje profundo para la segmentación automática del espacio de la vía aérea faríngea, agruparon los datos en: conjunto de entrenamiento, conjunto de prueba y conjunto de validación. El modelo CNN 3D logró identificar la región segmentada con una precisión y una recuperación óptimas. La diferencia máxima entre la segmentación automática y la realidad fundamental fue de 0,98 ± 0,74 mm. El modelo 3D U-Net propuesto ofreció un método preciso para la segmentación de las vías respiratorias a partir de imágenes de TC/CBCT (29).

En el año 2021, Park et al., utilizaron 315 CBCT para evaluar la precisión de la medición del volumen de las vías respiratorias mediante un modelo de aprendizaje profundo basado en redes neuronales de regresión. El volumen total fue el valor del coeficiente de correlación intraclase (CCI) más correlacionado en la orofaringe (0,986), seguido de la hipofaringe (0,964) y la nasofaringe (0,912). La pendiente de las dos mediciones fue cercana a 1 y mostró una correlación de regresión lineal ($r^2 = 0,975$, pendiente = 1,02, $p < 0,001$). Estos resultados indican que la segmentación completamente automática de las vías respiratorias es posible mediante el entrenamiento mediante aprendizaje profundo de inteligencia artificial (30).

En el año 2022, Orhan K et al., utilizaron 200 CBCT de 3 tomógrafos diferentes, para validar un algoritmo de detección automática de la vía aérea faríngea con datos

de CBCT mediante un software de IA para pacientes con SAOS. Validaron el sistema de inteligencia artificial recientemente desarrollado en comparación con el software comercial Diagnocat para la evaluación de CBCT 3D. Sin embargo no se observaron diferencias estadísticamente significativas entre las mediciones realizadas con la técnica manual y las realizadas con Diagnocat en todos los grupos ($p > 0,05$). Los coeficientes de correlación interclase fueron de 0,954 para la segmentación manual y automática, de 0,956 para Diagnocat y la segmentación automática, y de 0,972 para Diagnocat y la segmentación manual. Se observó que el algoritmo DC también mide el volumen de la epiglotis y el volumen de la abertura nasal posterior debido al bajo contraste de tejidos blandos en las imágenes CBCT; esto conlleva valores más altos en la medición del volumen de la vía aérea. Contar con esta posible colaboración para los pacientes con SAOS reduciría significativamente el esfuerzo y el tiempo necesarios para el diagnóstico inicial y el seguimiento de estos pacientes (31).

En el año 2022, Dot, G et al. realizaron un estudio con el objetivo de entrenar y evaluar una tubería de aprendizaje profundo basada en Spatial Configuration-Net, con la intención de poder localizar de manera automática 33 puntos de referencia en cefalometrías tridimensionales en escaneos de tomografías computarizadas. La comparación entre los datos de referencia y las predicciones permitió evaluar el modelo atlas y algoritmos de aprendizaje profundo utilizados en el estudio, se evaluó la exactitud de la localización, las medidas cefalométricas y la robustez o reproducibilidad de los 33 puntos de referencia que se hicieron manualmente. Los resultados indicaron que, aún existen mejoras que deben aplicarse a este método que utiliza el aprendizaje profundo, sin embargo, se logró la localizacion altamente exacta de puntos de referencia 3D con una credibilidad para la evaluación esquelética similar con lo que obtienen los médicos (32).

A pesar de que la inteligencia artificial y las redes neuronales convolucionales pueden segmentar perfectamente la vía aérea, existen algunos problemas que pueden entorpecer o complicar el proceso, entre los más significativos se encuentran tres: el primero se debe a que, la vía aérea, es un área sumamente compleja al estar integrada por muchos órganos, los modelos desarrollados hasta ahora no indican el órgano u órganos especificos que ocasionen la obstrucción y necesiten tratamiento, el segundo, es que la mayoría de los estudios se realizan en reconstrucciones o segmentaciones 3D que como esta reportado tienen cierto sesgo a diferencia de los cortes tomográficos en donde las medidas son completamente exactas, el tercero y último surge por la cantidad de tiempo que se debe emplear al análisis de la vía aérea debido al expertis que requiere el uso de software y medición de cada órgano (15,16).

4. PLANTEAMIENTO DEL PROBLEMA

La escaza detección de las hipertrofias de cornetes o adenoides, desviaciones del tabique y poca permeabilidad en la vía aérea han provocado que gran parte de la población no sepa que está enferma, ni las posibles alteraciones que puede ocasionar la respiración bucal en su desarrollo craneofacial, en su salud sistémica o a nivel oclusal.

La falta de acceso a métodos diagnósticos exactos, el requerir mucho tiempo en los trazados y la complejidad de la detección de los factores de riesgo hacen que surja la necesidad de desarrollar un método que sea automatizado y al mismo tiempo asistido por algún tipo de inteligencia artificial, que sea más exacto, más rápido en detectar los factores de riesgo a respiración bucal y que adicionalmente se pueda realizar a partir de cortes tomográficos en lugar de reconstrucciones o segmentaciones 3D debido al sesgo que pueden tener respecto a los cortes.

Las estructuras de aprendizaje profundo, como las redes neuronales convolucionales (CNN), se han utilizado ampliamente para la clasificación automática de imágenes y por lo tanto podrían ser una excelente herramienta para automatizar el proceso de la detección de los factores de riesgo en una CBCT.

La clasificación esquelética, así como el diagnóstico y la planificación del tratamiento ortodóntico, suelen requerir el uso de CBCT. Sin embargo, este proceso de análisis implica el rastreo manual de múltiples puntos de referencia anatómicos (más de 50 en muchos casos), lo que no solo incrementa significativamente el tiempo requerido para su realización, sino que también puede introducir errores inherentes al procedimiento manual.

Sumado a que la cantidad de ortodoncistas no es proporcional a la cantidad de pacientes surge la necesidad de desarrollar un método que sea automatizado y al mismo tiempo asistido por algún tipo de inteligencia artificial, que sea más exacto, rápido en detectar los factores de riesgo y por lo tanto la respiración bucal. Por lo que la incorporación de una red neuronal convolucional puede proporcionar un sistema de diagnóstico automatizado, exacto y robusto.

4.1 PREGUNTA DE INVESTIGACIÓN

¿Es posible detectar a través de una Red Neuronal Convolucional los factores predisponentes a respiración bucal a partir de CBCT?

5. JUSTIFICACIÓN

El diágnostico es una parte fundamental en la atención de los pacientes de Ortodoncia, por muchos años se ha omitido el diagnóstico integral, multidisciplinario y con un enfoque en la etiología más allá de lo dental o esquelético. Se ha demostrado que el no erradicar o mejorar la etiología que causa las alteraciones creaneofaciales o maloclusales conduce al fracaso, recidiva o empeoramiento de la condición del paciente. Por lo tanto se pretende aprovechar todos los auxiliares diagnósticos al máximo. Al contemplar que la vía respiratoria superior es sumamente complicada y es un espacio tridimensional, el estudio se concentra especificamente en cada uno de los órganos clave que pueden ser factores de riesgo, para descifrar si hay obstrucción de la vía respiratoria superior y centrarse en un órgano u órganos especificos a tratar o mejorar previo a la ortodoncia.

Así mismo se sabe que la CBCT es altamente precisa para detectar los factores de riesgo previamente mencionados, al ser un estudio indispensable y “Gold Standard” en un tratamiento de ortodoncia facilita la posibilidad de adquirirlo y aprovecharlo por la mayoría de los pacientes candidatos a ortodoncia. Otra de las ventajas que tiene es que, al enfocarse en los los factores de riesgo, brinda la oportunidad de hacer una detección oportuna de una de las principales patologías como lo es la SAOS (Síndrome de Apnea Obstructiva del Sueño) sin arriegarse a la omisión de la detección del diagnóstico por falta de entrenamiento humano o tiempo para diagnosticar cada uno de los órganos clave.

6. HIPÓTESIS

Hi: Las Redes Neuronales Convolucionales permiten detectar los factores predisponentes a respiración bucal a partir de CBCT.

Ho: Las Redes Neuronales Convolucionales no permiten detectar los factores predisponentes a respiración bucal a partir de CBCT.

7. OBJETIVOS

7.1 OBJETIVO GENERAL

Evaluar si la Red Neuronal Convolucional puede detectar con exactitud los factores predisponentes a respiración bucal a partir de CBCT.

7.2 OBJETIVOS ESPECÍFICOS

- Crear una base de datos con 1400 cortes que tengan factores predisponentes a respiración bucal y con 1400 cortes que no los tengan a partir de CBCT.
- Entrenar a una Red Neuronal Convolucional para que sea capaz de detectar los cambios físicos en los órganos claves y en la vía aérea que predispongan a respiración bucal a partir de CBCT, a partir de los siguientes procesos:

1. Correr la fase de entreamiento.
2. Correr la fase de validacion.
3. Correr la fase de prueba.

- Evaluar a través de la matriz de confusión la medida de rendimiento:

1. Exactitud.
   Con los resultados de la medida de rendimiento se desarrola un calculo matemático con una fórmula específica para la exactitud, para así poder establecer si es posible reconocer con exactitud a partir del entrenamiento de una Red Neuronal Convolucional los órganos clave que son factores de riesgo a respiración bucal.

8. MATERIALES Y MÉTODOS

En el campo de la computación y la inteligencia artificial se presenta un formato y estilo de redacción científica distinto al utilizado en el campo de la salud. Por lo tanto, para adherirse a este formato, la siguiente sección describirá los 5 tipos de redes neuronales convolucionales que se evaluarán con el algoritmo para llevar a cabo la detección de factores de riesgo a respiración bucal.

REDES NEURONALES CONVOLUCIONALES

Las redes neuronales convolucionales (CNN, por sus siglas en inglés) fueron introducidas por Yann LeCun y colaboradores en 1998, y describen un conjunto particular de redes neuronales profundas que emplean filtros de convolución para llevar a cabo el aprendizaje y la extracción de características. La red se compone de varias capas, cada una con una función específica, incluyendo una capa de convolución, una capa de agrupamiento y una capa completamente conectada. Una vez que la CNN completa la fase de aprendizaje y está entrenada, cada filtro se encarga de reconocer una característica de la entrada, y los filtros se reutilizan a lo largo de la imagen, lo que reduce el número de parámetros. La concatenación de capas de filtros genera la habilidad de identificar características no lineales; como resultado, la CNN profunda puede descubrir y clasificar conceptos complejos (33).

LeNet

Es una de las primeras arquitecturas de redes neuronales convolucionales, desarrollada en la década de 1980, y se utiliza principalmente para la clasificación de imágenes. Su arquitectura es relativamente simple en comparación con las redes más modernas, y consta de varias capas que incluyen capas convolucionales, capas de submuestreo (pooling) y capas completamente conectadas. Las capas convolucionales son fundamentales, ya que aplican filtros que ayudan a extraer características de las imágenes, como bordes y texturas (34).

Además, LeNet incorpora capas de submuestreo, que reducen la dimensionalidad de las características extraídas, lo que disminuye la carga computacional y hace que la red sea más robusta ante pequeñas variaciones en las imágenes. En cuanto a las funciones de activación, utiliza funciones como la sigmoide o la tangente hiperbólica en las capas ocultas, aunque en versiones más modernas se prefieren funciones como ReLU. Al final de la red, se encuentran capas completamente conectadas que combinan las características extraídas para realizar la clasificación final (34).

LeNet fue uno de los primeros modelos en implementar el algoritmo de retropropagación para el entrenamiento, lo que permite ajustar los pesos de la red en función del error de salida. Originalmente, esta red fue diseñada para la clasificación de dígitos manuscritos, como en el conjunto de datos MNIST, pero su arquitectura ha influido en el desarrollo de redes más complejas. A pesar de su poca profundidad en comparación con las redes neuronales modernas, LeNet es fundamental en la historia del aprendizaje profundo y ha sentado las bases para el avance de arquitecturas más avanzadas (34).

ResNet

Es una red neuronal convolucional conocida por ganar la competencia llamada ImageNet en 2015; se utiliza principalmente para llevar a cabo la clasificación de imágenes. Este tipo de red neuronal profunda tiene la capacidad de resolver el problema de la desaparición de gradientes en modelos de aprendizaje con muchas capas en redes convolucionales profundas. La arquitectura de este modelo permite implementar cientos o incluso miles de capas y, aun así, logra un rendimiento convincente. Se descubrió que más allá de cierta profundidad, el rendimiento se deteriora. Para asegurar que la información no se pierda durante la retropropagación, los autores diseñaron una arquitectura particular que implementa conexiones residuales. La estructura de la red está organizada en varios bloques, cada uno compuesto por dos o tres capas de convoluciones, asociadas a una capa de normalización por lotes y una activación ReLU. Por lo tanto, el apilamiento de estos bloques permite la construcción de modelos de aprendizaje convolucional más profundos al reducir el efecto del gradiente de fuga. Se han propuesto diversas arquitecturas ResNet en las que cada bloque utiliza dos convoluciones para modelos menos profundos, como ResNet18 o ResNet34, o tres convoluciones para uno más profundo, como ResNet50, ResNet101 y ResNet152 (35).

VGG19 Y VGG16

Son arquitecturas que fueron descritas por Simonyan y colaboradores, y se han utilizado con éxito en el conjunto de datos ImageNet. Este modelo ofrece una contribución única en comparación con otras redes neuronales al incrementar la profundidad de la red neuronal convolucional mediante el uso de filtros de convolución de 3 por 3. Generalmente, esta arquitectura se organiza en cinco bloques de convoluciones, intercalados con capas de "max pooling", y finaliza con un bloque de clasificación compuesto por capas densamente conectadas. VGG16 destaca por su notable capacidad para extraer características, lo que le permite lograr un buen rendimiento en la clasificación de imágenes. Se ha conseguido mejorar considerablemente la arquitectura al aumentar la profundidad a 16 o 19

capas de peso. Los modelos de VGG varían según el número de capas que presentan en la convolución, ya sea VGG16 o VGG19 (36).

Efficient Net

EfficientNet es una arquitectura de red neuronal profunda que ha sido diseñada para optimizar tanto la precisión como la eficiencia computacional. A través de un enfoque sistemático de escalado, EfficientNet utiliza una combinación de técnicas de optimización para ajustar de manera equilibrada las dimensiones de la red, como la profundidad, el ancho y la resolución de entrada, con el objetivo de mejorar el rendimiento sin aumentar significativamente los costos computacionales. Esta arquitectura ha demostrado un desempeño superior en comparación con modelos previos, logrando resultados de vanguardia en varias tareas de visión por computadora, mientras mantiene una eficiencia computacional notablemente alta (37).

8.1 DISEÑO DEL ESTUDIO

Estudio *in silico,* transversal y retrospectivo.

Los resultados de los hallazgos de predicción y de la simulación *in silico,* se realizarán a partir del porcentaje de rendimiento de sensibilidad, exactitud y especificidad.

8.2 POBLACIÓN Y MUESTRA

El tipo y número de muestra se elegirá con base a los métodos que utiliza la IA para entrenar los algoritmos y se definió de la siguiente manera:

Grupo 1: 1400 cortes de CBCT **con** factores predisponentes.
Grupo 2: 1400 cortes de CBCT **sin** factores predisponentes.

Que se obtendrán a través de 32 CBCT proporcionadas de la base de datos del centro radiológico Panorama.

Tipo de muestreo: Aleatorio simple.

8.3 CRITERIOS DE SELECCIÓN

8.3.1 CRITERIOS DE INCLUSIÓN

Cortes de CBCT 16x15 de hombres y mujeres de 4 a 65 años de edad.
Cortes de CBCT 16x15 que cumplan con el estándar de calidad del equipo dental de Tomografía marca VATECH (VATECH Co. LTD) modelo Green X.

8.3.2 CRITERIOS DE EXCLUSIÓN

Cortes de CBCT del mismo paciente en diferentes fechas.

8.3.3 CRITERIOS DE ELIMINACIÓN

Cortes o CBCT que sufran algún tipo de daño o deterioro antes de la fase de aprendizaje.

8.4 VARIABLES

En el presente estudio, se realizará una fase inicial de entrenamiento y una final de prueba, en la que los algoritmos aprendarán a través de cortes de CBCT a identificar la presencia de factores predisponentes a respiración bucal (cornetes hipertrofiados, desviación de tabique nasal, hipertrofia adenoidea y apertura de la vía aérea), el resultado de la detección de estos factores se evaluará a partir del rendimiento de los algoritmos, expresado como la **exactitud.**

VARIABLE	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL	ESCALA DE MEDICIÓN Y UNIDADES	CATEGORÍA
Redes neuronales convolucionaes	Son un algoritmo de aprendizaje profundo que procesa datos visuales, como imágenes y videos.	A través de formulas matematicas en cada sinápsis artificial.	Cualitativa	Independiente
***Factores predisponentes a respiración bucal**	Órganos clave con alteraciones.	Será como se medirá con la métrica de exactitud.	Cualitativo	Dependiente
Exactitud	Indica un resultado que se acerca al valor de referencia o también llamado valor real o magnitud real.	La cantidad de casos correctamente clasificados por el modelo desarrollado.	Cuantitativo	Dependiente

*los factores predisponentes a respiración bucal se expresarán como la exactitud con base en el rendimiento de las CNN.

8.5 CONCORDANCIA Y FIABILIDAD

1. Se capacitará al investigador por un experto en el campo de inteligencia artificial y sus respectivas ramas, tales como Machine Learning, Deep Learning y Redes Neuronales Convolucionales.
2. Así como la estandarización de criterios diagnósticos con expertos en radiología para poder evaluar la vía aérea y sus órganos clave, así como la identificación de anomalías que pudieran afectar el estudio.
3. Y la estandarización con un experto en otorrinolaringología para poder unificar criterios diagnósticos y protocolos de interconsultas.

8.6 UBICACIÓN ESPACIO – TEMPORAL

1. Centro Radiológico PANORAMA. Puebla, Puebla.
2. Posgrado de Ortodoncia FEBUAP. Puebla, Puebla.
3. Centro de Innovación y Desarrollo Tecnológico en Cómputo del Instituto Politécnico Nacional, CDMX.

ASPECTOS ÉTICOS.

El presente estudio siguió las pautas establecidas por el Código de Nüremberg, la Declaración de Helsinki, la Ley Federal de Salud y la Norma Oficial Mexicana NOM-012-SSA3-2012 que establecen los principios científicos y normas éticas para la realización de proyectos de investigación en humanos.

Las personas que participaron en la investigación tendrán la garantía de respeto a los principios de autonomía, beneficencia y justicia; así como a mantener su identidad y todos los datos que se obtuvieron en la presente investigación sobre su estado de salud en estricta confidencialidad. Se procuró mantener con los participantes un clima de respeto y cordialidad durante el desarrollo del estudio, se mantuvo en el anonimato la identidad de dichos participantes..

De acuerdo con la Ley General de Salud (NOM-004-SSA3-2012), según lo establecido en el artículo 17, esta investigación se consideró sin riesgo; justificando el hecho de ser un estudio que emplea técnicas y métodos de investigación documental en el que no se realizó ninguna intervención o modificación intencionada en las variables fisiológicas, psicológicas y sociales de los estudios que participaron en el estudio, entre los que se consideran: cuestionarios, entrevistas, revisión de expedientes clínicos, imágenes y otros, en los que no se le identifique ni se traten aspectos sensitivos de su conducta (38).

8.7 PROCEDIMIENTOS, TECNICAS Y FUENTES DE RECOLECCIÓN

Metodología

Este estudio se llevó a cabo en tres etapas consecutivas, cada una con objetivos específicos. La primera etapa, denominada "Prueba Piloto", tuvo como finalidad evaluar 3 de las 5 redes neuronales convolucionales que la literatura arrojó como las más apropiadas para identificar los factores predisponentes relevantes del estudio (cornetes, tabique, adenoides y vía aérea superior). Las redes evaluadas fueron VGG16, AlexNet y ResNet. En la segunda etapa, titulada "Aumento de datos", se implementó un proceso de ampliación de la base de datos a partir de las mismas CBCT obtenidas en donde se aumentaron el número de imágenes por cada grupo de interés, con el objetivo de mejorar los resultados obtenidos en la primera etapa. La tercera etapa, denominada "Experimentación", consistió en la prueba final con la base de datos completa, que incluso tuvo una modificación del número total de cortes obtenidos en la segunda fase, debido a un proceso estadístico llamado “Imbalance ratio”, en esta etapa se evaluaron las 5 redes neuronales convolucionales consideradas desde el inicio de esta investigación: VGG16, VGG19, ResNet, LeNet y EfficientNet, pero ya con una base de datos aumentada y balanceada de 520 imágenes sin factores predisponentes y 350 imágenes de cada factor predisponente. En esta fase se determinó las métricas de exactitud (con la fórmula matemática correspondiente) de las redes seleccionadas, a partir de los resultados de la matriz de confusión (ya que estadísticamente al no tener un desbalance entre clases no se requiere evaluar el rendimiento del modelo con las métricas de sensibilidad y especificidad debido a que existió balance de clases).

8.7.1 PRIMERA ETAPA - “Prueba Piloto”

1. Al inicio de esta etapa, se procedió con la estandarización del tesista en la clasificación de las vías aéreas superiores y órganos clave, así como en la medición correspondiente, con la colaboración de la Dra. María Isabel Pizano Damasco, especialista en radiología oral y maxilofacial. Se clasificaron 15 CBCT en dos grupos: uno con factores predisponentes y otro sin ellos. A partir de los resultados obtenidos, se calculó el coeficiente de correlación intraclase como estrategia para sustentar la estandarización del tesista.

2. Completada la estandarización, se solicitó el apoyo del centro radiológico PANORAMA, que proporcionó 32 CBCT. Estas fueron sometidas a muestreo aleatorio simple, evaluadas según los criterios de selección establecidos y clasificadas en los grupos de interés. Se realizó una prueba piloto inicial para evaluar la capacidad de los algoritmos en la identificación de las zonas de interés, utilizando 30 de las 32 CBCT de las cuales se obtuvieron 75

imágenes de cortes sagitales y coronales por grupo (con factores predisponentes a respiración oral y sin ellos), según lo sugerido por la literatura para este tipo de pruebas piloto.

3. Las tomografías fueron procesadas y clasificadas mediante el software Horos™ (Annapolis, Maryland, Estados Unidos), herramienta utilizada para visualizar archivos DICOM e identificar la condición de los órganos clave (cornetes, tabique, adenoides y vía aérea superior), obteniendo imágenes en vistas sagital y coronal. La estrategia de identificación y clasificación utilizada fue la recomendada por la literatura y por la experta radióloga. En el caso de las **adenoides hipertróficas** se realizó mediante una escala de 4 grados, el grado 1 es menos del 25 % de obstrucción, el grado 2 es del 25 % al 50 % de obstrucción a partir del cual se considera ya una hipertrofia adenoidea, el grado 3 es del 50 % al 75 % de obstrucción y el grado 4 es del 75 % al 100% de obstrucción de la nasofaringe en el plano sagital (39). Los criterios para identificar y clasificar los **cornetes hipertróficos** se basaron en el ancho máximo del cornete inferior en el plano coronal. Un ancho de más de 10 mm se consideró hipertrofia de cornete (40). El **tabique desviado** se identificó y clasificó con el ángulo de desviación septal, se midió en el plano coronal utilizando los siguientes puntos de referencia anatómicos, el punto A es la unión del tabique nasal con el suelo de la cavidad nasal, el punto B es la apófisis Crista Galli. La línea BC es la tangente que surge del punto B y pasa a través de la parte más externa en la convexidad del tabique desviado. El ángulo ABC es el ángulo de desviación septal; según el ángulo de desviación, se clasificaron en leve menos de 9°, moderado 9°-15° (a partir de este grado se consideró como tabique desviado) y severo mayor de 15° (41). Por último, la **vía aérea estrecha** se clasifico a partir de dos medidas en el plano sagital, las cuales contemplan el diámetro faríngeo superior (nasofaringe): 17.5 mm +/- 4 mm, diámetro faríngeo inferior (orofaringe): 11.3 mm +/- 4 mm. Si obteníamos una disminución en las medidas se clasificaba como estrechez de la vía aérea superior (42).

4. Los grupos completos de 75 imágenes por clasificación (con factores predisponentes y sin factores predisponentes) fueron almacenados en Microsoft Excel® (versión 16.77.1).

5. Posteriormente, las carpetas con las imágenes de los cortes clasificados fueron enviadas al Dr. Elías Ventura, experto en redes neuronales convolucionales, para iniciar las fases de aprendizaje, validación y prueba. Se evaluaron las CNNs: VGG16, AlexNet y ResNet, seleccionadas por su uso frecuente en estudios previos. Los resultados de esta fase fueron

determinantes para la elección de redes y número de imágenes en etapas posteriores.

6. El análisis realizado por el experto se dividió en tres fases: **entrenamiento, validación y prueba**. Antes de iniciar el aprendizaje, se particionó el banco de datos siguiendo estos pasos:

I. Se mezclaron aleatoriamente las imágenes de cada clase y se dividieron en tres conjuntos: entrenamiento, validación y prueba.

II. La partición de los datos se realizó asignando el 60% de las imágenes (n=45 por clase) al conjunto de **entrenamiento**, el 20% (n=15 por clase) al conjunto de **validación** y el 20% (n=15 por clase) al conjunto de **prueba**.

III. Las imágenes se almacenaron en tres carpetas separadas aleatoriamente: entrenamiento, validación y prueba.

IV. Se utilizaron los datos de entrenamiento para enseñarle a la red neuronal convolucional, los de validación para ajustar los hiperparámetros del modelo y los de prueba para evaluar el rendimiento final.

7. Durante la fase de entrenamiento, se proporcionaron las 45 imágenes de cada grupo a las CNNs para que identificaran bordes, líneas y formas específicas en las áreas de interés de los órganos clave.

8. En la validación, se utilizaron 15 imágenes por grupo para verificar la correcta identificación de las zonas de interés por parte de las CNNs.

9. Finalmente, en fase de prueba, se evaluó el desempeño de las redes con las 15 imágenes restantes, a fin de determinar su capacidad de identificar y clasificar correctamente las imágenes. (43-45).

8.7.2 SEGUNDA ETAPA - "Aumento de datos"

Con base en las clasificaciones obtenidas de las imágenes de los dos grupos en conjunto, 75 con factores predisponentes y 75 sin factores predisponentes durante la prueba piloto, en la segunda etapa se aplicó un proceso de "Aumento de datos", en colaboración con el experto en CNNs, esperando que como se reporta en la literatura con un mayor número de datos que se les proporcionara a las redes pudieran mejorar su rendimiento. Se incrementó el número de imágenes a través de la obtención de nuevos cortes en distintas localizaciones sagitales y coronales,

en un complejo y largo proceso en donde por cada tomografía se generó el número de imágenes promedio correspondiente a su grupo de condición para que al final de la fase se obtuvieran el mismo número de imágenes por cada grupo (n=350), con y sin factores predisponentes. Para lograr esto se utilizó el total de las 32 CBCT proporcionadas por el centro radiológico PANORAMA, esto permitió ampliar la base de datos para volver a entrenar los modelos en una tercera fase con conjuntos más extensos, generando en total 1400 imágenes de cortes tomográficos con factores predisponentes y 1400 imágenes sin ellos, es decir, en esta fase se aumentó la base de datos en un 1750%.

8.7.3 TERCERA ETAPA - "Prueba experimental"

En esta etapa se evaluaron las 5 redes neuronales convolucionales VGG16, VGG19, ResNet, LeNet y EfficientNet contempladas desde el inicio de esta investigación. El objetivo fue determinar la exactitud de cada red, a partir de los valores obtenidos en la matriz de confusión. Estos datos permitieron calcular las métricas de rendimiento y realizar el análisis comparativo de los resultados.

1. En esta última etapa, se replicaron los procedimientos de la prueba piloto, pero utilizando la base de datos ampliada y con un nuevo balance de clases, es decir, buscando que las CNN aprendieran y se siguieran midiendo únicamente con la métrica exactitud, se realizó el cálculo de las muestras a través de un proceso llamado “Imbalance ratio” o “Índice de desbalance” (IR) ya que cuando una clase aparece con mucha más frecuencia que otra(s), el modelo tiende a sesgarse hacia la clase mayoritaria. Esto puede llevar a un rendimiento pobre, especialmente en la detección de la clase minoritaria (46).

   Este IR se calculó a través de una fórmula matemática la cual se explica a continuación: $IR = \frac{número\ de\ muestras\ de\ la\ clase\ mayoritaria}{número\ de\ muestras\ de\ la\ clase\ minoritaria} = \leq 1.5$ (47). Es decir, en esta tercera etapa se utilizaron del nuevo banco de datos 520 imágenes sin factores predisponentes como clase mayoritaria y 350 imágenes de cada factor predisponente como clase minoritaria (cornetes hipertróficos, tabique desviado, adenoides hipertróficas, vía aérea superior estrecha). Por lo tanto, el Índice de desbalance se calculó de la siguiente manera: $IR = \frac{520}{350} = 1.486$, lo cual quiere decir que el IR = 1.486 es menor que 1.5; por lo que se dice que el banco de datos está balanceado y basta con calcular la exactitud como medida de rendimiento (46, 47).

2. El análisis realizado por el experto se dividió en tres fases: entrenamiento, validación y prueba. Antes de iniciar el aprendizaje, se particionó el nuevo

banco de datos balanceado siguiendo estos pasos:

I. Se mezclaron aleatoriamente las imágenes de cada clase y se dividieron en tres conjuntos: entrenamiento, validación y prueba.

II. La partición de los datos por clases se realizó de la siguiente manera:

- El 60% de las 520 imágenes sin factores predisponentes (clase mayoritaria) corresponde a una n=312 para conjunto de **entrenamiento**.
- El 20% de las 520 imágenes sin factores predisponentes corresponde a una n=104 para el conjunto de **validación**.
- El 20% de las 520 imágenes sin factores predisponentes corresponde a una n=104 para el conjunto de **prueba**.

- El 60% de las 350 imágenes con factor predisponente: **cornetes hipertróficos**, (clase minoritaria) corresponde a una n=210 para el conjunto de **entrenamiento**.
- El 20% de las 350 imágenes con factor predisponente: cornetes hipertróficos, corresponde a una n=70 para el conjunto de **validación**.
- El 20% de las 350 imágenes con factor predisponente: cornetes hipertróficos, corresponde a una n=70 para el conjunto de **prueba**.

- El 60% de las 350 imágenes con factor predisponente: **tabique desviado**, (clase minoritaria) corresponde a una n=210 para el conjunto de **entrenamiento**.
- El 20% de las 350 imágenes con factor predisponente: tabique desviado, corresponde a una n=70 para el conjunto de **validación**.
- El 20% de las 350 imágenes con factor predisponente: tabique desviado, corresponde a una n=70 para el conjunto de **prueba**.

- El 60% de las 350 imágenes con factor predisponente: **adenoides hipertróficas**, (clase minoritaria) corresponde a una n=210 para el conjunto de **entrenamiento**.
- El 20% de las 350 imágenes con factor predisponente: adenoides hipertróficas, corresponde a una n=70 para el conjunto de **validación**.
- El 20% de las 350 imágenes con factor predisponente: adenoides hipertróficas, corresponde a una n=70 para el conjunto de **prueba**.

- El 60% de las 350 imágenes con factor predisponente: **vía aérea superior estrecha**, (clase minoritaria) corresponde a una n=210 para el conjunto de **entrenamiento**.
- El 20% de las 350 imágenes con factor predisponente: vía aérea superior estrecha, corresponde a una n=70 para el conjunto de **validación**.
- El 20% de las 350 imágenes con factor predisponente: vía aérea superior estrecha, corresponde a una n=70 para el conjunto de **prueba**.

De esta manera se consiguió una partición de datos totales de la siguiente manera:

- El conjunto de **aprendizaje (correspondiente al 60%)** tiene una n=312 de imágenes sin factores predisponentes + una n=210 de imágenes con cornetes hipertróficos + una n=210 de imágenes con tabique desviado + una n=210 de imágenes con adenoides hipertróficas + una n=210 de imágenes con vía aérea cerrada, lo cual arrojó un total de: 1152 imágenes.

- El conjunto de **validación (correspondiente al 20%)** tiene una n=104 de imágenes sin factores predisponentes + una n=70 de imágenes con cornetes hipertróficos + una n=70 de imágenes con tabique desviado + una n=70 de imágenes con adenoides hipertróficas + una n=70 de imágenes con vía aérea cerrada, lo cual arrojó un total de: 384 imágenes.

- El conjunto de **prueba (correspondiente al 20%)** tiene una n=104 de imágenes sin factores predisponentes + una n=70 de imágenes con cornetes hipertróficos + una n=70 de imágenes con tabique desviado + una n=70 de imágenes con adenoides hipertróficas + una n=70 de imágenes con vía aérea cerrada, lo cual arrojó un total de: 384 imágenes.

III. Las imágenes se almacenaron en tres carpetas separadas aleatoriamente: entrenamiento, validación y prueba.

IV. Se utilizaron los datos de entrenamiento para enseñar a la red neuronal convolucional, los de validación para ajustar los hiperparámetros del modelo y los de prueba para evaluar el rendimiento final.

1. Durante la fase de **entrenamiento**, se proporcionaron las 1152 imágenes de cada grupo a las CNNs para que identificaran bordes, líneas y formas específicas en las áreas de interés de los órganos clave.

2. En la **validación**, se utilizaron 384 imágenes por grupo para verificar la correcta identificación de las zonas de interés por parte de las CNNs.

3. Finalmente, en fase de **prueba**, se evaluó el desempeño de las redes con las 384 imágenes restantes, a fin de determinar su capacidad de identificar y clasificar correctamente las imágenes. (43-45).

Es de suma importancia recalcar que cada vez que se corrió el algoritmo se hizo una nueva partición del banco de datos, con la misma cantidad de imágenes en cada fase pero se repartió aleatoriamente esa cantidad usando el banco de datos obtenido en la segunda etapa, el total de veces que se corrió el algoritmo fue de 100 veces para cada red neuronal convolucional (se corrió 500 veces en total midiendo el rendimiento de las 5 CNNs), en cada corrida se obtuvieron resultados diferentes que se guardaron y dividieron entre 100, con ese promedio se rellenó la matriz de confusión y posteriormente se midió la exactitud con la fórmula matemática correspondiente para evaluar que CNN rindió mejor porcentaje de exactitud.

DIAGRAMA DE FLUJO

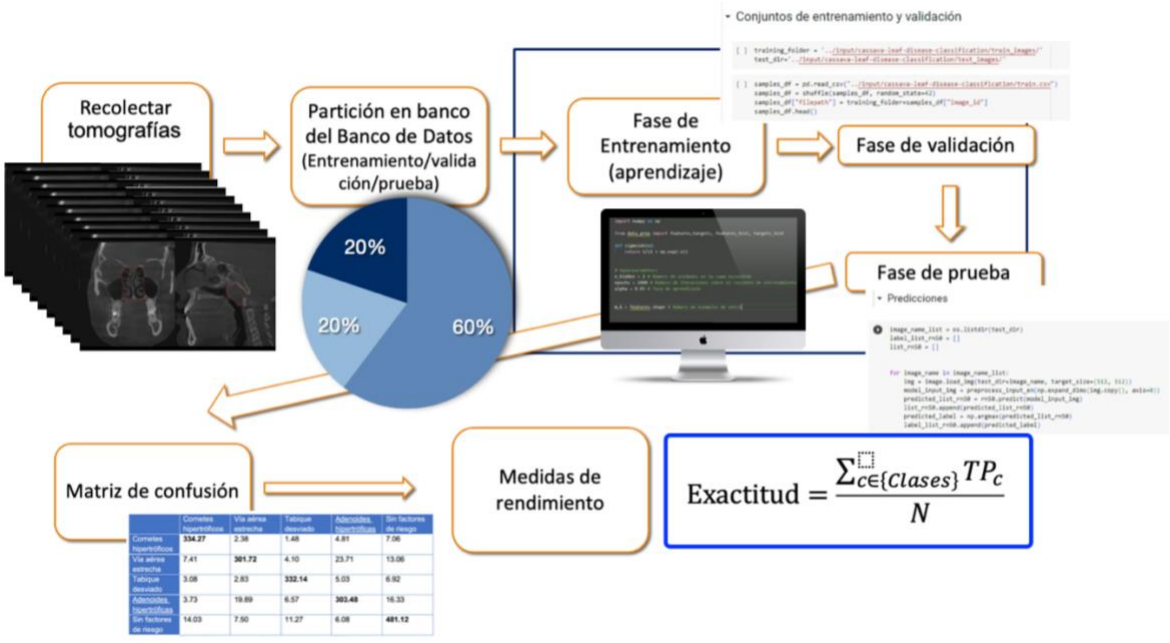

Cuantificación de los resultados obtenidos por la mejor red neuronal convolucional.

Dado el enfoque metodológico propio de las ciencias computacionales y la complejidad del presente estudio (el cual contempla la detección de más de un

factor de riesgo y la evaluación comparativa de cinco arquitecturas de redes neuronales), el análisis detallado de las matrices de confusión y los cálculos asociados a la métrica de exactitud se limita a aquellas redes que demostraron el mejor desempeño en términos de clasificación.

Una vez realizadas las pruebas de las diferentes fases, el siguiente paso fue evaluar los resultados obtenidos de las pruebas de la mejor red neuronal convolucional. La matriz de confusión de la mejor red entregó los datos finales los cuales se interpretaron y describieron. En este estudio se obtuvo la exactitud (con la respectiva fórmula matemática que se explica más adelante) que es es la cantidad de imágenes clasificadas correctamente por el modelo, a partir de los valores de la matriz de confusión de 5x5 que se usa en un problema de clasificación multiclase (para los cuatro factores de riesgo y la clase sin factor de riesgo), la cuál se encargó de cuantificar el desempeño del algoritmo, La fórmula matemática para calcular esta exactitud se desarrolla de la siguiente manera: el símbolo ∑ representa sumatoria, la expresión c∈ {Clases}, TPc representa el número de verdaderos positivos de cada clase, es decir, la cantidad de instancias que fueron correctamente clasificadas como pertenecientes a cada clase expresadas en la matriz de confusión. La suma se realiza de todas las clases consideradas en el problema (en este caso, cinco clases). Finalmente, N corresponde al total de instancias del conjunto de evaluación, es decir el total de cada muestra de clase mayoritaria y minoritaria respectivamente, a ese total es al que se dividió la suma de los verdaderos positivos de las clases. Una vez realizada la suma de los verdaderos positivos de cada clase, esta suma se divide entre el número total de las dos muestras, es decir, clase mayoritaria y minoritaria, para finalmente ese número multiplicarlo por 100 y así obtener el resultado de la exactitud en porcentaje (48).

$$\text{Exactitud} = \frac{\sum_{c \in \{Clases\}} TP_c}{N}$$

8.8 ANÁLISIS ESTADÍSTICO

Para evaluar el desempeño del mejor modelo, se emplearon las métricas de rendimiento para calcular la exactitud. La obtención de estas métricas se basó en la interpretación de las ecuaciones derivadas de la matriz de confusión, la cual se construyó a partir de los valores correspondientes a los TPc que representa el número de verdaderos positivos para cada clase c∈ sumados y divididos entre n, que corresponde al total de instancias del conjunto de evaluación, es decir el total de cada muestra de clase mayoritaria y minoritaria respectivamente. Los valores

resultantes de estas métricas se encuentran en un rango que va de 0 a 1. La ecuación utilizada para este cálculo es la siguiente:

$$\text{Exactitud} = \frac{\sum_{c \in \{Clases\}} TP_c}{N}$$

Un resultado positivo indica que el modelo ha predicho si hay algún factor de riesgo que predisponga a respiración oral. En cuanto a los términos de 'verdadero' o 'falso', la predicción se refiere a si la clasificación realizada es correcta o incorrecta (48).

Además, se empleó la prueba estadística CCI (Coeficiente de Correlación Intraclase o Coeficiente de Determinación R^2 de Pearson) para la evaluación del rendimiento de la estandarización en comparación con la evaluación de la experta en radiología.

9. RESULTADOS

Para valorar la concordancia y fiabilidad de este estudio, como se mencionó previamente se estandarizó al tesista con una Radiológa Maxilofacial y se realizó el análisis de CCI (Coeficiente de correlación intraclase). Se realizó el CCI intraobservador con el tesista; es decir se midieron 2 veces los mismos órganos claves en diferentes tiempos donde se obtuvo una concordancia de 0.90. De igual manera se midieron los mismos órganos clave por la experta radiológa y se realizó el análisis interobservador y se obtuvo una concordancia de 0.90. El análisis de CCI fue realizado con las herramientas de Microsoft Excel para medir la correlación. Después de obtener un CCI favorable de 0.9 tanto intra como interobservador, se procedió a realizar las pruebas de las CNNs teniendo la certeza de que lo que se le enseñó al modelo estaría correctamente clasificado.

Dado el enfoque metodológico propio de las ciencias computacionales y la complejidad del presente estudio (el cual contempla la detección de más de un factor de riesgo y la evaluación comparativa de cinco arquitecturas de redes neuronales), los resultados del análisis detallado de las matrices de confusión y los cálculos asociados a la métrica de exactitud se limitaron a aquellas redes que demostraron el mejor desempeño en términos de clasificación.

PRIMERA ETAPA - “Prueba Piloto”

Tres redes neuronales convolucionales fueron probadas previamente por medio de una prueba piloto para valorar parámetros y observar si las CNNs eran capaces de detectar el área de interés de los factores predisponentes. En la prueba piloto las redes neuronales convolucionales; VGG16, AlexNet y ResNet fueron probadas con

un base de datos de 75 imágenes de CBCT con factores de riesgo y 75 imágenes de CBCT sin factores de riesgo. El mejor resultado obtenido fue de ResNet con 86.66% de exactitud de detección de factores de riesgo, después VGG16 con 83.91%, y por último AlexNet 76.65% (Tabla 1).

Tabla 1. *Resultados de la prueba piloto; 3 CNNs fueron probadas.*

RED NEURONAL	EXACTITUD
ResNet	**86.66%**
VGG16	83.91%
AlexNet	76.65%

La Red Neuronal Convolucional ResNet mostró la mayor exactitud, se logró un porcentaje de 86.66% (Tabla 1), este porcentaje se obtuvo a partir de la matriz de confusión de 2x2 que reflejó el promedio de las 100 veces que se corrió esta red neuronal con las 75 imágenes sin factores de riesgo y las 75 imágenes con factores de riesgo, en donde se obtuvieron: **56** imágenes con factores de riesgo clasificadas como correctas y **74** imágenes sin factores de riesgo clasificadas como correctas (Tabla 2).

Tabla 2. *Matriz de confusión 2x2; red neuronal ResNet.*

	Factores predisponentes	Sin factores predisponentes
Factores predisponentes	**56**	19
Sin factores predisponentes	1	**74**

Exactitud.

Por lo tanto, podemos observar que el número de imágenes clasificadas correctamente en la matriz de confusión que aparecen subrayadas y resaltadas (Tabla 2), fueron los valores que se utilizaron para hacer la sumatoria de las clases que posteriormente se dividió en el número total de la muestra de las dos clases, para poder calcular el porcentaje en la fórmula matemática correspondiente a la exactitud:

$$\text{Exactitud} = \frac{\sum_{c \in \{Clases\}} TP_c}{N}$$

$$\text{Exactitud} = \frac{\mathbf{56 + 74}}{75 + 75}$$

$$\text{Exactitud} = \frac{\mathbf{130}}{150} = 0.8666 * 100 = 86.66\%$$

SEGUNDA ETAPA - "Aumento de datos"

En esta segunda etapa, se implementó un proceso de *aumento de datos* en colaboración con el especialista en redes neuronales convolucionales, con el objetivo de mejorar el desempeño de los modelos. Esta estrategia se basó en evidencia reportada en la literatura, donde un mayor volumen de datos disponibles para el entrenamiento tiende a favorecer el rendimiento de las redes. El incremento en la cantidad de imágenes se logró mediante la obtención de nuevas imágenes de cortes tomográficos en diferentes localizaciones sagitales y coronales. Este procedimiento, de carácter complejo y prolongado, consistió en generar para cada tomografía un número de imágenes equivalente al promedio correspondiente a su grupo diagnóstico, por ejemplo, de las tomografías numero 1, 4, 9, 10, 19, 29 y 32 se tenían que obtener 50 imágenes de cortes de cada una con adenoides hipertróficas para que las 7 tomografías dieran un total de 350 imágenes de cortes del grupo diagnóstico: Adenoides hipertróficas, así sucesivamente con cada grupo diagnóstico; 350 imágenes de adenoides sanas, 350 imágenes de cornetes hipertróficos, 350 imágenes de cornetes sanos, 350 imágenes de tabique desviado, 350 imágenes de tabique sano, 350 imágenes de vía aérea estrecha y 350 imágenes de vía aérea sana, como se observa en la (Tabla 3). Con el número total de imágenes obtenidas de cada tomografía, se equilibro el número de muestras entre los grupos con y sin factores predisponentes. Lo que permitió ampliar significativamente la base de datos. Esta ampliación posibilitó un nuevo entrenamiento de los modelos en una tercera y última fase, utilizando conjuntos más extensos que pudieron incluir hasta 1400 cortes con factores predisponentes y hasta 1400 sin ellos, lo que representa un aumento del 1750 % en la cantidad de datos disponibles (Tabla 3).

Tabla 3. *Resultados del aumento de datos en un 1750%; con el número total de imágenes generadas por cada tomografía, por factor, señalada en cada casilla.*

CBCT	Adenoides hipertróficas	Adenoides sanas	Cornetes hipertróficos	Cornetes sanos	Tabique desviado	Tabique sano	Vía aérea estrecha	Vía aérea sana
1	50		19		22		31	
2				24		20		
3		16		24	42		29	
4	50		19				29	
5			19					
6		18		24		22		18
7		16	19		22			18
8		15	19		22		16	
9	50			23		22	42	
10	50			20	22			32
11		15	22			22		18
12		15		24	22			18

13		15		23	22			18
14		15	25		44		29	
15		15	23		22		29	
16		15		24		22		18
17		15		23		22		18
18		15		23		22	29	
19	50		22			22		31
20		15	27			22		18
21		15		24	22			18
22		15	23			22		18
23		15	21			22		17
24		15	23			22		18
25		15		23	22			18
26		15		24		22	29	
27		15	18		22		29	
28		15	18		22			18
29	50		18			22	29	
30		15		24		22		18
31		15		23		22		18
32	50		15		22		29	
Total	350	350	350	350	350	350	350	350

TERCERA ETAPA - "Prueba experimental"

Finalmente las cinco redes neuronales convolucionales contempladas al inicio de la investigación fueron probadas para valorar cual de ellas obtenia el mejor porcentaje de exactitud. En la prueba experimental las redes neuronales convolucionales; LeNet, VGG16, VGG19, ResNet y EfficientNet fueron probadas con un base de datos balanceada por el IR de 350 imágenes de CBCT por factor de riesgo y 520 imágenes de CBCT sin factores de riesgo. El mejor resultado en exactitud de detección de factores de riesgo obtenido fue de EfficientNet con 91.28%, después VGG19 con 89.07%, seguida de VGG16 con 88.71%, después ResNet con 86.43% y por último LeNet 78.35% (Tabla 4).

Tabla 4. *Resultados de la prueba experimental; 5 CNNs fueron probadas.*

RED NEURONAL	EXACTITUD
EfficientNet	**91.28%**
VGG19	89.07%
VGG16	88.71%
ResNet	86.43%
LeNet	78.35%

La Red Neuronal Convolucional EfficientNet mostró la mayor exactitud, se logró un porcentaje de 91.28% (Tabla 4), este porcentaje se obtuvo a partir de la matriz de

confusión de 5x5 que reflejó el promedio de las 100 veces que se corrió esta red neuronal con las 520 imágenes sin factores de riesgo y las 350 imágenes de cada factor de riesgo, en donde se obtuvieron: **334.27** imágenes de cornetes hipertróficos clasificadas como correctas, **301.72** imágenes de vía aérea estrecha clasificadas como correctas, **332.14** imágenes de tabique desviado clasificadas como correctas, **303.48** imágenes de adenoides hipertróficas clasificadas como correctas después y por último **481.12** imágenes sin factores de riesgo clasificadas como correctas (Tabla 5).

Tabla 5. *Matriz de confusión 5x5; red neuronal EfficientNet.*

	Cornetes hipertróficos	Vía aérea estrecha	Tabique desviado	Adenoides hipertróficas	Sin factores de riesgo
Cornetes hipertróficos	**334.27**	2.38	1.48	4.81	7.06
Vía aérea estrecha	7.41	**301.72**	4.10	23.71	13.06
Tabique desviado	3.08	2.83	**332.14**	5.03	6.92
Adenoides hipertróficas	3.73	19.89	6.57	**303.48**	16.33
Sin factores de riesgo	14.03	7.50	11.27	6.08	**481.12**

Exactitud.

Por lo tanto, podemos observar que el número de imágenes clasificadas correctamente en la matriz de confusión subrayados y resaltados (Tabla 5), fueron los valores que se utilizaron para hacer la sumatoria de las clases que posteriormente se dividió en el número total de la muestra para poder calcular el porcentaje en la fórmula matemática correspondiente a la exactitud:

$$\text{Exactitud} = \frac{\sum_{c \in \{Clases\}} TP_c}{N}$$

$$\text{Exactitud} = \frac{\mathbf{334.27 + 301.72 + 332.14 + 303.48 + 481.12}}{350 + 350 + 350 + 350 + 520}$$

$$\text{Exactitud} = \frac{\mathbf{1752.73}}{1920} = 0.9128 * 100 = 91.28\%$$

10. DISCUSIÓN

La respiración bucal y la apnea obstructiva del sueño (AOS) representan condiciones clínicas de elevada prevalencia que afectan significativamente la salud general y el desarrollo cráneo-facial (49,50). La respiración bucal, frecuentemente subdiagnosticada, puede estar asociada a alteraciones en la morfología dentofacial, tales como maloclusiones, paladar estrecho y postura lingual inadecuada (51). Por su parte, la AOS se caracteriza por episodios recurrentes de obstrucción parcial o total de la vía aérea superior durante el sueño, lo cual conlleva a hipoxemia, microdespertares y fragmentación del sueño, impactando negativamente en el rendimiento cognitivo, crecimiento y calidad de vida del paciente (52, 53). En las últimas décadas, la inteligencia artificial (IA) ha emergido como una herramienta prometedora en el ámbito médico, permitiendo la automatización y mejora de procesos diagnósticos complejos. En particular, las redes neuronales convolucionales (CNN) han demostrado un rendimiento notable en el análisis de imágenes médicas, señales acústicas y registros fisiológicos, facilitando la detección exacta y no invasiva de patrones característicos de patologías respiratorias (54, 55). Aplicadas a la evaluación del tracto respiratorio superior, las CNN permiten segmentar estructuras anatómicas críticas en tomografías computarizadas o imágenes por resonancia magnética, así como clasificar patrones acústicos o morfométricos indicativos de respiración bucal o episodios de AOS (56, 57). Diversos estudios han validado la efectividad de las CNN en la identificación de alteraciones estructurales del espacio aéreo faríngeo, el reconocimiento automático de fases respiratorias y la predicción de riesgo de apnea, superando en varios casos las metodologías tradicionales en exactitud y eficiencia (48, 58, 59). Estas aplicaciones no solo ofrecen beneficios clínicos inmediatos en términos de diagnóstico, sino que también abren nuevas posibilidades para la implementación de sistemas de monitoreo continuo, personalizados y accesibles.

Primera Etapa: Prueba Piloto

La fase inicial de esta investigación se centró en evaluar la viabilidad de aplicar técnicas de inteligencia artificial para identificar factores predisponentes a respiración bucal. Se desarrolló un modelo preliminar utilizando 3 redes neuronales convolucionales (ResNet, VGG16 y AlexNet) entrenadas con un conjunto de datos limitado, compuesto por imágenes obtenidas a partir de CBCT de pacientes con factores predisponentes a respiración bucal y sin factores predisponentes. Los resultados de la mejor red neuronal arrojaron una exactitud del 86.66% con la CNN ResNet, lo que indica un potencial prometedor para esta aproximación. Estos hallazgos son consistentes con estudios previos que han utilizado IA para analizar patrones de hipertrofías en órganos claves. Por ejemplo, J. L. Liu et al. desarrollaron

una CNN llamada VGG-Lite, utilizando el mayor conjunto de datos descrito hasta la fecha para apoyar la detección automática de la hipertrofia adenoidea (n=1023 imágenes laterales de rayos X, n=505 de adenoides sanas y n=418 con hipertrofia), alcanzando una sensibilidad del 89.80%, una especificidad del 88.20%, un valor predictivo positivo de 0,880, un valor predictivo negativo de 0,900 y una puntuación F1 de 0,889 (60). Demostrando que en clases con balances especifícos y de dos grupos es viable reportar la sensibilidad, especificidad y puntuación F1, a diferencia de la prueba piloto de la primera fase, en donde solamente se reportó la exactitud debido a que era el primer acercamiento, con el único objetivo de comparar entre las 3 redes cual era la mejor, con el mejor porcentaje de exactitud se decidió parar para probar otras redes con otro balance de clases y con el aprendizaje de necesitar más datos en una tercera etapa, ya que la n total era de n=150 en comparación a la reportada por J. L. Liu et al. de n=1023. Aunque su enfoque se centró únicamente en la detección de hipertrofia adenoidea y en datos obtenidos de rayos X, demuestra la eficacia de las CNN en el análisis de factores predisponentes relacionados con la respiración (60). Sin embargo, en el presente estudio la limitada cantidad de datos en esta etapa representó una restricción significativa para los resultados piloto. La necesidad de una mayor diversidad y volumen de datos se hizo evidente en los porcentajes de exactitud. Por lo que se decidió dedicar toda una etapa a la limitación de la cantidad de datos.

Segunda Etapa: Aumento de Datos

En respuesta a la limitación identificada en la primera etapa, la cual fué número reducido de imágenes, se procedió a ampliar el conjunto de datos mediante la recopilación de información adicional de las CBCT. Esta expansión permitió entrenar un modelo más robusto en la tercera etapa. La inclusión de más datos enriqueció el modelo ya que como se reporta en la literatura, las redes neuronales convolucionales profundas han funcionado notablemente bien en muchas tareas de visión por ordenador. Sin embargo, estas redes dependen en gran medida del big data para evitar el sobreajuste. El sobreajuste se refiere al fenómeno cuando una red aprende una función con una varianza muy alta, como modelar perfectamente los datos de entrenamiento. Desafortunadamente, muchos dominios de aplicaciones no tienen acceso a macrodatos, como el análisis de imágenes médicas. Por lo tanto el aumento de datos, es una solución de espacio de datos al problema de los datos limitados. Abarca un conjunto de técnicas que mejoran el tamaño y la calidad de los conjuntos de datos de capacitación de tal manera que se puedan construir mejores modelos de aprendizaje profundo al utilizarlos. Pueden incluir transformaciones geométricas, aumentos del espacio de color, filtros de núcleo, mezcla de imágenes, borrado aleatorio, aumento del espacio de características, etc, (61). Tingting Zhao et al., en el año 2021 en su estudio titulado:

Evaluación automatizada de la hipertrofia adenoide con cefalometría lateral en niños basada en inteligencia artificial, modificaron las imágenes originales rotandolas de -20 a 20 grados alrededor del centro de la imagen. Además estas imágenes se desplazaron 10 píxeles en las direcciones arriba, abajo, izquierda, derecha, 20 píxeles hacía direcciones diagonales, siempre cuidando que la región de interés estuviera siempre dentro de la imagen para evitar la pérdida de información. Después de este paso, el tamaño del conjunto de datos de entrenamiento creció de 581 imágenes a 9877 imágenes (62). En comparativa, el presente estudio buscó resolver la limitación de la cantidad de datos sin hacer modificaciones a las imágenes originales para no perder la región de interés y para no distorcionar las imágenes, se hizo incluyendo nuevas imágenes de las mismas CBCT solo que tomadas en diferentes localizaciones en los planos sagital y coronal, pasando de una n=150 a una n=2800 imágenes, permitiendo el aumento significativo del dataset buscando mejorar la exactitud. A pesar de que este sistema ha demostrado un buen rendimiento, sigue teniendo algunas limitaciones respecto a los datos que podrían mejorar en estudios futuros, la más importante es que este conjunto de datos está formado únicamente por CBCT de un solo centro radiológico (PANORAMA), en el futuro, será necesario entrenar un modelo recopilando imágenes de varios pacientes de más centros radiológicos y clínicos para incrementar su generalizabilidad.

Tercera Etapa: Prueba Experimental

En este estudio, se propuso un modelo de diagnóstico basado en aprendizaje profundo con redes neuronales que identifica automáticamente los factores de riesgo a respiración bucal a partir de imágenes CBCT. Los resultados demostraron que el rendimiento del modelo fue muy similar al de expertos humanos, requiriendo una mínima parte de su tiempo. La fase experimental se enfocó en validar la eficacia del mejor modelo de IA para llegar a ser altamente exacto y utilizable en un entorno clínico real. Se aplicó al modelo un nuevo grupo de datos, aumentados y balanceados cuidadosamente para que la exactitud fuera la única medida de rendimiento necesaria y más confiable obteniendo una exactitud del 91.28% en la identificación de factores predisponentes a respiración bucal, con la CNN EfficientNet. Este resultado demuestra la capacidad del modelo para clasificar nuevos datos que no ha visto previamente y su potencial utilidad en la práctica clínica. Comparativamente, algunos estudios han propuesto que el aprendizaje profundo puede aplicarse al diagnóstico de hipertrofia adenoidea en niños mediante análisis cefalométrico lateral (63, 64). Sin embargo, según la revisión en la literatura, este estudio es de los primeros en proponer un modelo basado en aprendizaje profundo para diagnosticar no solo la hipertrofia adenoidea, sino además la hipertrofía de cornetes, desvío de tabique y vía aérea superior estrecha en un solo

modelo, lo cual sitúa al modelo como bastante amplio y exacto para diagnosticar los principiales órganos causales de la Apnea Ostructiva del Sueño y no solo identificando un solo órgano causal y haciendolo a partir de cortes de CBCT y no de rayos X. Un estudio previo solo propuso una red codificadora-decodificadora profunda convolucional basada en el modelo Tiramisú para hacer solamente la segmentación la cavidad nasosinusal y la vía aérea faríngea (65). Sin embargo, en el presente estudio, no se propuso un modelo de segmentación para la vía aérea superior (debido a la ya conocida problemática de que las segmentaciones no tienen la misma exactitud como un corte), sino que se obtuvo un diagnóstico automatizado de los factores predisponentes a respiración bucal mediante la evaluación de la morfología anátomica de estos órganos clave en cortes. Recientemente, se han publicado algunos programas comerciales que pueden segmentar la vía aérea superior, pero primero requieren establecer un punto manual, enmarcar el rango de la vía aérea superior y luego formar la estructura 3D de la vía aérea (66). Establecer puntos de referencia produce errores que afectan el diagnóstico final y consumen más tiempo. Estos programas comerciales, Dolphin (Imaging & Management Solutions, Chatsworth, EE. UU.), Romexis 5 y Romexis 6 (ambos Planmeca Oy, Helsinki, Finlandia), se basan en parte en la segmentación semiautomática, cuya exactitud depende del valor de gris y del umbral definidos por el operador. No existe un gradiente de grises significativo entre las vías respiratorias superiores y los tejidos de los órganos clave en las imágenes CBCT ya que la densidad de tejidos blandos es menor a la de los tejidos duros lo cual vuelve poco fiable a las segmentaciones en la que se basan la mayoría de los modelos existentes (66). Por lo tanto, el presente estudio obtiene directamente resultados de diagnóstico de los factores predisponentes mediante la introducción de una imagen CBCT, eliminando el proceso de localización de puntos de referencia y segmentación, reduciendo así la carga de trabajo del ortodoncista y el sesgo que implica la segmentación de cortes tomográficos. Dong, W., et al., en el año 2023 reportaron su estudio el cual propuso un método de diagnóstico automático basado en el aprendizaje profundo para la detección de hipertrofia adenoide en CBCT, utilizando 87 CBCT, obteniendo como mejor resultado a la CNN (3D)-ResNet con una exactitud del 91.20% (67). Lo cual refuerza el enfoque del presente estudio, que de igual manera utiliza imágenes de CBCT por ser el “Gold Standar” en diagnóstico ortodóncico, existe esta nueva tendencia de realizar nuevos estudios ahora en CBCT ya que los cortes tomográficos proporcionan datos con valores exactos sin tener que lidiar con la distorción de las sobreimposiciones que ofrecen por ejemplo las imágenes 2D de rayos X como las radiografías laterales o panóramicas. En el estudio de Dong, W., et al., el porcentaje de exactitud (91.20%) fue muy similiar al que se alcanzó en este estudio (91.28%), sin embargo, cabe recalcar que a pesar de que ambos estudios se realizaron con CBCT, este estudio evalua tres factores más además de la hipertrofia adenoidea los cuales son: hipertrofia de cornetes, tabique desviado y vía

aérea superior estrecha. Citando textualmente a Dong, W., et al., “En el diagnóstico y el tratamiento de la Apnea Obstructiva del Sueño a menudo deben tenerse en cuenta diversos factores, nuestro modelo de aprendizaje profundo solo tiene en cuenta 1 factor (HA) debido a las limitaciones de la tecnología y los conjuntos de datos, lo que puede llevar a un juicio erróneo” (67). Esto coloca a este estudio en la obtención de un modelo sumamente completo evaluando más de 1 factor predisponente a respiración bucal y por lo tanto haciéndolo un excelente método diagnóstico para la detección temprana de la respiración bucal y la Apnea Obstructiva del Sueño, así como de sus múltiples secuelas como lo son las alteraciones en el desarrollo craneofacial. Sobre todo en términos clínicos, es crucial preescribir un adecuado tratamiento multidisciplinario, en el cuál el ortodoncista tiene un rol fundamental, ya que al saber exactamente en que área anátomica se encuentra la obstrucción puede implementar el tratamiento indicado para mejorar esa obstrucción especifica, como por ejemplo, ante una obstrucción provocada por tabiquete desviado y/o hipertrofia de cornetes, la expansión maxilar asistida por mini implantes es uno de los tratamientos de elección o coadyuvantes que mejoran esa obstrucción, o bien el avance mandibular asistido por un dispositivo de reposicionamiento mandibular, que es uno de los tratamientos de elección o coadyuvantes cuando la obstrución es provocada por una hipertrofia adenoidea o por una vía aérea estrecha.

11. CONCLUSIONES

Las Redes Neuronales Convolucionales (EfficientNet, VGG16, VGG19, ResNet y LeNet) permiten detectar los factores predisponentes a respiración bucal a partir de CBCT.

Los niveles de exactitud alcanzados por las Redes Neuronales Convolucionales evaluadas, especialmente EfficientNet, indican su alto potencial como una herramienta de apoyo valiosa en el proceso diagnóstico del ortodoncista.

La integración de herramientas como lo son las Redes Neuronales Convolucionales en la práctica clínica ha demostrado que podría facilitar la identificación y permitir intervenciones tempranas en casos predisponentes a respiración bucal.

12. BIBLIOGRAFÍA

1. Proffit WR, Fields HW, Sarver DM. *Contemporary orthodontics*. 6th edition. Alabama. Elsevier/Mosby; 2013.
2. Guilleminault C, Ji B, Lee H, Chan A. Pediatric obstructive sleep apnea syndrome. Arch Pediatr Adolesc Med. 2005;159(8):775–85.
3. Viejo Bañuelos JL. Infecciones agudas de la vía aérea superior. Neumol Clin. 2010;2:271–8.
4. Ferré A, Vila J, Arcalís N. Utilidad de la exploración básica de la vía aérea superior y estructuras vecinas en los pacientes adultos con síndrome de apnea-hipopnea obstructiva del sueño. *Med Clin (Barc)*. 2014;142(7):310–6.
5. Zhao T, Zhou J, Yan J, Cao L, Cao Y, Hua F, et al. Automated adenoid hypertrophy assessment with lateral cephalometry in children based on artificial intelligence. *Diagnostics*. 2021; 11(8): 12-6.
6. Wang H. Chronic adenoiditis. *J Int Med Res*. 2020;48(12): 300-5.
7. Katyal V, Pamula Y, Martin AJ, Daynes CN, Kennedy JD, Sampson WJ. Craniofacial and upper airway morphology in pediatric sleep-disordered breathing: Systematic review and meta-analysis. *Am J Orthod Dentofacial Orthop*. 2013;143(1):775-785.
8. Zhao T, Ngan P, Hua F, Zheng J, Zhou S, Zhang M, et al. Impact of pediatric obstructive sleep apnea on the development of Class II hyperdivergent patients receiving orthodontic treatment: A pilot study. *Angle Orthod*. 2018;88(5):560–6.
9. Caboot J, Chan J, Currie M, Healy F, Josephson M, Konstantinopoulou S, et al. Diagnosis and Management of Childhood Obstructive Sleep Apnea Syndrome. *Pediatrics*. 2012;130(3):e714–26.
10. Smith T, Ghoneima A, Stewart K, Liu S, Eckert G, Halum S, et al. Three-dimensional computed tomography analysis of airway volume changes after rapid maxillary expansion. *Am J Orthod Dentofacial Orthop*. 2012;141(5):618–26.
11. Major MP, Flores-Mir C, Major PW. Assessment of lateral cephalometric diagnosis of adenoid hypertrophy and posterior upper airway obstruction: A systematic review. *Am J Orthod Dentofacial Orthop*. 2006;130:700–8.
12. Vilaza I, Araya-Díaz P, Palomino HM. Two-dimensional and Three-dimensional Assessment of the Upper Airway. *Int J Morphol*. 2017;357-362.
13. Thakkar K, Yao M. Diagnostic Studies in Obstructive Sleep Apnea. *Otolaryngol Clin North Am*. 2007;40:785–805.
14. Lionel Young MW, Girdany BR. Radiographic Evaluation of Adenoidal Size in Children: Adenoidal-Nasopharyngeal Ratio. AJR. 1979; 401-404.
15. Leonardi R, Lo Giudice A, Farronato M, Ronsivalle V, Allegrini S, Musumeci G, et al. Fully automatic segmentation of sinonasal cavity and pharyngeal airway based on convolutional neural networks. *Am J Orthod Dentofacial Orthop*. 2021;159(6):824–35.
16. Liu JL, Li SH, Cai YM, Lan DP, Lu YF, Liao W, et al. Automated Radiographic Evaluation of Adenoid Hypertrophy Based on VGG-Lite. *J Dent Res*. 2021;100(12):1337–43.
17. Berman LH, Hargreaves KM, Rotstein I. *Cohen's pathways of the pulp*. 12th ed. St. Louis Missouri. Elsevier. 2021.

18. Association for Computing Machinery. Proceedings of the 26th ACM International Conference on Information and Knowledge Management (CIKM '17); 2017 Nov 6–10; Singapore. New York (NY): ACM; 2017. 2572 p.
19. Snyder TL. Integrating Technology into Dental Practices. *J Am Dent Assoc*. 1995;126(2):171–8.
20. Acorn TL, Walden SH. SMART: Support management automated reasoning technology for Compaq customer service. In: Proceedings of the 4th Innovative Applications of Artificial Intelligence Conference (IAAI); 1992 Jul; San Jose, CA. Menlo Park (CA): AAAI Press; 1992. p. 172–178.
21. Zhao T, Zhou J, Yan J, Cao L, Cao Y, Hua F, et al. Automated adenoid hypertrophy assessment with lateral cephalometry in children based on artificial intelligence. *Diagnostics*. 2021; 11(8):1386.
22. Nilsson NJ. Introduction to machine learning. [Internet]. 2nd ed. Stanford (CA): Stanford University; 1998 [citado 15 Mayo 2025]. disponible en: https://cs.stanford.edu/people/nilsson/mlbook.html
23. Monill-González A, Rovira-Calatayud L, d'Oliveira NG, Ustrell-Torrent JM. Artificial intelligence in orthodontics: Where are we now? A scoping review. *Orthod Craniofac Res*. 2021;24:6–15.
24. LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521(7553):436–44.
25. Yang J, Zhao J, Lu L, Pan T, Jubair S. A New Improved Learning Algorithm for Convolutional Neural Networks. Processes. 2020; 1(8); 295.
26. Li P, Kong D, Tang T, Su D, Yang P, Wang H, et al. Orthodontic Treatment Planning based on Artificial Neural Networks. *Sci Rep*. 2019;9-1.
27. Yu HJ, Cho SR, Kim MJ, Kim WH, Kim JW, Choi J. Automated Skeletal Classification with Lateral Cephalometry Based on Artificial Intelligence. *J Dent Res*. 2020;99(3):249–56.
28. Schwendicke F, Chaurasia A, Arsiwala L, Lee JH, Elhennawy K, Jost-Brinkmann PG, et al. Deep learning for cephalometric landmark detection: systematic review and meta-analysis. *Clin Oral Investig*. 2021;25:4299–309.
29. Shujaat S, Jazil O, Willems H, Van Gerven A, Shaheen E, Politis C, et al. Automatic segmentation of the pharyngeal airway space with convolutional neural network. J Dent. 2021;111:103705.
30. Park J, Hwang J, Ryu J, Nam I, Kim SA, Cho BH, et al. Deep learning based airway segmentation using key point prediction. Appl Sci. 2021;11(8):3501.
31. Orhan K, Shamshiev M, Ezhov M, Elnagger A, Tsurumachi T, Jacobs R, et al. AI-based automatic segmentation of craniomaxillofacial anatomy from CBCT scans for automatic detection of pharyngeal airway evaluations in OSA patients. Sci Rep. 2022;12:11863.
32. Dot G, Rafflenbeul F, Arbotto M, Gajny L, Rouch P, Schouman T, et al. Automatic 3-Dimensional Cephalometric Landmarking via Deep Learning. *J Dent Res*. 2022;101(11):1380–7.
33. LeCun Y, Bengio Y, Hinton G. Deep learning. Nature. 2015;521(7553):436–44.
34. LeCun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. Proc IEEE. 1998;86(11):2278–324.
35. He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR); 2016 Jun 27–30; Las Vegas, NV. Piscataway (NJ): IEEE; 2016. p. 770–778.

36. Harahap FAA. Performance Comparison of VGG16, VGG19 and Alexnet Pre-Trained Transfer Learning Architecture Models in the Convolutional Neural Network Algorithm in Classification of Lung Disease. J Inform Data Sci. 2023;3(1):1–10.
37. Marques G, Agarwal D, de la Torre Díez I, Romero CA, García-Zapirain B, López-Coronado M, et al. Automated medical diagnosis of COVID-19 through EfficientNet convolutional neural network. Biomed Signal Process Control. 2021;68:102587.
38. National Institutes of Health (NIH). Protección de los participantes humanos de la investigación. Bethesda (MD): NIH; 2008.
39. Major MP, Witmans M, El-Hakim H, Major PW, Flores-Mir C. Agreement between cone-beam computed tomography and nasoendoscopy evaluations of adenoid hypertrophy. Am J Orthod Dentofacial Orthop. 2014;146(4):451–9.
40. Jha A, Ghimire P, Shrestha S. Radiological Evaluation of Inferior Turbinate in Patients with Deviated Nasal Septum using Computed Tomography. Nepalese Journal of Radiology. 2020;10:16–21.
41. Shetty SR, Al Bayatti SW, Al-Rawi NH, Marei H, Reddy S, Abdelmagyd HA, et al. Analysis of inferior nasal turbinate width and concha bullosa in subjects with nasal septum deviation: a cone beam tomography study. BMC Oral Health. 2021;21(1):206.
42. Momany SM, AlJamal GA, Shugaa-Addin B, Khader YS. Cone Beam Computed Tomography Analysis of Upper Airway Measurements in Patients With Obstructive Sleep Apnea. Am J Med Sci. 2016;352(4):376–384.
43. Zhang JN, Lu HP, Hou J, Wang Q, Yu FY, et al. Deep learning-based prediction of mandibular growth trend in children with anterior crossbite using cephalometric radiographs. BMC Oral Health. 2023;23(1):28.
44. Li H, Xu Y, Lei Y, Wang Q, Gao X. Automatic Classification for Sagittal Craniofacial Patterns Based on Different Convolutional Neural Networks. Diagnostics. 2022;12(6):1359.
45. Vasdev D, Gupta V, Shubham S, Chaudhary A, Jain N, Salimi M, et al. Periapical dental X-ray image classification using deep neural networks. Ann Oper Res. 2022;1–29.
46. Bakırarar B, Yılmaz Işıkhan S. A new class-weighting formulation for the class imbalance problem: a methodological research. Turk Klin J Biostat. 2023;15(2):79–90.
47. Sun Y, Wong AKC, Kamel MS. Classification of imbalanced data: a review. Int J Pattern Recognit Artif Intell. 2009;23(4):687–719.
48. Gu J, Wang Z, Kuen J, Ma L, Shahroudy A, Shuai B, et al. Recent advances in convolutional neural networks. Pattern Recognition. 2018;77:354–377.
49. De Menezes VA, Leal RB, Pessoa RS, Lima KC, Paranhos LR. Influence of mouth breathing on craniofacial development. *J Bras Pneumol*. 2023;49(3):e20220249.
50. Milanesi JM, Berwig LC, Marquezan M. Variables associated with mouth breathing diagnosis in children based on a multidisciplinary assessment. *J Pediatr (Rio J)*. 2018;94(2):162–8.
51. Abreu RR, Rocha RL, Lamounier JA, Guerra ÂF. Etiology, clinical manifestations and concurrent findings in mouth-breathing children. *J Pediatr (Rio J)*. 2008;84(6):529–35.

52. Marcus CL, Brooks LJ, Draper KA, Gozal D, Halbower AC, Jones J, et al. Diagnosis and management of childhood obstructive sleep apnea syndrome. *Pediatrics*. 2012;130(3):e714–55.
53. Huang YS, Guilleminault C. Pediatric obstructive sleep apnea and the critical role of oral-facial growth: evidences. Front Neurol. 2012;3:184.
54. Shujaat S, Jazil O, Willems H, Van Gerven A, Shaheen E, Politis C, et al. Automatic segmentation of the pharyngeal airway space with convolutional neural network. *J Dent*. 2021;111:103705.
55. Hwang JJ, Jung YH, Cho BH, Heo MS. An overview of deep learning in the field ofdentistry. *Imaging Sci Dent*. 2019;49(1):1–7.
56. Neelapu BC, Kharbanda OP, Sardana V, Gupta A, Vasamsetti S, Balachandran R, et al. A pilot study for segmentation of pharyngeal and sino-nasal airway subregions by automatic contour initialization. *Int J Comput Assist Radiol Surg*. 2017;12(11):1877–93.
57. Yadollahi A, Moussavi Z. Automatic breath and snore sounds classification from tracheal and ambient sounds recordings. Med Eng Phys. 2010;32(9):985–990.
58. Jácome C, Ravn J, Holsbo E, Aviles-Solis JC, Melbye H, Bongo LA. Convolutional neural network for breathing phase detection in lung sounds. Sensors (Basel). 2019;19(8):1798.
59. Acharya J, Basu A. Deep neural network for respiratory sound classification in wearable devices enabled by patient specific model tuning. IEEE Trans Biomed Circuits Syst. 2020;14(3):535–544.
60. Liu JL, Li SH, Cai YM, Lan DP, Lu YF, Liao W, et al. Evaluación radiográfica automatizada de la hipertrofia adenoidea basada en VGG-Lite. J Dent Res. 2021;100(12):1337–1343.
61. Shorten C, Khoshgoftaar TM. A survey on image data augmentation for deep learning. J Big Data. 2019;6:60.
62. Zhao T, Zhou J, Yan J, Cao L, Cao Y, Hua F, et al. Automated adenoid hypertrophy assessment with lateral cephalometry in children based on artificial intelligence. Diagnostics (Basel). 2021;11(8):1386.
63. Shen Y, Li X, Liang X, Xu H, Li C, Yu Y, et al. A deep-learning-based approach for adenoid hypertrophy diagnosis. Med Phys. 2020;47: 2171-81.
64. Liu JL, Li SH, Cai YM, Lan DP, Lu YF, Liao W, et al. Automated radiographic evaluation of adenoid hypertrophy based on VGG-lite. J Dent Res. 2021;100:1337-43.
65. Leonardi R, Lo Giudice A, Farronato M, Ronsivalle V, Allegrini S, Musumeci G, et al. Fully automatic segmentation of sinonasal cavity and pharyngeal airway based on convolutional neural networks. *Am J Orthod Dentofacial Orthop*. 2021. 1;159(6):824–35.e1.
66. Mini, A.H.I., Wegner, H., Lonic, D. et al. Cone beam computed tomography based upper airway measurement after orthognathic surgery: a comparative evaluation of different imaging software. Sci Rep 15, 6638 (2025).
67. Dong W, Chen Y, Li A, Mei X, Yang Y. Automatic detection of adenoid hypertrophy on cone-beam computed tomography based on deep learning. Am J Orthod Dentofacial Orthop. 2023;163(4):553–560.e3.

12. ANEXOS

INSTITUTO DE ENSEÑANZA
ESTOMATOLÓGICA
Otorga este
RECONOCIMIENTO
ACADÉMICO
al Dr. Oscar Hernandez Ruiz
Por haber completado el
Programa Calibración VAS y Adenoides,
impartida por la Dra. María Isabel Pizano Damasco
en el mes de Marzo de 2024.
Ma. Isabel Pizano Damasco
Directora Académica
Isabel Bermúdez Pizano
Directora Administrativa

Emtech Institute & Santander Open Academy
Otorga la siguiente constancia a
Oscar Hernandez
Por haber completado satisfactoriamente el programa
Introducción a las Tecnologías Emergentes: Edición 2024
Edición 2024
Santander | Open Academy
Emtech INSTITUTE
Issued: 2024-04-07
Certificate ID: ovpdrcl8ec