

BENEMÉRITA UNIVERSIDAD AUTÓNOMA DE PUEBLA



FACULTAD DE ESTOMATOLOGÍA

SECRETARÍA DE INVESTIGACIÓN Y ESTUDIOS DE POSGRADO

MAESTRÍA EN ESTOMATOLOGÍA CON TERMINAL EN ORTODONCIA

“CLASIFICACIÓN DE LA APERTURA DE LA VÍA AÉREA SUPERIOR A PARTIR DE LA RADIOGRAFÍA LATERAL DE CRÁNEO CON REDES NEURONALES CONVOLUCIONALES”

TESIS PARA OBTENER EL GRADO DE MAESTRA EN ESTOMATOLOGÍA CON OPCIÓN TERMINAL EN ORTODONCIA

PRESENTA:

C.D. María Paola Romero Navarro
ID: 222450008

DIRECTOR DE TESIS:

Dr. Miguel Angel Casillas Santana
ID: 100526485

DIRECTOR METODOLÓGICO:

M.O. Estela del Carmen Velásco León
ID: 100225455

DIRECTOR DISCIPLINARIO:

M.O. Yareli Hernández Ávila
ID: 100426099

ASESOR EXTERNO:

Dr. Elías Jesús Ventura Molina

LECTOR:

Dr. Víctor Hernández Vidal
ID: 10037883

Puebla de Zaragoza, Puebla, mayo 2024

I.Dictamen de aprobación de tesis



Oficio No. FESIEP/CIFE/035/2024

C. María Paola Romero Navarro
Estudiante de la Maestría en Estomatología
con opción en Terminal en Ortodoncia
Matrícula No.: 222450008
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, la que suscribe MEP. Gisela Nataly Rubin de Celis Quintana en mi calidad de Secretaría de Investigación y Estudios de Posgrado de la Facultad de Estomatología de la Benemérita Universidad Autónoma de Puebla; para comunicarle una noticia importante en relación con su proceso académico.

Con agrado, le informo que la Secretaría de Posgrado ha otorgado la aprobación para la impresión de su Tesis Titulada:
"Clasificación de la apertura de la vía aérea superior a partir de la radiografía lateral de cráneo con redes neuronales convolucionales."

Esta tesis está inscrita en el libro de registros No. 09, página 01, con el No. de asignación 2024240, en la Secretaría de Investigación de esta Unidad Académica. Usted presentará esta tesis para realizar su examen profesional y así obtener el grado de Maestría en Estomatología con opción en Terminal en Ortodoncia.

La aprobación de la impresión de su tesis represente un hito significativo en su trayectoria académica y profesional. Es el reflejo de su arduo trabajo, dedicación y la profundidad de su investigación en el campo de la Estomatología.

Le insto a que proceda con los pasos necesarios para la impresión y presentación de Tesis, cumpliendo con todas las normativas y plazos establecidos por la Facultad. Esto incluye la revisión final de su documento, asegurándose de que desempeñe todos los requisitos académicos y formatos establecidos, así como la coordinación con la Secretaría para la programación de su examen profesional.

Para cualquier consulta, aclaración o información adicional, le invito a contactar directamente a este Posgrado, estamos aquí para asistirlo en cada paso restante de su proceso académico.

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

Atentamente

"Pensar bien, para vivir mejor"

H. Puebla de Z., a miércoles 22 de mayo del 2024

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

*Nota: Se anexa Formato de Impresión de Tesis - C. María Paola Romero Navarro - Maestría en Estomatología con opción en 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/ymeth

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: **Maestro(a) en Estomatología con opción terminal en Ortodoncia**

No. de Registro CIFE: 2024240 **Fecha de Registro ante CIFE:** lunes 29 de enero del 2024.

Título de la Tesis: "Clasificación de la apertura de la vía aérea superior a partir de la radiografía lateral de cráneo con redes neuronales convolucionales"

Nombre del alumno: María Paola Romero Navarro.

Matrícula: 222450008.

Domicilio: Toweke 8123, Col. Santa fe, Ciudad Juárez, Chihuahua.

Tel: 65*63 01 21 13.

Fecha de ingreso a la Facultad: lunes 03 de enero del 2022.

Firma: _____

Director de Tesis: DC. Miguel Ángel Casillas Santana.

Grado académico: Doctor en Ciencias Estomatológicas.

Adscripción: Facultad de Estomatología.

ID: 100526485.

Tel: 44*48 46 76 45.

Firma: _____

Director Disciplinario: MO. Yareli Hernández Ávila.

Grado académico: Maestría en Ortodoncia.

Adscripción: Facultad de Estomatología.

ID: 100426099.

Tel: 22*21 99 20 62.

Firma: _____

Director Metodológico: MO. Estela del Carmen Velásco León.

Grado académico: Maestría en Ortodoncia.

Adscripción: Facultad de Estomatología.

ID: 100225455.

Tel: 22*23 23 48 42.

Firma: _____

Lector: MO. Víctor Hernández Vidal.

Grado académico: Maestría en Ortodoncia.

Adscripción: Facultad de Estomatología.

ID: 100378833

Tel: 22 21 74 19 16.

Firma: _____

Nombre y firma de aprobación del responsable de la Maestría en Estomatología con opción Terminal en Ortodoncia

M.O Farid Dipp Velázquez

Firma: _____

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

MEP. Gisela Natally Rubin de Celis Quintana



Fecha actual: miércoles 22 de mayo del 2024.

Sello _____

III. Oficio de aceptación de proyecto C.I.F.E.



Constancia No. FESIEP/CIFE/013/2024

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

Sinva este medio para enviarle un cordial saludo, asimismo la que suscribe MEP. Gisela Nataly Rubin de Celis Quintana en mi calidad de Secretaria de Investigación y Estudios de Posgrado de la Facultad de Estomatología de la Benemérita Universidad Autónoma de Puebla, y tras un detenido análisis y evaluación en el Proyecto de Investigación (Colectivo):

Nombre del Título del Proyecto:

"Clasificación de la apertura de la vía aérea superior a partir de la radiografía lateral de cráneo con redes neuronales convolucionales"

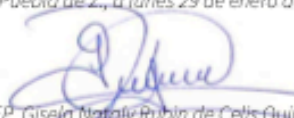
Presentado por:

No.	Cargos	Nombres	ID y/o Matrícula
1	Responsable del Proyecto de Investigación:	DC. Miguel Ángel Casillas Santana	100526485
2	Directora Metodológica:	MD. Estefo del Carmen Velasco León	100225455
3	Directora Disciplinaria:	MD. Yanelli Hernández Avila	100426098
4	Asesor Externo:	DCC. Elías Ventura Molina Instituto Politécnico Nacional	S/N
5	Estudiante de Maestría en Estomatología: <u>Terminal en Ortodoncia</u>	C. María Paola Rogero Navarro	222450008

HAGO CONSTAR, que, ha sido oficialmente ACEPTADO. Este relevante proyecto, ha sido registrado ante el Comité de Investigación de la Facultad de Estomatología (C.I.F.E.), inscrita en el libro de registros No. 03, página 01, bajo el No. de asignación 2024240, en la Secretaría de Investigación de esta Unidad Académica.

Para los fines legales que los interesados convengan, y sin otro particular, reitero a Usted mi más atenta y distinguida consideración.

Atentamente
"Pensar bien, para vivir mejor"
H. Puebla de Z., a Junes 29 de enero del 2024


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



*C.p. Archivo
*MCO, FMM/MEP, GURCO/Yarelli

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

Paola

ORIGINALITY REPORT



PRIMARY SOURCES

1	Submitted to BENEMERITA UNIVERSIDAD AUTONOMA DE PUEBLA BIBLIOTECA Student Paper	2%
2	hdl.handle.net Internet Source	1%
3	www.schoolandcollegelistings.com Internet Source	1%
4	www.researchgate.net Internet Source	1%
5	eprints.uanl.mx Internet Source	1%
6	1library.co Internet Source	<1%
7	repositorio.urp.edu.pe Internet Source	<1%
8	docs.bvsalud.org Internet Source	<1%
9	upc.aws.openrepository.com Internet Source	<1%



Universidad Autónoma de Zacatecas
 Unidad Académica de Odontología
 Sociedad Nacional de Investigadores en Odontología, A. C.

OTORGAN EL PRESENTE
RECONOCIMIENTO A

María Paola Romero Navarro, Elías Ventura Molina, Miguel A. Casillas Santana, Mayra Daniela Carrera González, Marco Felipe Salas Orozco, Yareli Hernández Ávila

PRIMER LUGAR CATEGORÍA MAESTRIA AREA BÁSICA MODALIDAD CARTEL

CLASIFICACIÓN DE LA VÍA AÉREA SUPERIOR CON RADIOGRAFÍA LATERAL DE CRÁNEO: REDES NEURONALES PROFUNDAS

**XXXI Encuentro Nacional y XXII Iberoamericano de Investigación en Odontología
 y X Jornadas Internacionales de Investigación en Odontología UAO**
 Efectuado los días, 8, 9 y 10 de noviembre de 2023

Dr. Rubén de Jesús Ibarra Reyes
 Rector Universidad
 Autónoma de Zacatecas

Dr. Amaury de Jesús Pozos Guillén
 Presidente de la Sociedad Nacional
 de Investigadores en Odontología, A.C.

Dra. Leticia Rodríguez Villalobos
 Directora de la Unidad Académica
 de Odontología UAZ

VI. Agradecimientos

Quiero agradecer a Dios por darme la oportunidad de cumplir un sueño, darme la fortaleza y sabiduría de tomar decisiones. A mis padres René y Lulú, sin duda estoy aquí gracias a ustedes, gracias por su amor y apoyo incondicional, por brindarme la oportunidad de cumplir mis sueños a lo largo de mi vida, son mi ejemplo a seguir, espero que Dios me permita regresarles al menos un poco de todo lo que me han dado con tanto amor y esfuerzo. A mis hermanos, Pedro y Ana, por apoyarme en mis decisiones, son una gran ejemplo a seguir, gracias por las risas, cariño y apoyo a distancia. Gracias a toda mi familia, tías, tíos, primos, en especial a mi primo Lalito, mi prima Gaby, mis cuñados Miriam e Irvin que siempre creyeron en mí, que a distancia siempre se preocuparon por mí y me apoyaron.

Agradezco a mi familia que conocí durante este camino, Beki, May, Yuri y Omar, no hay manera de describir lo que siento, son mis hermanos, fueron mi fortaleza durante todo este proceso. Se llevan una parte de mi corazón, me quedo con lo mejor de ustedes, gracias por todos los malos y buenos momentos vividos, las risas, las desveladas, los viajes y congresos que pasamos, son increíbles, estoy segura que van a lograr todo lo que se proponen.

Agradezco a mi comité, Dr. Casillas, por su apoyo a lo largo de este camino, por nunca soltarme y corregirme las veces necesarias, gracias por sus consejos y paciencia. A la Dra. Yareli y Dra. Carmen, gracias por siempre estar al pendiente de este proyecto y aportar con sus ideas, pero más allá de formar parte de esta tesis, gracias por sus enseñanzas de cada día. Al Dr. Elías, le agradezco por sus grandes enseñanzas en este campo completamente nuevo para mí, por su dedicación, tiempo y esfuerzo, que puso en este proyecto, sin duda no se hubiera logrado sin su apoyo. A la Dra. María Pizano por compartir sus conocimientos y dedicar parte de su tiempo a este proyecto. A mi compañero Oscar que somos los primeros aprendiendo y conociendo de este tema, hemos hecho un buen equipo, gracias por todo tu apoyo.

Agradezco a mi coordinadora, Dra. Moni, por ser un pilar en nuestra formación durante posgrado, por siempre estar al pendiente de nosotros, brindarnos su apoyo, enseñanza, paciencia y cariño. A todos los docentes que formaron parte de nuestra formación, gracias por siempre dar su mayor esfuerzo, por sus correcciones, por sus ejemplos y enseñanzas. Al Dr. Farid por impulsarnos a sacar lo mejor de nosotros.

A mis amigas Carolina, Andrea, Steph, Myrnita, Mariana y Paola, y Martín que siempre creyeron en mí, que a pesar de la distancia se hicieron presentes en este proceso, gracias por su apoyo y amistad. A.

VII. ÍNDICE GENERAL

<i>V. Evidencia de productos académicos derivados del proyecto</i>	7
RESUMEN	14
PALABRAS CLAVE	14
INTRODUCCIÓN	15
ANTECEDENTES	16
3.1 ANTECEDENTES GENERALES	16
3.2 ANTECEDENTES ESPECÍFICOS.....	21
PLANTEAMIENTO DEL PROBLEMA Y PREGUNTA DE INVESTIGACIÓN	23
4.1 PREGUNTA DE INVESTIGACIÓN	24
JUSTIFICACIÓN	24
HIPÓTESIS	25
6.1 Hipótesis científica	25
6.2 Hipótesis nula	25
OBJETIVOS	25
7.1 Objetivo general	25
7.2 Objetivos específicos.....	25
MATERIALES Y MÉTODOS	25
8.1 REDES NEURONALES CONVOLUCIONALES	26
8.2 DISEÑO DEL ESTUDIO	27
8.3 POBLACIÓN Y MUESTRA.....	27
8.4 CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN.....	28
8.5 TABLA DE DEFINICIÓN Y MEDICIÓN DE VARIABLES	29
8.6 CONCORDANCIA Y FIABILIDAD	30
8.7 UBICACIÓN ESPACIO-TEMPORAL.....	30
8.8 ASPECTOS ÉTICOS	30
8.9 PROCEDIMIENTOS, TÉCNICAS Y FUENTES DE RECOLECCIÓN.....	31
8.9.1 PRIMERA ETAPA - PRUEBA PILOTO	31
8.9.2 SEGUNDA ETAPA – “Data Augmentation”	33
8.9.3 TERCERA ETAPA – “Prueba experimental”	36
8.9.4 Cuantificación de los resultados obtenidos por la red neuronal convolucional	39
8.10 ANÁLISIS ESTADÍSTICO	40
RESULTADOS	41
9.1 Primera etapa - Prueba piloto	41

9.2 Segunda etapa – “Aumento de datos”	42
9.3 Tercera etapa – Prueba experimental.....	42
DISCUSIÓN	45
CONCLUSIONES	50
BIBLIOGRAFÍA	51
PRODUCCIÓN ACADÉMICA	<i>Error! Bookmark not defined.</i>
ANEXOS	57

VIII. Índice de tablas y figuras

Figura 1	17
Figura 2	19
Figura 3	20
Tabla 1	29
Figura 4	35
Tabla 2	37
Figura 5	38
Tabla 3	41
Tabla 4	42
Tabla 5	43
Tabla 6	43
Tabla 7	43
Tabla 8	44

IX. Abreviaturas

ANN. Artificial Neural Network (Red Neuronal artificial)

ATM. Articulación temporomandibular

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

CNN. Convolutional Neural Network (Red neuronal convolucional)

CNNs. Convolutional Neural Networks (Redes neuronales convolucionales)

DL. Deep Learning (Aprendizaje profundo)

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

FN. False Negative (Falso negativo)

FP. False Positive (Falso positivo)

IA. Inteligencia artificial

IRM. Imagen por Resonancia Magnética

ML. Machine Learning (Aprendizaje Automático)

SAHOS. Síndrome de Apnea o hipoapnea obstructiva del sueño

SAO. Síndrome de apnea obstructiva

TC. Tomografía Computarizada

TN. True negative (verdadero negativo)

TP. True positive (verdadero positivo)

“Clasificación de la vía aérea superior a partir de la radiografía lateral de cráneo con redes neuronales convolucionales”

RESUMEN

Introducción: La ortodoncia, una rama de la odontología, se dedica a corregir las maloclusiones dentarias mediante la aplicación de fuerzas a través de dispositivos ortodóncicos. El diagnóstico desempeña un papel fundamental en la formulación del plan de tratamiento para cada paciente. En este campo, se emplean una variedad de herramientas de diagnóstico, incluyendo radiografías, CBCT, trazados cefalométricos, modelos de estudio y fotografías intraorales y extraorales. Una de las herramientas más comunes y aún ampliamente utilizada es la radiografía lateral de cráneo, la cual permite identificar anomalías y discrepancias tanto en las estructuras óseas como en los tejidos blandos, como la vía aérea superior. El análisis de la vía aérea superior es fundamental para desarrollar un plan de tratamiento integral y alcanzar el éxito a largo plazo. Sin embargo, debido a la complejidad de detectar los tejidos blandos en las radiografías laterales de cráneo, se han buscado nuevas herramientas para su detección. En los últimos años se ha implementado el uso de Inteligencia Artificial (IA) en la odontología, con la finalidad de clasificar y/o reconocer imágenes, facilitando los procesos de diagnóstico para el odontólogo. Las redes neuronales convolucionales son parte de la IA, las cuáles son entrenadas para reconocer y clasificar imágenes con grandes porcentajes de exactitud. **Objetivo:** Clasificar la apertura de la vía aérea superior con el uso de las redes neuronales convolucionales a partir de una base de datos de radiografías laterales de cráneo. **Materiales y métodos:** 200 radiografías laterales de cráneo con vía aérea abierta y 200 radiografías laterales de cráneo con la vía aérea obstruida previamente clasificadas, se realizó la partición de datos; 60% de las radiografías para el entrenamiento de la CNN, 20% para la validación de la CNN y 20% para la fase de prueba y se evaluaron 3 diferentes tipos de Redes Neuronales Convolucionales; AlexNet, ResNet, VGG16. **Resultados:** Se obtuvo una exactitud de 88.97% con VGG16, 85.83% con ResNet, 83.82% con AlexNet. **Conclusión:** Las redes neuronales convolucionales demuestran ser una herramienta útil y eficaz para el reconocimiento y clasificación de las vías aéreas superiores la cual permite ser más exactos durante la fase de diagnóstico.

PALABRAS CLAVE

Vía aérea obstruida, radiografía lateral de cráneo, inteligencia artificial, redes neuronales convolucionales, análisis de imágenes.

INTRODUCCIÓN

La ortodoncia es una rama de la odontología que se encarga de corregir las maloclusiones dentarias, es decir, la mal posición de los huesos y los dientes mediante la aplicación de diferentes tipos de fuerzas con aparatos ortodóncicos. La ortodoncia nos permite tratar el apiñamiento dental y la incorrecta posición de los órganos dentarios con la finalidad de evitar problemas de higiene dental, periodontales y problemas de la articulación temporomandibular (ATM). Tiene el objetivo de contribuir al bienestar del paciente, al mejorar la función y la estética de sus dientes.

El diagnóstico es una parte fundamental para idear el plan de tratamiento del paciente, en la ortodoncia se implementan diversos auxiliares de diagnóstico; modelos de estudio, fotografías extraorales e intraorales, radiografía lateral de cráneo y tomografías. El uso de las herramientas auxiliares en la odontología ha permitido obtener diagnósticos más precisos y en ortodoncia, la implementación de la radiografía lateral de cráneo y tomografía permite obtener datos más allá de lo dental y esquelético, es decir, observar espacios de los tejidos blandos, lo cual permite complementar el diagnóstico y valorar la vía aérea superior a partir de medidas lineales para saber si se encuentra con o sin obstrucción.

La evaluación de las vías aéreas facilita determinar si existe obstrucción del espacio aéreo faríngeo el cual puede llegar a generar alteraciones en la respiración, se ha descrito que tiene un impacto significativo en el desarrollo de las estructuras craneofaciales. En ortodoncia, las alteraciones de la vía aérea superior deben ser evaluadas durante el diagnóstico, con la finalidad detectar alguna anomalía que deba ser atendida previo a un tratamiento ortodóncico. Con la radiografía lateral de cráneo o de la Cone Beam Computed Tomography (CBCT, por sus siglas en inglés) podemos obtener esta información, que permite completar el diagnóstico del paciente.

En los últimos años el diagnóstico ha sido auxiliado de nuevas tecnologías, como lo es la inteligencia artificial (IA), la cual ha permitido corroborar los datos y comprobar que es efectiva para auxiliarse durante el diagnóstico de un paciente.

Los avances en la tecnología han introducido diferentes aplicaciones que se encuentran dentro del área de la IA y sus derivados. La inteligencia artificial se refiere a la tecnología que se utiliza para desarrollar un software que pueda imitar la inteligencia humana y realizar tareas específicas. Las redes neuronales convolucionales son parte de la inteligencia artificial, consisten en un conjunto de algoritmos que calculan señales a través de neuronas artificiales, la capacidad de estas redes depende de la cantidad y calidad de imagen o datos que se le proporcione a la red, con la finalidad de que funcione como lo hace el cerebro humano. El uso de la inteligencia artificial se ha desarrollado en

las diferentes ramas de la odontología tales como: periodoncia, implantología, odontología forense, patología oral, diagnóstico/endodoncia y de interés para este trabajo, ortodoncia.

La inteligencia artificial ha demostrado ser útil en varias fases de la ortodoncia, desde el diagnóstico hasta crear el plan de tratamiento, la IA comprueba que puede reducir las posibilidades de error durante la fase de diagnóstico y con ellos poder tener mejor eficacia durante la ejecución del tratamiento ortodóncico.

Las redes neuronales convolucionales se han evaluado para la identificación y clasificación de imágenes, en este estudio fueron probadas para valorar su desempeño clasificando la vía aérea superior a partir de una radiografía lateral de cráneo.

ANTECEDENTES

3.1 ANTECEDENTES GENERALES

Los tratamientos de ortodoncia buscan corregir las anomalías dentofaciales y esqueléticas, las cuales se clasifican en Clase I, II y III; son determinadas por el tamaño, posición, forma de los maxilares y su relación entre ellos. En la clase I podemos encontrar una buena relación interoclusal y tamaños proporcionados del maxilar con respecto a la mandíbula, por otro lado, en la Clase II y III no hay proporción de los maxilares en un sentido antero-posterior y vertical debido a la malposición que pueda tener la mandíbula (1).

El diagnóstico en ortodoncia incluye; análisis cefalométricos a partir de la radiografía lateral de cráneo donde se realizan mediciones para determinar el desarrollo y patrones de crecimiento de los maxilares. Hay varios análisis que nos permiten ver el tipo de crecimiento óseo que va presentando el paciente, así como también podemos observar los tejidos blandos, por ejemplo, el espacio orofaríngeo (2). Existen muchas otras herramientas que se aplican para evaluar la obstrucción de las vías aéreas superiores, incluida la tomografía computarizada (TC), la fluoroscopia, la resonancia magnética (IRM) y la faringoscopia de fibra óptica; la radiografía lateral sigue siendo excelente auxiliar en clínicas dentales, ya que es una técnica barata y fácilmente disponible con menos radiación y cierto valor diagnóstico (3).

El espacio orofaríngeo consiste en una región anatómica que va desde el paladar blando hasta el hueso hioides que incluye el tercio posterior de la lengua (4). Es de importancia debido a la fonación y respiración. En esta zona podemos obtener la dimensión del espacio aéreo faríngeo; se extiende desde la base de cráneo al nivel del

paladar duro, es importante conocer por la relación con la morfología de la mandíbula ya que si presenta una reducción de ese espacio la respiración nasal se vuelve difícil (5). Los estudios han demostrado que esta obstrucción se asocia con una maloclusión Clase II, debido al patrón de crecimiento vertical el paciente se convierte en un respirador bucal (6).

En 1984, McNamara realizó un análisis basado principalmente en medidas lineales y no angulares, en las cuales se relacionan básicamente el maxilar con la base de cráneo, el incisivo superior con el maxilar, incisivo inferior con mandíbula e incorporan el análisis del tracto respiratorio a nivel de la nasofaringe y orofaringe. McNamara refiere el espacio nasofaríngeo con una medida lineal trazada desde un punto en el contorno del paladar blando hasta el más cercano con la pared posterior de la faringe, mientras que el espacio orofaríngeo se mide desde la intersección del borde posterior de la lengua con el borde inferior de la mandíbula, hasta el punto más cercano en la pared posterior de la faringe, a nivel de las amígdalas faríngeas (7).

McNamara establece una clasificación con valores promedio para adultos (hombres y mujeres): diámetro faríngeo superior (nasofaringe): 17.5 mm +/- 4 mm, diámetro faríngeo inferior (orofaringe): 11.3 mm (mujeres) y 13.5 (hombres) +/- 4 mm. Si tenemos una disminución en las medidas se puede sospechar de una posible obstrucción de las vías aéreas (Figura 1) (6).




Figura 1. Esquema de medición del espacio aéreo nasofaríngeo y orofaríngeo. Tomada de Quevedo y cols. (7).

La evaluación de las vías aéreas superiores ha sido de gran importancia para poder detectar y confirmar problemas respiratorios y/o el Síndrome de Apnea o hipoapnea obstructiva del sueño (SAHOS), la radiografía lateral de cráneo nos permite realizar la medición de esta vía, por lo tanto se ha convertido en una buena técnica complementaria en la detección de patología obstructiva de la vía aérea superior (8). El Síndrome de apnea obstructiva (SAO) es una condición relativamente común causada por la obstrucción de las vías aéreas superiores durante el sueño, los pacientes refieren síntomas como; somnolencia diurna y ronquidos (9). Al identificar una posible obstrucción respiratoria se contribuye a la toma de decisiones terapéuticas que incluyan la solución de este problema y no enfocarse solo a lo dental, si no también tener un abordaje hacia las vías aéreas. Medir la vía aérea basándose en esta clasificación puede presentar inconveniente debido a que en ocasiones es complicado encontrar las estructuras por la calidad de la imagen y desconocimiento de las estructuras. La clasificación tiene una alta desviación estándar de +/- 4 mm la cual representa un amplio rango para ambas clasificaciones (7).

Es importante tomar en cuenta estos factores debido a que el paciente con vías aéreas obstruidas presenta cambios faciales como; aumento del tercio inferior, cara estrecha y larga, falta de desarrollo en huesos de la nariz, ojeras profundas, boca abierta, incompetencia labial, hipertrofia del músculo borla del mentón, labio superior corto y labio inferior grueso, labios resecaos con presencia de fisuras en las comisuras (10). Así como características esqueléticas tales como: posteroposición de la mandíbula y maxilar, ángulo goniaco abierto, mordida abierta anterior asociada a una lengua grande, un plano mandibular inclinado, incisivos proinclinados y un plano oclusal inclinado (10).

Todas las herramientas utilizadas para lograr un mejor diagnóstico, llegan a ser más precisas y se obtienen con mayor facilidad gracias a la Inteligencia Artificial (IA), que hoy en día su uso se ha extendido a la odontología y sus diversas especialidades. La inteligencia artificial es la tecnología que utiliza máquinas para imitar las acciones que realiza el ser humano (11). Un subdominio de la IA, es el machine learning (ML) el cuál consiste en aprender patrones a partir de ciertos datos para eventualmente dar predicciones sobre datos que no se han visto antes. Apartir del ML se ha desarrollado el Deep Learning (DL) que es una técnica de aprendizaje automático que realiza operaciones matemáticas a través un sistema de multicapas para aprender y obtener datos de imágenes (12).

Las redes neuronales convoluciones (CNNs, por sus siglas en inglés) es un tipo de red neuronal artificial (ANN, por sus siglas en inglés) que consiste en una arquitectura de multicapas que se encargan de identificar objetos y clasificar imágenes (13). El modelo profundo de la red neuronal convolucional consiste en un conjunto finito de capas

de procesamiento que puede aprender ciertas características de la imagen de entrada. Las primeras capas aprenden y extraen de las imágenes las características de alto nivel, es decir, aquellas que tienen menos nivel de abstracción y posteriormente en las capas más profundas se extraen las características de bajo nivel, aquellas con mayor abstracción (14). Las redes neuronales convolucionales fueron introducidas hace más de 20 años con el desarrollo de la arquitectura de LeNet CNN. Desde un inicio las aplicaciones de las CNN fueron limitadas para resolver simples problemas, como el reconocimiento de dígitos hechos a mano, pero actualmente el enfoque de las CNN ha sido en la clasificación y segmentación de las imágenes y en la localización de objetos (15). Esto se ha dado debido a que hoy en día se obtiene mayor disponibilidad en cuanto a los recursos tecnológicos.

Las CNNs están diseñadas con cierto orden para ir procesando datos. Utiliza filtros para ir extrayendo información de las imágenes, es decir, las primeras capas se encargan de detectar bordes, otras capas pueden detectar objetos, y, capas aún más profundas pueden llegar a detectar objetos, caras y figuras más complejas (16). La CNN esta compuesta por un conjunto de capas que están agrupadas conforme a su función, las principales capas son: capa de convolución (convolutional layer), capa de agrupación (pooling layer) y capa completamente conectada (fully-connected layer) (17) como se muestra en la figura 2.




Figura 2. Estructura de las redes neuronales convolucionales y sus capas.
Tomado de Yang (18).

De las redes neuronales convolucionales se obtienen datos tales como exactitud, especificidad y sensibilidad, estos datos los obtenemos a partir de la matriz de confusión,

esta se utiliza para medir el desempeño del algoritmo. La matriz que aplica para este estudio es una matriz de confusión de 2x2 (Figura 3) (19). El algoritmo nos da los datos que resultaron de la fase de prueba; verdadero positivo (TP), verdadero negativo (TN), falso positivo (FP), falso negativo (FN), estos datos son cuantificados en la matriz de confusión donde se observa lo obtenido del algoritmo y los valores actuales, es decir, los valores que nosotros obtuvimos al inicio en la recolección de los datos (19).

		Predicción	
		Negativo (N) -	Positivo (P) +
Actual	Negativo -	Verdadero Negativo (TN)	Falso Positivo (FP)
	Positivo +	Falso Negativo (FN)	Verdadero Positivo (TP)

Figura 3. Matriz de confusión de 2x2.
Tomada de Suresh (20).

Se ha enfatizado el uso de IA en el sector salud como auxiliar para los profesionales como médicos y odontólogos durante el diagnóstico, tratamiento y predicción de enfermedades. En la odontología se ha implementado el uso de IA para auxiliar al clínico a identificar por medio de imágenes la detección de caries (21). En cuanto al ámbito ortodóncico la IA ha incrementado la precisión al momento de identificación de puntos cefalométricos en la radiografía lateral de cráneo, predicciones de tratamientos ortodóncicos y quirúrgicos, realizar evaluaciones de estadios de maduración vertebral e identificar vías aéreas (22).

Actualmente, se han utilizado múltiples programas donde se realiza el análisis cefalométrico a partir de una radiografía lateral de cráneo digital, el uso de las redes neuronales convolucionales con la clasificación de las vías aéreas podría complementarlo y generar un diagnóstico más rápido y preciso para el paciente (23).

3.2 ANTECEDENTES ESPECÍFICOS

La inteligencia artificial y sus respectivas ramas han sido utilizadas en diversos experimentos con el objetivo de favorecer el diagnóstico ortodóncico. Los estudios utilizan algún método de IA, ya sea redes neuronales artificiales o redes neuronales convolucionales (24). Por otra parte, la radiografía lateral de cráneo, además de ser utilizada para trazados cefalométricos, se utiliza para el análisis de maduración de las vértebras cervicales y análisis de vías aéreas, estos análisis nos permiten complementar el diagnóstico del paciente y así idear el plan de tratamiento con un abordaje más completo (25). Actualmente, solo existe un artículo que utilice una metodología similar a la propuesta en este trabajo (redes neuronales convolucionales), para clasificar la vía aérea a partir de la radiografía lateral de cráneo. En ese sentido, además de dicho artículo, se utilizan como evidencia indirecta todos aquellos estudios que han hecho uso de las redes neuronales convolucionales en el área ortodóncica.

Kim y cols., en el 2021, utilizaron la radiografía lateral de cráneo para evaluar el estadio de maduración de las vértebras cervicales con el propósito de estudiar modelos de deep learning que sean capaces de reconocer cada uno de los estadios. Propusieron un modelo basado en segmentación de las imágenes que se enfocara en las regiones de las C2-C4, realizaron tres modelos de redes neuronales convolucionales; uno para solo la clasificación del estadio de maduración de las vértebras cervicales, otro que realiza la detección y clasificación, y el último modelo iba enfocado hacia la detección, clasificación y segmentación de imágenes. Realizaron una base de datos de 600 radiografías laterales para ser analizadas y concluyeron que el modelo de tres pasos, (el que realiza detección, clasificación y segmentación de imágenes) fue el mejor, al tener una exactitud del 62.5% en comparación a los demás modelos (26).

Yao y cols., en el 2022, describieron como identificar los puntos cefalométricos en una radiografía lateral de cráneo, utilizaron 512 radiografías laterales de cráneo con sus respectivos puntos, y propusieron un nuevo sistema para la localización automática de los puntos con base en las redes neuronales convolucionales. 312 radiografías fueron utilizadas para el entrenamiento y aprendizaje de la red neuronal, 100 para la fase de validación y 100 para fase de prueba. Para evaluar el método realizado, utilizaron Error Radial Medio (MRE) y Tasa detección de éxito (SDR) con un rango de 1 a 4mm. Error radial medio en el proceso de validación fue de 1.127 ± 1.028 mm y de la tasa detección de éxito (SDR) 1.0, 1.5, 2.0, 2.5, 3.0, y 4.0 mm donde fueron respectivamente 45.95%, 89.19%, 97.30%, 97.30%, y 97.30%. Error radial medio fue de 1.038 ± 0.893 mm, y SDR de 1.0, 1.5, 2.0, 2.5, 3.0, y 4.0 mm donde se obtuvo 54.05%, 91.89%, 97.30%, 100%, 100%, y 100% respectivamente. Obtuvieron como resultado la localización de 37 puntos con alto grado de precisión, todos estos puntos son comúnmente utilizados en la práctica dental (27).

Por otra parte, Li y cols., en el 2022, evaluaron por medio de radiografías laterales de cráneo el estadio de maduración de las vértebras cervicales, realizaron una clasificación que los dividía en 6 estadios de maduración. Realizaron varios modelos de redes neuronales convolucionales para determinar cual es el más conveniente para el análisis, después del entrenamiento y validación de la red neuronal convolucional, el modelo ResNet 152 resultó ser el método más rápido y confiable para el análisis de maduración de las vertebras cervicales obteniendo una precisión del 67.06% en comparación con las otras CNN; VGG16, GoogLeNet, DenseNet161 donde obtuvieron 61.15%, 64.11%, 64.22% respectivamente (28).

Li y cols., en el 2022, con el uso de redes neuronales convolucionales evaluaron y compararon la clasificación de los patrones esqueléticos sagitalmente. Ellos recolectaron 2,432 radiografías laterales de cráneo, las clasificaron en patrones de crecimiento de tipo, clase I, clase II y clase III, con base a los ángulos que resultaban de los puntos ANB y valores de Witts. Las radiografías fueron divididas de manera aleatoria para cada una de las fases de la CNNs, aprendizaje, validación y prueba. Cuatro diferentes CNNs: VGG16, GoogLeNet, ResNet152 y DenseNet161 fueron entrenadas y su desempeño fue comparado. Como resultados obtuvieron que la opción con la máxima precisión fue la red DenseNet161 con 89.58% mientras que GoogLeNet fue la que obtuvo resultados más deficientes. Concluyeron que cada uno de los modelos estudiados tiene sus características y que pueden servir para diferentes aplicaciones dependiendo de las necesidades del investigador. Y definieron que las CNN pueden de manera rápida y eficaz ayudar al ortodoncista para el diagnóstico de los patrones esqueléticos vistos de manera sagital (29).

Jeon y cols., en el 2021, realizaron un estudio para comparar los resultados de un análisis cefalométrico al utilizar redes neuronales convolucionales con una cefalometría realizada con método convencional. Realizaron las medidas cefalométricas a partir de radiografía lateral de cráneo de 35 pacientes. Las cefalometrías fueron importadas al programa V-Ceph™ para el análisis cefalométrico convencional y a Ceph X™ para el análisis con la IA. Se seleccionaron 16 puntos cefalométricos, 15 medidas cefalométricas esqueléticas, 9 medidas cefalométricas dentales y 2 medidas cefalométricas de tejidos blandos, éstas fueron obtenidas por un experto en los tratamientos ortodóncicos. Como resultados, obtuvieron diferencias estadísticamente significativas en cuanto al ángulo de la silla, medidas lineales del incisivo superior al plano NA e incisivo inferior al plano NB, en cuanto a los tejidos blandos no se observaron diferencias estadísticamente significativas entre los dos métodos empleados. Concluyeron, que a pesar de las limitaciones del estudio, las redes neuronales convolucionales pueden ofrecer un mejor desempeño durante el diagnóstico (30).

Shujaat y cols., en el 2021, realizaron un estudio en el que proponían el uso de redes neuronales convolucionales e investigar el desempeño de la red al momento de realizar la segmentación automática del espacio aéreo faríngeo. Para ello utilizaron una base de datos de pacientes de cirugía ortognática y seleccionaron 103 CBCT, en las cuales 48 fueron utilizadas para la fase de entrenamiento, 25 para la fase de prueba y 30 para la validación. El tiempo promedio que le tomó a la red neuronal convolucional para procesar y segmentar los datos fue de 14.5 s, y, de 70 min. cuando se aplica una segmentación manual. El coeficiente de correlación intraclase del intraobservador fue de 0.998, mientras que el de interobservador fue de 0.996, lo cual indica que no hay una diferencia significativa entre los observadores. El modelo de la red neuronal convolucional fue apto para identificar la región segmentada con una óptima precisión (0.97 ± 0.01) indicando una precisa y casi perfecta segmentación de la vía aérea faríngea (31). Cabe mencionar que este estudio es el único que utiliza las redes neuronales convolucionales para analizar las vías aéreas.

El uso de la inteligencia artificial en la ortodoncia ha tenido un gran avance en los últimos años, su crecimiento en el área a impulsado a los clínicos a utilizar más este tipo de tecnologías para facilitar los tratamiento ortodóncicos. En este estudio se buscó probar el uso de las redes neuronales convolucionales como una herramienta para facilitar la interpretación de radiografías durante el diagnóstico. Hoy en día el uso de radiografías ya sea lateral de cráneo o panorámicas, se proporcionan al ortodoncista de manera digital, el cuál se ayuda de programas para facilitar localización de puntos y hasta realizar trazados cefalométricos. Si el algoritmo de la red neuronal convolucional es capaz de clasificar la vía aérea, podríamos en un futuro implementar esta función en esos programas y así complementar el diagnóstico de cada uno de nuestros pacientes.

PLANTEAMIENTO DEL PROBLEMA Y PREGUNTA DE INVESTIGACIÓN

Obtener un diagnóstico completo en ortodoncia ha sido facilitado debido a las herramientas auxiliares, a pesar de tener estas facilidades, en ocasiones solo damos enfoque a lo dental y esquelético dejando a un lado un análisis completo del paciente. En el caso de las vías aéreas es importante aprender a identificarlas y clasificarlas para poder lograr un abordaje correcto hacia el paciente y saber si presenta alguna alteración y de ser así el caso, poder referirlo y tratarlo multidisciplinariamente previo al tratamiento ortodóncico. La obstrucción de la vía aérea superior puede llegar a tener repercusiones en el desarrollo de las estructuras craneofaciales y si no son detectadas a tiempo, el tratamiento ortodóncico puede fracasar o de igual manera empeorar la condición del paciente. Se debe tener el conocimiento completo de todas y cada una de las estructuras que podemos analizar en la radiografía, para en caso de presentarse una obstrucción de

la vía aérea, encontrar su etiología y trabajar de manera multidisciplinaria con el otorrinolaringólogo.

La radiografía lateral de cráneo es un requisito indispensable para el diagnóstico en ortodoncia, implementarlo de la manera correcta para obtener la mayor cantidad de información de ella nos permitirá detectar la mayor cantidad de anomalías en el paciente. Debido al desconocimiento por algunos ortodontistas de como medir las vías aéreas y su clasificación, se podría aplicar el uso de inteligencia artificial en este caso las redes neuronales artificiales, con la finalidad de facilitar el proceso de clasificación, obtener un resultado preciso y elaborar de manera completa el plan de tratamiento. La investigación de redes neuronales convolucionales en ortodoncia, ha sido escasa, por lo tanto, se debe comenzar a explorar cada vez más este campo para poder ir desarrollando múltiples alternativas de diagnóstico. El comprobar que se pueda realizar este análisis con el uso de la IA, nos abre la posibilidad de realizar mayores estudios, y de este modo trabajar siempre con una herramienta exacta cada vez que se realice un diagnóstico ortodóncico.

Con base en lo mencionado nos planteamos la siguiente pregunta de investigación:

4.1 PREGUNTA DE INVESTIGACIÓN

¿Es posible clasificar la apertura de las vías aéreas superiores a partir de una radiografía lateral de cráneo con el uso de redes neuronales convolucionales?

JUSTIFICACIÓN

Para obtener mayor precisión durante el diagnóstico debemos apoyarnos de métodos que la tecnología nos ha brindado, en este caso, las redes neuronales convolucionales, las cuales han probado ser eficaces para auxiliar al ortodontista con el diagnóstico. Debido a que durante el diagnóstico no se toma en cuenta el espacio de las vías aéreas superiores por el desconocimiento de como medirlas y clasificarlas, solo se le busca dar enfoque a lo esquelético, al momento de buscar la vía aérea se dificulta la identificación en la radiografía lateral de cráneo y se le resta la importancia de realizarlo, el tener una herramienta auxiliar que nos permita identificarla más rápido representa una gran ventaja para poder complementar nuestros diagnósticos y por lo tanto el plan de tratamiento. Clasificar la vía aérea de una manera precisa y fácil puede apoyar mucho al ortodontista para elaborar planes de tratamientos con un abordaje completo hacia el paciente. Además, no existe un estudio que realice un análisis de clasificación de las vías aéreas superiores, por lo tanto no existe un algoritmo de redes neuronales convolucionales que tenga la capacidad de identificarlo. Por esta razón, se creará un algoritmo específico de redes neuronales convolucionales entrenado para identificar y clasificar la vía aérea

superior con solo mostrar la radiografía lateral de cráneo. Realizar un primer acercamiento hacia las redes neuronales convolucionales para probar su exactitud durante la fase diagnóstica en un tratamiento de ortodoncia. Comprobar que su uso es de gran utilidad en la ortodoncia y con base a esto realizar más estudios para el beneficio de ortodoncista y paciente.

HIPÓTESIS

1.1 Hipótesis científica: Las redes neuronales convolucionales permiten clasificar la apertura de las vías aéreas a partir de una radiografía lateral de cráneo.

6.2 Hipótesis nula: Las redes neuronales convolucionales NO permiten clasificar apertura de las vías aéreas a partir de una radiografía lateral de cráneo.

OBJETIVOS

7.1 Objetivo general

Clasificar la apertura de la vía aérea superior con el uso de las redes neuronales convolucionales a partir de una base de datos de radiografías laterales de cráneo.

7.2 Objetivos específicos

1. Crear una base de datos con la clasificación de la apertura de las vías aéreas de las radiografías lateral de cráneo de acuerdo a la clasificación de McNamara.
2. Determinar la exactitud del algoritmo de red neuronal convolucional para clasificar la vía aérea superior.
3. Determinar la sensibilidad, especificidad y el valor-F del algoritmo utilizado.
4. Crear una red neuronal convolucional que pueda discernir entre vía aérea obstruida y abierta.

MATERIALES Y MÉTODOS

El área de computación e inteligencia artificial, tiene un formato y estilo de redacción científica diferente al empleado en el área de la salud, por lo que para respetar en este formato, el siguiente apartado describirá los 3 tipos de redes neuronales convolucionales que se pondrán a prueba con el algoritmo para realizar la clasificación de la vía aérea superior.

8.1 REDES NEURONALES CONVOLUCIONALES

Las redes neuronales convolucionales (CNNs, por sus siglas en inglés) fueron propuestas por Yann LeCun y cols., en el 1998 (32) las cuales describen un grupo especial de redes neuronales profundas que utilizan filtros de convolución para realizar el aprendizaje y la extracción de características (33). La red está compuesta por diversas capas donde se realiza un trabajo específico, consiste en una capa de convolución (convolutional layer), capa de agrupación (pooling layer) y capa completamente conectada (fully-connected layer). Una vez que la CNN realiza la fase de aprendizaje y está entrenada cada filtro se encarga de identificar una característica de la entrada, los filtros se reutilizan en toda la imagen reduciendo el número de parámetros. La concatenación de capas de filtro crea la capacidad de detectar características no lineales, en consecuencia, la CNN profunda puede encontrar y clasificar conceptos complejos.

AlexNet

Modelo que consta de 5 capas convolucionales y 3 capas completamente conectadas propuesto por Sutskever y Hinton (34). Lo que caracteriza a este modelo es el uso de la función de activación ReLU en lugar de la función tangente hiperbólica (tanh), la facilidad para ejecutar el entrenamiento usando múltiples GPU, lo cual reduce el tiempo de entrenamiento. Este modelo logró un rendimiento significativamente mejorado con respecto a otros métodos de aprendizaje no profundo, la CNN AlexNet puede aprender desde cero o ajustarlo a partir de modelos previamente entrenados (35). Una de las limitaciones del modelo original es que al manejar hasta 60 millones de parámetros, puede ser propenso al sobre-entrenamiento, por lo que se introdujeron estrategias de aumento y abandono (dropout) de datos.

ResNet

Es una red neuronal convolucional (36) conocida por ganar la competencia llamada: *ImageNet Competition* en 2015; se utiliza principalmente para realizar clasificación de imágenes. Este tipo de red neuronal profunda tiene la capacidad de

resolución del problema de la desaparición de gradientes para modelos de aprendizaje con muchas capas de en redes convolucionales profundas. La arquitectura de este modelo permite implementar cientos o incluso miles de capas y aun así logra un rendimiento convincente (37). Se encontró que más allá de cierta profundidad, el rendimiento se deteriora. Para garantizar que la información no se pierda durante la *retropropagación*, los autores crearon 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 varias arquitecturas ResNet en las que cada bloque utiliza dos circunvoluciones para modelos menos profundos, como ResNet18 o ResNet34, o tres convoluciones para uno más profundo, como ResNet50, ResNet101 y ResNet152 (38).

VGG16 y VGG19

Esta arquitectura que fue descrita por Simonyan et al. y utilizada exitosamente en el banco de datos ImageNet (39). Este modelo presenta una contribución diferente a las otras redes neuronales por aumentar la profundidad de la red neuronal convolucional utilizando filtros de convolución (3×3). Por lo general, esta arquitectura se divide en cinco bloques de circunvoluciones alternados por capas de "agrupación máxima" y termina con un bloque de clasificación formado por capas densamente conectadas. VGG16 tiene una notable capacidad de extracción de características para que pueda obtener un buen efecto en la clasificación de imágenes (40).

Se ha logrado mejorar significativamente la arquitectura aumentando la profundidad a 16 o 19 capas de peso. Los modelos de VGG varían dependiendo del número de capas que presentan en la convolución (VGG 16 o VGG19).

8.2 DISEÑO DEL ESTUDIO

Es un estudio *in silico*, transversal y retrospectivo.

8.3 POBLACIÓN Y MUESTRA

Tamaño de la muestra: de acuerdo a la naturaleza de los estudios, entre el mayor número de radiografías mejor, sin embargo con base a las pruebas piloto, el experto en CNN determinó que el tamaño de muestra podría ser de 200 para cada grupo.

Radiografías laterales de cráneo de pacientes que hayan iniciado su tratamiento de ortodoncia en la clínicas de FEBUAP.

Grupos:

Se dividirá en dos grupos diferentes con base en la apertura u obstrucción de la vía aérea superior.

- Grupo control: 200 radiografías laterales de cráneo con la vía aérea superior obstruida.
- Grupo experimental: 200 radiografías laterales de cráneo con la vía aérea superior abierta.

Tipo de muestreo

Muestreo aleatorio simple

8.4 CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN

Inclusión: 1. Radiografías laterales de cráneo de candidatos a tratamiento de ortodoncia.

2. Radiografías laterales de cráneo que cumplan con el estándar de calidad del equipo dental de Rayos X marca VATECH (VATECH Co. LTD).

Exclusión: 1. Radiografías laterales de cráneo que sean tomadas con un equipo radiológico diferente.

Eliminación: 1. Radiografías laterales de cráneo que sufran algún tipo de deterioro antes de la fase de aprendizaje.

8.5 TABLA DE DEFINICIÓN Y MEDICIÓN DE VARIABLES

Tabla 1. Tabla de variables.

VARIABLE	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL	ESCALA DE MEDICIÓN Y UNIDADES	CATEGORÍA
Clasificación de las vías aéreas	Es la forma en la que se identifica a las vías aéreas que depende de la apertura de la misma.	Se clasificará dependiendo de los milímetros que resulten de cada medida. Norma: Diámetro faríngeo superior: 17.4mm +/- 4 mm Diámetro faríngeo inferior: 11.3 (mujeres) 13.5 (hombres) +/- 4mm.	Cuantitativo, razón, milímetros	Independiente
Exactitud (Accuracy)	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
Especificidad	Frecuencia en la que una prueba produce resultados negativos verdaderos en las personas que no tienen la enfermedad o la variante genética en estudio.	Resultado obtenido por el software.	Cuantitativa	Dependiente
Sensibilidad	Se refiere a la probabilidad de que el resultado de la prueba de una enfermedad sea positivo si realmente tiene la enfermedad.	Corresponde a la cantidad de casos positivos correctamente clasificados como positivos.	Cuantitativa	Dependiente
Valor-F	Balance entre especificidad y sensibilidad.	Que tan correcto identifica los casos negativos como los positivos.	Cuantitativa	Dependiente

8.6 CONCORDANCIA Y FIABILIDAD

Se capacitó 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. La tesista adquirió la capacitación necesaria para comprender como funcionan las redes neuronales convolucionales para ser capaz de interpretar los resultados que se obtengan del modelo.

Para determinar la confiabilidad, reproductibilidad y concordancia entre las mediciones se utilizó la prueba estadística CCI (coeficiente de correlación intraclase o coeficiente R^2 de Pearson).

8.7 UBICACIÓN ESPACIO-TEMPORAL

La obtención de datos fue en el departamento de radiología de FEBUAP. Después de elaborar la base de datos de las radiografías, los algoritmos fueron creados por investigadores especialistas en Inteligencia Artificial, en el Centro de Innovación y Desarrollo Tecnológico en Cómputo del Instituto Politécnico Nacional.

8.8 ASPECTOS ÉTICOS

Este estudio se apega a la Ley General de salud en materia de investigación y a los principios de Helsinki que garantiza la integridad física y mental de los pacientes. Nuestro estudio se llevó a cabo de manera estricta a los principios éticos de toda investigación, entiéndase, el respeto por las personas y su autonomía, justicia, no maleficencia y beneficencia. Si bien considerando que nuestro estudio trabajó con un banco de datos anonimizados, por lo que era imposible identificar individuos, y debido a la naturaleza del tipo de estudio, no se requiere la participación de seres humanos. De igual manera no se pretende hacer uso inadecuado de la información proporcionada, es meramente con fines del estudio.

8.9 PROCEDIMIENTOS, TÉCNICAS Y FUENTES DE RECOLECCIÓN

Métodología

Este trabajo se realizó en tres etapas, la primera de ellas denominada “Prueba Piloto”, con la finalidad de evaluar las redes neuronales convolucionales más apropiadas para identificar el área de interés del estudio (vía aérea superior), las cuales son: VGG16, VGG19, ResNet y LeNet. En la segunda etapa, “Aumento de datos”, se implementó un proceso artificial para aumentar la base de datos con el fin de calibrar y probar los algoritmos que se utilizarían finalmente en la fase experimental, donde se determinó utilizar ResNet, VGG16 y AlexNet. Y la tercera etapa, “experimentación”, donde ya se tenía la base de datos completa, se probaron las mismas CNNs de la segunda etapa, debido a los buenos resultados adquiridos en esa fase y con la cual se determinarían la exactitud, sensibilidad, especificidad y valor-F de las redes neuronales convolucionales seleccionadas en el estudio previo.

8.9.1 PRIMERA ETAPA - PRUEBA PILOTO

1. El primer paso realizado durante la primera etapa fue la estandarización de la tesista en la clasificación de las vías aéreas superiores y su medición, con la colaboración de una experta radióloga, Dra. María Isabel Pizano Damasco (Radióloga oral y maxilofacial), se llevó a cabo la clasificación de 15 radiografías laterales de cráneo por grupo (grupo de vía aérea obstruida y grupo de vía aérea abierta), con los resultados obtenidos se llevó a cabo el coeficiente de correlación intraclase como estrategia para sustentar la estandarización de la tesista (CCI=0.9).
2. Una vez realizado el proceso de estandarización, se acudió a la clínica de radiología de la Facultad de Estomatología de la BUAP (FEBUAP), el expediente clínico que fue proporcionado contaba con 500 radiografías laterales de cráneo, las cuales fueron sometidas a un muestreo aleatorio simple para posteriormente ser evaluadas de acuerdo a los criterios de selección y comenzar su clasificación de acuerdo al análisis de McNamara; aquellas radiografías con una vía aérea abierta y el grupo de vía aérea obstruida, para esta primera etapa, como se mencionó previamente, el objetivo era realizar una primera prueba piloto para evaluar la capacidad de los algoritmos para identificar la zona de interés, por lo que se decidió utilizar una “n” de 75 para cada grupo de acuerdo a la literatura (41).
3. Las radiografías laterales de cráneo digitalizadas fueron ingresadas al software de análisis de imágenes IMAGEJ (Rasband, W.S., ImageJ, U. S. National

Institutes of Health, Bethesda, Maryland, USA), herramienta que permite hacer los trazos lineales de acuerdo a la técnica de McNamara para identificar la condición de las vías aéreas (obstruida, abierta) para ello, se obtuvieron dos medidas de cada una de las radiografías: Diámetro faríngeo superior: 17.4 mm +/- 4 mm y Diámetro faríngeo inferior: 11.3 mm (mujeres) y 13.5 mm (hombres) +/- 4mm.

4. Una vez obtenidos los grupos completos de 75 radiografías para cada clasificación (obstruida y abierta), se procedió a guardar estos datos en el programa Microsoft Excel ® (Microsoft Excel 2019, versión 16.77.1).
5. Posteriormente, las carpetas que contenían las radiografías de acuerdo a su clasificación, fueron enviadas al experto en redes neuronales convolucionales (Dr. Elías Ventura, Ingeniero en sistemas computacionales) para comenzar con su fase de aprendizaje, validación y prueba. Las CNNs que se incluyeron para su evaluación en esta etapa fueron: VGG16, VGG19, ResNet y LeNet, se consideró el uso de estas redes con base a la literatura, es decir, estas son las mas ampliamente utilizadas en estudios de clasificación de imágenes bidimensionales, a pesar de ello, era importante considerar que las imágenes en este trabajo eran radiografías con escalas de colores diferentes a aquellas pruebas con las que convencionalmente se habían evaluado estas CNNs, con base al resultado de esta prueba se decidiría que redes utilizar en los experimentos finales.
6. Como se mencionó previamente, el análisis de las radiografías por el experto en inteligencia artificial se divide en aprendizaje, validación y prueba, y, el paso previo al inicio de la fase de aprendizaje es realizar una partición del banco de radiografías, el cual tiene como objetivo clasificarlas en vías aéreas abiertas y obstruidas, para ello se llevaron a cabo los siguientes pasos:
 - I. De la base de datos obtenida, se mezcló aleatoriamente el conjunto de datos de imágenes por clase, para que posteriormente fueran divididas en 3 grupos para sus diferente fases de trabajo; fase de entrenamiento, validación y prueba.
 - II. * La partición del banco de datos fue realizada de la siguiente manera, esto con el fin de que la imágenes utilizadas en cada fase no sean repetidas en otra fase, y pudiéramos de esta manera valorar el desempeño de las CNNs. Se seleccionaron el 60% de las imágenes (n=45 de imágenes de cada clasificación) para el conjunto de entrenamiento, el 20% (n=15 imágenes de cada clasificación) para el conjunto de validación y el 20% (n=15 imágenes de cada clasificación) para el conjunto de prueba.

- III. Se almacenaron las imágenes y sus etiquetas en tres carpetas separadas: entrenamiento, validación y prueba.
- IV. Posteriormente se utilizaron los datos de entrenamiento para entrenar la red neuronal convolucional, los datos de validación para ajustar los hiperparámetros del modelo y los datos de prueba para evaluar el rendimiento final del modelo.

* Por el estilo del área científica la parte del entrenamiento, validación y prueba.

- 7. Fase de entrenamiento: se proporcionaron las 45 imágenes de cada clasificación (obstruida y abierta) a las CNNs para aprender de cada una de las radiografías por medio de la identificación de bordes, líneas y formas específicas del área de interés, con la finalidad de reconocer la vía aérea abierta u obstruida.
- 8. Fase de validación: las 15 imágenes de cada clasificación fueron validadas; es decir verificar si la CNNs es capaz de validar/reconocer correctamente el área de interés a estudiar; vía aérea superior.
- 9. Fase de prueba: se realizó la prueba con las 15 imágenes de cada clasificación para identificar si la CNN es fue capaz de realizar la identificación de la imagen y su respectiva clasificación (29).

8.9.2 SEGUNDA ETAPA – “Aumento de datos”

- 1. Con base a la clasificación de las 150 radiografías clasificadas previamente en la prueba piloto, estas fueron sometidas al proceso de “Aumento de datos”. Este proceso fue realizado por el experto en redes neuronales convolucionales que consiste en aplicar un proceso de inteligencia artificial para crear nuevos datos a partir de los datos ya existentes con la finalidad de entrenar nuevos modelos de machine learning con bases de datos más amplias, en este caso entrenar a las redes neuronales convolucionales. Se aplicaron modificaciones como rotación, traslación, aumento y reducción de tamaño de las imágenes, aplicación de filtros para cambio de color y que juntos producen un aumento en el número de imágenes (150 imágenes) modificadas sintéticamente como se muestra en la Figura 4. Las imágenes originales, junto con las imágenes aumentadas para el conjunto de datos, actúan como entrada para varios algoritmos de aprendizaje. Esta fase se llevó a cabo con el objetivo de mejorar el

rendimiento de las CNNs. En la prueba piloto, observamos que la exactitud estuvo por debajo del 60%. Por lo tanto, se decidió aumentar la base de datos al utilizar las imágenes disponibles para evaluar cómo trabajan las CNNs utilizadas. En esta etapa, se enfocó únicamente en las dos CNNs que mostraron los mejores resultados en la prueba anterior. Además, se decidió incorporar una nueva CNN: AlexNet. Según la literatura, AlexNet ha demostrado un rendimiento sólido en la clasificación de imágenes, incluidas las radiografías bidimensionales (42).

2. Se obtuvo al final una base de datos de 150 radiografías laterales de cráneo con vía aérea obstruida y 150 radiografías lateral de cráneo con vía aérea abierta, es decir, se duplicó la base de datos que se tenía inicialmente con este método de “Aumento de datos”.
3. A partir de esta etapa del estudio, se aplicaron los mismos pasos que se realizaron en la “prueba piloto”, es decir desde que se proporcionaron los datos al experto en redes neuronales convolucionales, para iniciar con la partición de banco de datos, solo que en este caso la distribución de imágenes fue con base a la nueva base de datos (300 imágenes en total). La partición se llevó a cabo con el mismo porcentaje de distribución, 60% imágenes para el aprendizaje (n=90 imágenes de cada clasificación), 20% para validación (n=30 imágenes de cada clasificación) y 20% para la prueba (n=30 imágenes de cada clasificación).
4. Posteriormente se evaluó las CNNs por medio del proceso de aprendizaje, validación y prueba, tal y como se explicó en la fase previa a esta (43).
5. El experto en redes neuronales convolucionales comenzó la fase de prueba con la nueva base de datos. Se utilizaron dos redes neuronales convolucionales de la primera etapa: ResNet y VGG16, seleccionadas por ser aquellas que obtuvieron el mayor porcentaje de exactitud. Con el objetivo de medir el rendimiento de estas CNNs con bases de datos más amplias y, además, se añadió una CNN más; AlexNet, conocida por su eficacia en la clasificación de radiografías según la literatura.

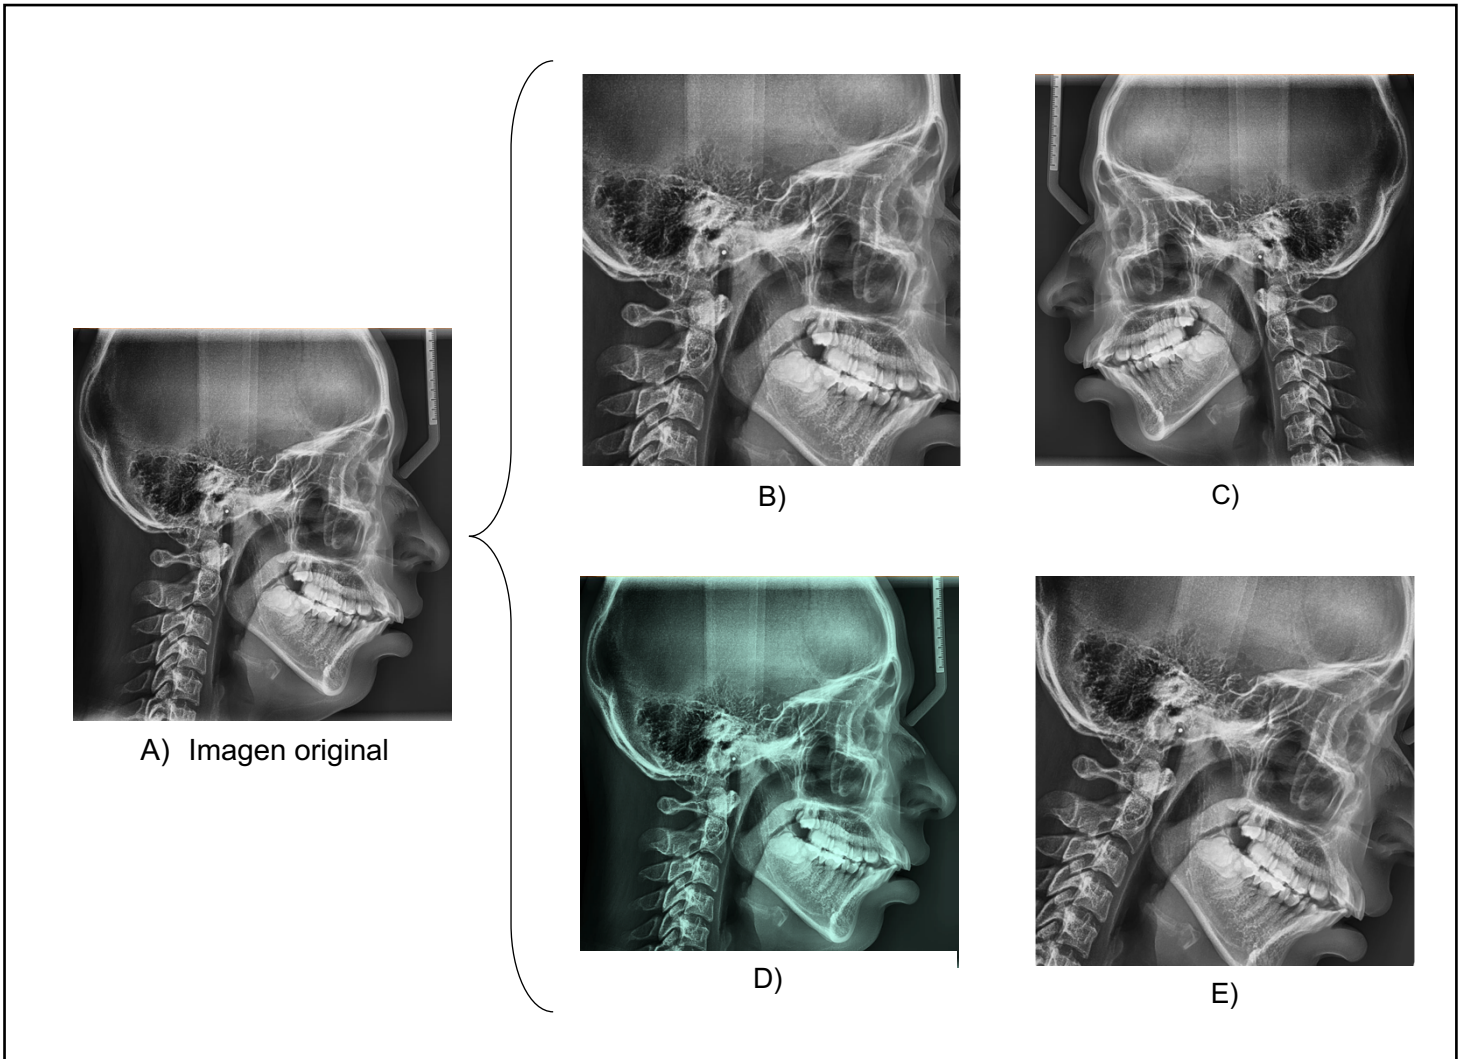


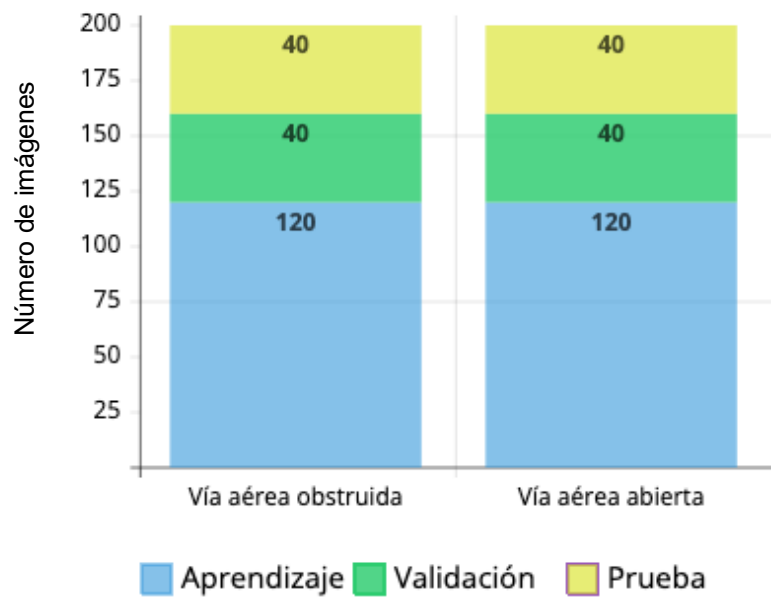
Figura 4. Representación del Aumento de datos, A) Imagen representativa que fue modificada por medio de la IA para adquirir nuevas imágenes, B) imagen con aumento de tamaño, C) imagen con traslación, D) imagen con cambio de color/contrastes, E) imagen con rotación.

8.9.3 TERCERA ETAPA – “Prueba experimental”

Basándonos en los resultados previos, se determinó la necesidad de adquirir un mayor número de imágenes para enriquecer la base de datos inicial. Tras consultarlo con el experto en redes neuronales convolucionales, se estableció que serían necesarias 400 imágenes (200 para cada clasificación) debido a que a partir de la prueba anterior con 300 imágenes resultaron exactitudes favorables. Y con el fin de evaluar con exactitud el rendimiento de cada CNN se utilizó esa base de datos. En esta etapa, se utilizaron AlexNet, ResNet y VGG16, dado el éxito previo de AlexNet en la fase anterior, se decidió continuar utilizando esta arquitectura en el estudio.

1. Inicialmente, se recopilaron las primeras radiografías laterales de cráneo en el área de radiología de FEBUAP. Posteriormente, se accedió nuevamente a la base de datos para obtener las radiografías faltantes necesarias para completar ambos grupos. Como resultado, se logró reunir un total de 400 radiografías laterales de cráneo, distribuidas en dos categorías: 200 con vía aérea obstruida y 200 con vía aérea abierta.
2. A partir de esta etapa del estudio, se aplicaron los mismos pasos que se realizaron en la “prueba piloto”, es decir desde que se proporcionaron los datos al experto en redes neuronales convolucionales, para iniciar con la partición de banco de datos, con el nuevo banco de datos (400 imágenes, 200 para cada clasificación). La partición se llevo a cabo con el mismo porcentaje de distribución (Tabla 2), 60% imágenes para el aprendizaje (n=120 imágenes de cada clasificación), 20% para validación (n=40 imágenes de cada clasificación) y 20% para la prueba (n=40 imágenes de cada clasificación).
3. Posteriormente se evaluó las CNNs por medio del proceso de aprendizaje, validación y prueba, tal y como se explicó en la fase previa a esta.
4. El experto en redes neuronales convolucionales comenzó la fase de prueba con la nueva base de datos (total de 400 imágenes). Se utilizaron las redes neuronales convolucionales; ResNet, VGG16 y AlexNet. En esta etapa se valoró la exactitud, sensibilidad, especificidad y valor-F de cada una de las redes neuronales, a partir de los datos obtenidos de la matriz de confusión de cada una de las CNNs (Figura 5). La matriz de confusión, es aquella que se encarga de medir el desempeño de la CNN, nos proporcionó los valores verdadero positivo, verdadero negativo, falso positivo y falso negativo de cada una de las CNNs para que con esos valores se pudieran calcular las métricas de rendimiento de las CNNs y a partir de esto analizar sus resultados (29).

Tabla 2. Partición del banco de datos.



Total de imágenes utilizadas en cada fase; aprendizaje, validación y prueba.

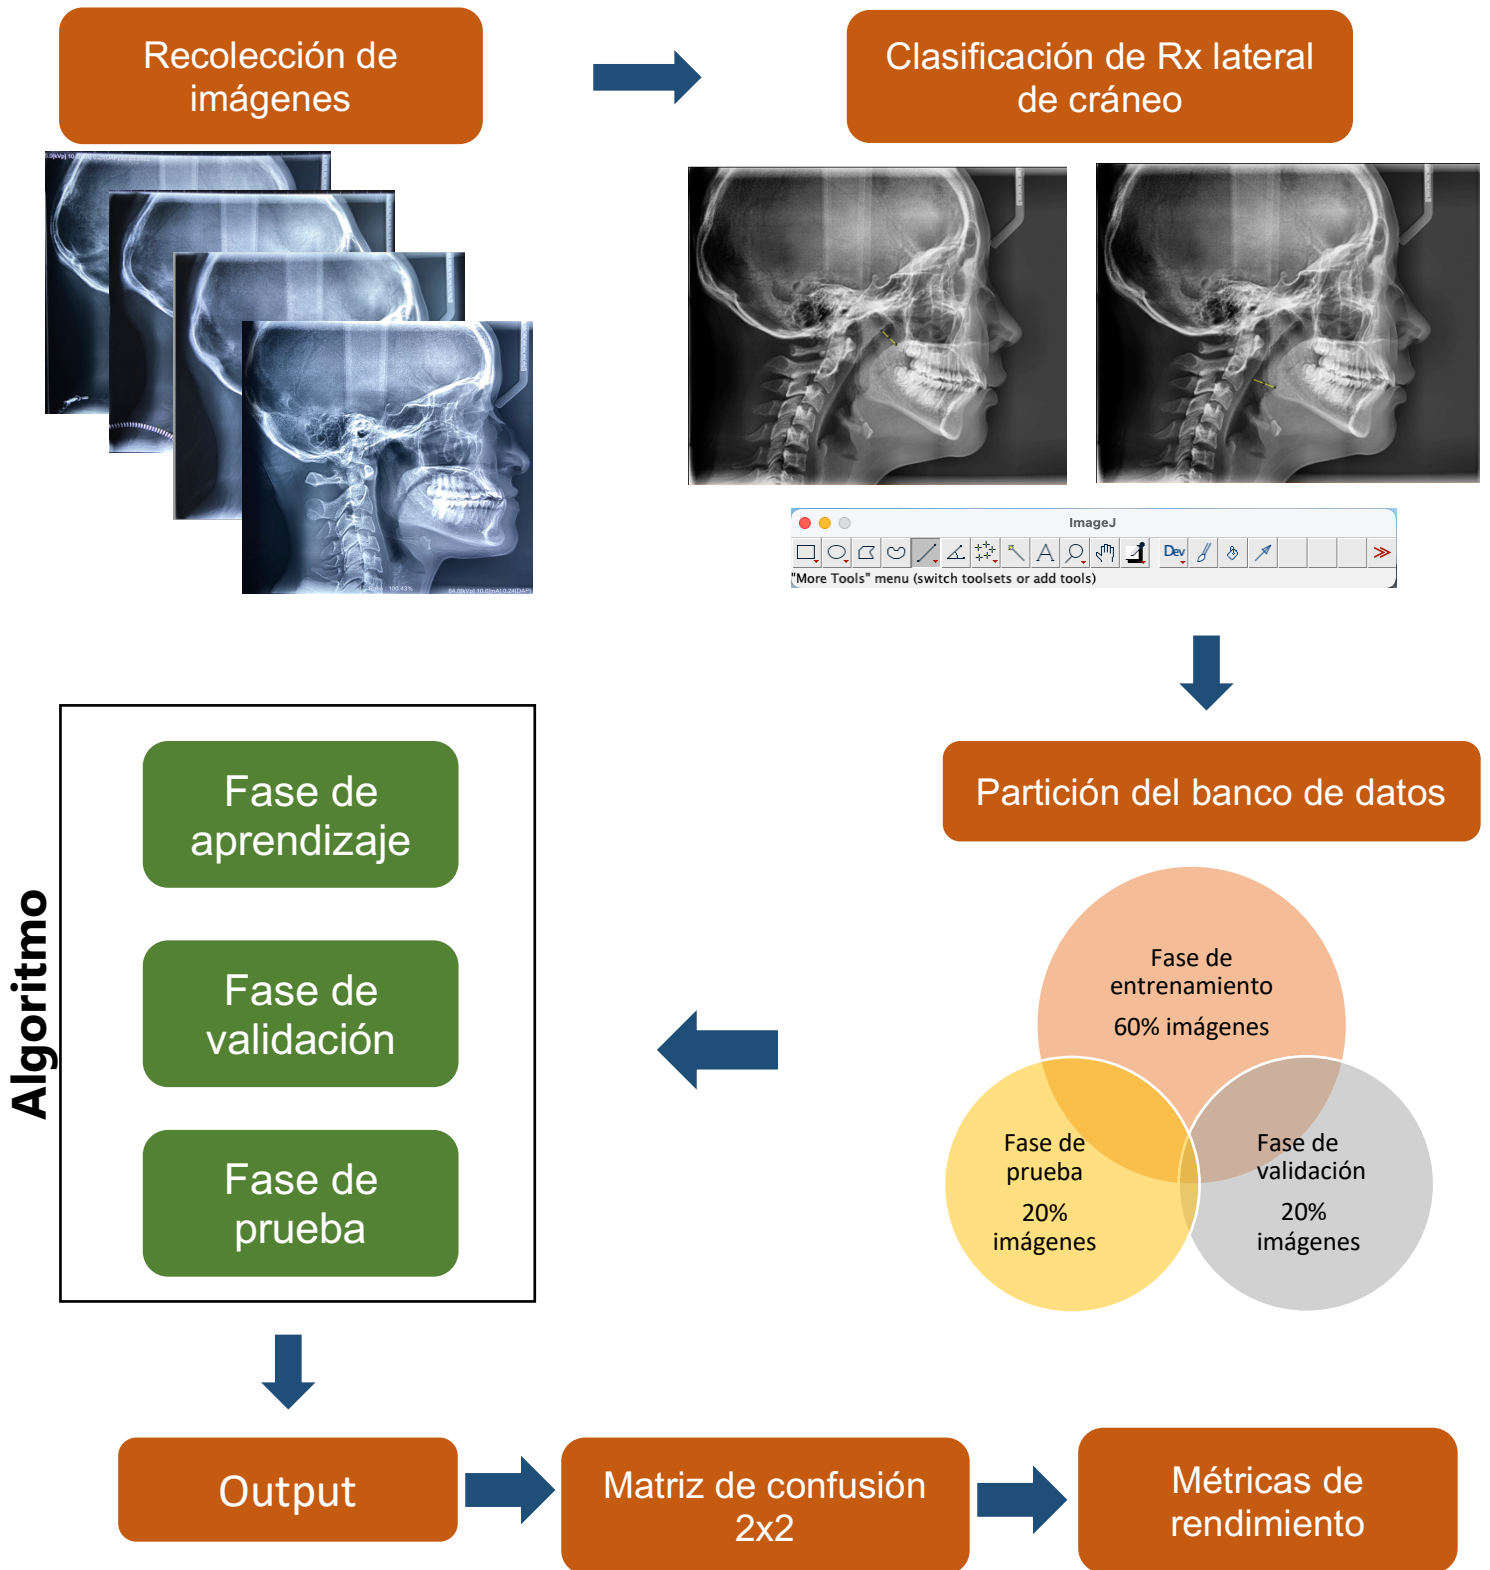


Figura 5. Esquema de procedimientos de cada una de las fases realizadas después de obtener la base de datos para la prueba de las CNNs.

8.9.4 Cuantificación de los resultados obtenidos por la red neuronal convolucional

Se realizaron las pruebas y posterior a la ejecución de la redes neuronales convolucionales, se evaluaron los resultados obtenidos de las pruebas. La red neuronal convolucional nos proporcionó los datos finales los cuales nos corresponde interpretar y describirlos.

En este estudio se obtuvo la exactitud, especificidad, sensibilidad y valor-F (F-score), se adquirieron los valores a partir de la matriz de confusión de 2x2, la cuál se encarga de cuantificar el desempeño del algoritmo, de ahí se produjeron las medidas de rendimiento que son los verdaderos positivos (TP), verdaderos negativos (TN), falso positivo (FP) y falso negativo (FN). Contando con estos valores del algoritmo, nos permitió medir la exactitud, especificidad y sensibilidad utilizando las siguientes fórmulas.

- Exactitud: es la cantidad de imágenes clasificadas correctamente por el modelo.

$$\text{Exactitud} = \frac{TP+TN}{TP+FP+TN+FN}$$

- Sensibilidad: cantidad de imágenes de casos positivos (vía aérea obstruida) clasificados correctamente como tal.

$$\text{Sensibilidad} = \frac{TP}{TP+FN}$$

- Especificidad: cantidad de imágenes de casos negativos (vía aérea abierta) clasificados correctamente como tal.

$$\text{Especificidad} = \frac{TN}{TN+FP}$$

- Valor-F: Balance entre especificidad y sensibilidad; que tan correcto identifica los casos negativos como los positivos.

$$\text{F-Score} = \frac{2}{\frac{1}{\text{Precision}} + \frac{1}{\text{Recall}}} = \frac{2 * (\text{Precision} * \text{Recall})}{(\text{Precision} + \text{Recall})}$$

Entiéndase como recall como exhaustividad.

8.10 ANÁLISIS ESTADÍSTICO

Para medir el desempeño del modelo, se utilizan las métricas de rendimiento exactitud, sensibilidad, especificidad y el Valor-F, para obtener estas medidas se interpretan las ecuaciones a partir de los verdaderos positivos (TP), verdaderos negativos (TN), falso positivo (FP) y falso negativo (FN). En estas métricas, la puntuación F1 es la métrica más general que indica la media entre especificidad y sensibilidad. Todo el valor de las métricas oscilan entre 0 y 1. Las ecuaciones son las siguientes:

$$\text{Exactitud} = \frac{TP+TN}{TP+FP+TN+FN}$$

$$\text{Sensibilidad} = \frac{TP}{TP+FN}$$

$$\text{Especificidad} = \frac{TN}{TN+FP}$$

$$\text{F-Score} = \frac{2}{\frac{1}{\text{Precision}} + \frac{1}{\text{Recall}}} = \frac{2 * (\text{Precision} * \text{Recall})}{(\text{Precision} + \text{Recall})}$$

Si obtenemos resultado positivo o negativo significa que el modelo predice que la radiografía muestra la vía aérea abierta u obstruida, en cuanto al verdadero o falso la predicción significa si esta bien o mal.

RESULTADOS

Para valorar la concordancia y fiabilidad de este estudio, como se mencionó previamente se estandarizó a la tesista con una Radióloga Maxilofacial y se realizó el análisis de CCI (Coeficiente de correlación intraclase). Se realizó el CCI intraobservador con la tesista; es decir se midieron 2 veces las mismas radiografías laterales de cráneo en diferentes tiempos donde se obtuvo una concordancia de 0.90. De igual manera se midieron las mismas radiografías por la experta radióloga 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.

9.1 Primera etapa - Prueba piloto

Las 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. En la prueba piloto las redes neuronales convolucionales; VGG16, VGG19, ResNet y LeNet fueron probadas con un base de datos de 75 radiografías lateral de cráneo con las vías aéreas obstruidas y 75 radiografías lateral de cráneo con vía aérea abierta. El mejor resultado obtenido fue de ResNet con 52.07% de exactitud de detección de vía aérea obstruida, después VGG16 con 50.09%, VGG19 con un resultado de 49.98% y por último LeNet 47.88% de exactitud (Tabla 3).

Tabla 3. Resultados de la prueba piloto; 4 CNNs fueron probadas.

Red neuronal	Exactitud
VGG16	50.09%
VGG19	49.98%
ResNet	52.07%
LeNet	47.88%

9.2 Segunda etapa – “Aumento de datos”

En esta etapa se duplicó la base de datos obtenida inicialmente, con la finalidad de seguir probando las redes neuronales convolucionales y verificar si era necesario realizar modificaciones en los parámetros para mejorar el rendimiento de los algoritmos. En esta etapa AlexNet, VGG16 y ResNet fueron evaluadas, se obtuvieron buenos porcentajes de exactitud. La mejor exactitud fue obtenida por VGG16 con 87.79% de exactitud, después ResNet con 86.54% y por último AlexNet con una exactitud del 84.93%. El utilizar esta técnica para aumentar el banco de datos mejoró la exactitud en todas las redes neuronales convolucionales aplicadas en esta etapa (Tabla 4).

Tabla 4. Resultados de la redes neuronales convolucionales probadas en la segunda etapa; VGG16, ResNet y AlexNet.

Red Neuronal	Exactitud
AlexNet	84.93%
ResNet	86.54%
VGG16	87.79%

9.3 Tercera etapa – Prueba experimental

Posteriormente las redes neuronales convolucionales fueron probadas con una base de datos de 400 radiografías laterales de cráneo (200 radiografías con vía aérea superior obstruida y 200 con vía aérea superior abierta). Se probaron 3 diferentes tipos de CNN; AlexNet, ResNet y VGG16 para valorar en cual obtendríamos mayor exactitud y se midieron diferentes parámetros; especificidad, sensibilidad y el valor-F donde se obtuvieron resultados positivos en todas, se definió que las redes neuronales convolucionales utilizadas en el presente estudio, nos probaron ser una buena herramienta para la clasificación de imágenes, en este caso en radiografías laterales de cráneo.

Exactitud

La Red Neuronal Convolutiva VGG16 mostró la mayor exactitud, se logró un porcentaje de 88.97% (Tabla 5), se obtuvieron 182 radiografías de la vía aérea obstruida clasificadas como correctas y 181 radiografías de la vía aérea abierta clasificadas de manera correcta, después, ResNet obtuvo una exactitud de 85.83% (Tabla 6), se

identificaron 170 radiografías de la vía aérea obstruida clasificadas como correctas y 179 radiografías de la vía aérea abierta clasificadas de manera correcta, y por último AlexNet 83.82% de exactitud (Tabla 7), se identificaron 168 radiografías con la vía aérea superior obstruida de manera correcta y 174 radiografías con la vía aérea abierta. Con la base de datos con la que fue previamente entrenada fue capaz de obtener resultados favorables, debido a que sobrepasan el 80% de exactitud en cada una de ellas, esto confirma la hipótesis, las redes neuronales convolucionales son capaces de clasificar la apertura de la vía aérea superior a partir de una radiografía lateral de cráneo. Las CNNs son una herramienta que puede apoyar al clínico en la fase diagnóstica.

Tabla 5. Resultados de la matriz de confusión de la CNN; VGG16.

VGG16		PREDICCIÓN	
		POSITIVO	NEGATIVO
ACTUAL	POSITIVO	182	18
	NEGATIVO	27	181

Tabla 6. Resultados de la matriz de confusión de la CNN; ResNet.

ResNet		PREDICCIÓN	
		POSITIVO	NEGATIVO
ACTUAL	POSITIVO	170	30
	NEGATIVO	29	179

Tabla 7. Resultados de la matriz de confusión de la CNN; AlexNet.

AlexNet		PREDICCIÓN	
		POSITIVO	NEGATIVO
ACTUAL	POSITIVO	168	32
	NEGATIVO	34	174

Sensibilidad

En cuanto a la sensibilidad de las CNNs, se refiere al porcentaje de casos positivos, se refiere a los casos que detectó la CNN la vía aérea obstruida de manera correcta en cada una de las radiografías examinadas. VGG16 obtuvo de igual manera el porcentaje más alto con 91%, ResNet 85% y AlexNet con 84% de sensibilidad para detectar la vía aérea obstruida (Tabla 8).

Especificidad

En este caso, se refiere a las radiografías que fueron detectados por la CNN con la vía aérea abierta, como resultados se obtuvo VGG16 con un 87%, ResNet 86% y AlexNet 83% de especificidad (Tabla 8).

Valor-F

Este valor se describe como el promedio de exactitud en detección de casos negativos como los positivos, es decir el promedio de los casos que fueron clasificados correctamente con vía aérea obstruida tanto los casos que fueron clasificados con vía aérea abierta. Se obtuvo de resultado VGG16 con 88% ResNet 85% y AlexNet con 83% (Tabla 8).

Tabla 8. Resultados de la exactitud, sensibilidad, especificidad, F-score.

	EXACTITUD	SENSIBILIDAD	ESPECIFICIDAD	F-SCORE
AlexNet	83.82%	0.84	0.83	0.83
ResNet	85.83%	0.85	0.86	0.85
VGG16	88.97%	0.91	0.87	0.88

DISCUSIÓN

El uso de la inteligencia artificial en el sector salud se ha incrementado a través de los años debido a su éxito en los estudios realizados. Las redes neuronales convolucionales son un tipo de inteligencia artificial diseñadas específicamente para procesar datos, como imágenes o señales de audio (44). Inspiradas en la forma en que el cerebro humano procesa información visual, las CNNs demuestran ser extremadamente efectivas en la tarea de reconocimiento de patrones y clasificación de imágenes. En ortodoncia, la IA se ha implementado para ayudar al odontólogo durante fases diagnósticas, con el fin de proporcionar herramientas que sean útiles para desarrollar tratamientos con éxito en los pacientes (45). Uno de los principales problemas durante el diagnóstico inicial en ortodoncia, es la identificación de aquellos pacientes con alguna alteración en la apertura de la vía aérea (46), a pesar de las estrategias actuales para su identificación, sigue siendo complejo para el ortodoncista diagnosticar la vía aérea obstruida, por lo que el objetivo de este trabajo fue evaluar si las redes neuronales convolucionales son capaces de clasificar con exactitud la vía aérea superior abierta u obstruida a través de radiografías laterales de cráneo.

Para alcanzar dicho objetivo, el trabajo se desarrolló en tres etapas, las cuales serán discutidas por separado para su mejor entendimiento.

Primera Etapa- Prueba piloto

Las redes neuronales convolucionales evaluadas en este estudio se comportaron de manera similar, sin embargo, algunas demostraron mejor desempeño que otras durante las etapas de este trabajo, lo que permitió seleccionar aquellas que fueran óptimas para la clasificación de las radiografías laterales de cráneo de pacientes con vía aérea abierta y obstruida. En la primera etapa del estudio (prueba piloto), se evaluó una base de datos de 75 radiografías por grupo, sin embargo, los resultados no fueron favorables; ResNet 52.07%, VGG16 50.09%, VGG-19 49.98% y LeNet 47.88%, lo cual demuestra una deficiencia de desempeño de las CNNs. A pesar de presentar una exactitud baja, el objetivo de esta etapa era realizar un primer acercamiento a la clasificación de las imágenes e identificar aquellas redes que fueran más prometedoras para ser utilizadas en las siguientes etapas, es importante tener en consideración que una baja exactitud está relacionada con el uso de una base de datos escasa, previamente, Kim et al. al evaluar la maduración de las vértebras con el uso de las CNNs como ResNet50, una red similar a las evaluadas en el presente estudio, obtuvieron un porcentaje de exactitud de un 62.5%, concluyen que la causa de un porcentaje bajo estaba relacionado con el uso de una base pequeña de radiografías (n= 100) (26). Como mencionan Showkat et al. en su estudio, la escasez de datos puede comprometer la

solidez de los modelos de CNNs, lo que resalta la importancia de contar con bases de datos extensas para obtener un mejor rendimiento (47).

Por otro lado, Balasubramaniam et al. informaron en su estudio sobre el uso del modelo LeNet para el reconocimiento de imágenes, donde se logró un 89.91% de exactitud, sin embargo, su análisis se centró en imágenes obtenidas a partir de ultrasonidos, mientras que nuestro estudio se enfocó en radiografías laterales de cráneo. Además, la arquitectura de LeNet puede no ser lo suficientemente profunda como para capturar las características complejas de los tejidos blandos en una radiografía, lo que podría limitar su rendimiento en esta tarea (48). Aunado a esto, AlexNet es un modelo de CNN que es una extensión del modelo LeNet, es decir, AlexNet tiene un arquitectura más profunda según la literatura en comparación con LeNet(49).

El propósito era evaluar el desempeño de las mejores CNNs durante la etapa de prueba piloto y dado a lo mencionado anteriormente de la CNN; AlexNet, se decidió realizar la segunda prueba agregando esta red, ya que es una de las redes con mayor porcentaje de exactitud al realizar la tarea de identificación e clasificación de imágenes según la literatura (50).

Segunda Etapa-“Aumento de Datos”

Durante la segunda etapa de aumento de datos, se observó un aumento significativo en los porcentajes de exactitud. Este incremento se debió a que se amplió la base de datos mediante la aplicación de modificaciones a las imágenes existentes para producir imágenes sintéticamente modificadas. (51). Bashar et al. llevaron a cabo un estudio similar en el cual también implementaron la técnica de aumento de datos para mejorar el rendimiento de las CNNs. Asimismo, evaluaron diferentes arquitecturas de CNNs, incluyendo AlexNet, GoogleNet, VGG16, VGG19 y DenseNet. La red que logró el porcentaje más alto de exactitud, fue VGG16 con un 95.63%. A pesar de que el porcentaje de exactitud más alto en este estudio (87.79%) es menor al reportado en el estudio de Bashar et al., es importante destacar que VGG16 fue de igual forma, la red con mejor exactitud y que la diferencia en el porcentaje seguramente está relacionada con la naturaleza y el contexto en el que las radiografías fueron analizadas tanto en el estudio de Bashar et al. y el presente (49). Tanto VGG16 como VGG19 son arquitecturas de CNN diseñadas para la clasificación de datos visuales a gran escala, lo cual sugiere que, cuando se cuenta con una base de datos más extensa, estas CNNs pueden ofrecer un mejor rendimiento (49).

En ese mismo contexto, Gulakala et al. realizaron estudio con una base de datos de 417 radiografías de tórax, y por medio de la técnica de aumento de datos, lograron

aumentar hasta 2000 radiografías, tres tipos de CNNs se evaluaron; DenseNet, ResNet y IBNRUN GAN (Generative adversarial network), y como resultados se obtuvo que ResNet desarrolló la mayor exactitud al alcanzar un 99.2%, en este sentido, se evidenció que el aumento de datos es un factor determinante para que las CNNs como ResNet obtengan un mejor desempeño, en este estudio, ResNet logró 86.54% de exactitud, razón por la cual se decidió seleccionarla para su evaluación en la etapa final (etapa de prueba experimental) (52).

De la evidencias anteriores podemos comprobar lo dicho por Sarwinda et al. debido a que el describe que el modelo ResNet tiene una ventaja sobre la arquitectura de otros modelos debido a que el rendimiento de este modelo no disminuye a pesar de que la arquitectura se hace más profunda, y tiene la capacidad de entrenar mejor que otras CNN porque las convoluciones ramificadas reducen los parámetros generales, al mantener la red más ligera (53).

Por otra parte, en esta etapa se evaluó un nuevo modelo de CNN; AlexNet, la cual desarrolló el menor porcentaje de exactitud comparado con las otras CNN (VGG16 y ResNet), sin embargo, su desempeño no fue malo (84.93%). Como previamente se había mencionado, AlexNet es un modelo con mayor profundidad en comparación con LeNet, y aún así no se obtuvo la mayor exactitud, pero de este modo, podemos respaldar el seguimiento de esta CNN en el estudio debido a que Eldem et al. mencionaron que la arquitectura AlexNet se utiliza con éxito para resolver diferentes problemas de clasificación tal como se hizo en el estudio, este tiene la particularidad de permitir modificaciones en su arquitectura, como cambiar el número de capas para aumentar la probabilidades de realizar una clasificación exitosa, por lo que se pueden realizar estas modificaciones para mejorar nuestra exactitud (54).

Tercera Etapa-Prueba Experimental

En la tercera fase experimental del estudio, evaluamos las tres CNNs seleccionadas: AlexNet, ResNet y VGG16. Se observó un ligero incremento en los porcentajes de exactitud, al alcanzar un 88.97% con VGG16. Este aumento es notable si lo comparamos con los resultados obtenidos en la prueba piloto, donde los porcentajes se encontraban alrededor del 50%. Este progreso se debe al aumento gradual de datos proporcionados a las CNNs a lo largo del estudio. Al incrementar la cantidad de datos, las CNNs demostraron un desempeño más eficiente y favorable. Estos resultados refuerzan la idea de que las CNNs son beneficiosas en la clasificación de imágenes bidimensionales, como las radiografías laterales de cráneo (55).

En un estudio llevado a cabo por Tsuiki et al. con el objetivo de investigar si el aprendizaje automático podría ser utilizado para detectar pacientes con SAO grave a partir de imágenes bidimensionales. Utilizaron el modelo VGG-19, una red neuronal convolucional profunda diseñada para aprender características locales de las imágenes y sus resultados mostraron un alto porcentaje de exactitud (56). En este estudio se incluyó una red similar VGG16 (88.97% de exactitud), el cual coincide con el resultado obtenido por Tsuiki et al., en ese sentido, se puede sugerir que el modelo VGG representa un opción viable para identificar ciertas regiones en imágenes bidimensionales, como radiografías laterales de cráneo. Relacionado a esto, Kong et al. describieron en su estudio al modelo VGG como un módulo simple compuesto por un pequeño núcleo convolucional, un pequeño núcleo de agrupación y ReLU (rectified linear unit), lo que hace que VGG sea una red que simplifica la estructura de las redes neuronales y no solo puede aumentar la profundidad de la red sino también mejorar el rendimiento haciéndola más efectiva, lo que se puede comprobar en este estudio donde se obtuvo la mayor exactitud al evaluar este modelo (57).

Por otro lado, Li et al. llevaron a cabo un análisis de radiografías laterales de cráneo para clasificar la maduración de las vértebras cervicales, consideraron varios modelos de CNN, incluyeron VGG16, GoogLeNet, DenseNet161 y ResNet. Los resultados mostraron que ResNet fue la red con el mayor porcentaje de exactitud, se reportó un 67.06% de exactitud (28). Es importante destacar que ResNet ha demostrado ser una de las CNN más exitosas en este tipo de estudios para clasificación de radiografías, ResNet es un modelo conveniente y confiable para la clasificación de imágenes.

Durante esta última etapa de experimentación, se decidió continuar con la evaluación de la red AlexNet como modelo de prueba, esta decisión se basó en su buen desempeño en la etapa anterior, donde, a pesar de no haber obtenido la mayor exactitud, demostró un rendimiento aceptable. Este hecho se respalda también por el estudio realizado por Vasdev et al. quienes analizaron y clasificaron diversas patologías dentales a partir de radiografías periapicales, se utilizaron modelos como ResNet18, ResNet34 y AlexNet, y se destacó que AlexNet logró el mejor resultado de exactitud con un 85%. Estos hallazgos sugieren que AlexNet funciona eficazmente con datos previamente no vistos y puede ser útil en el diagnóstico y clasificación de una variedad de enfermedades dentales (42).

Sensibilidad, especificidad y valor-F

La sensibilidad nos indica los casos que fueron detectados correctamente con presencia de enfermedad (vía aérea obstruida), la especificidad indica lo contrario, es decir los casos de ausencia de enfermedad (vía aérea abierta), mientras que el valor-F es una balance entre especificidad y sensibilidad. En el estudio los resultados fueron proporcionales al porcentaje de exactitud, es decir, VGG16 obtuvo la exactitud más alta, y así lo fue con su sensibilidad, especificidad y valor-f, y así respectivamente con las otras CNNs (ResNet y AlexNet). Si lo comparamos con los estudios de Monshi et al, donde utilizaron CNN similares a las del estudio (ResNet y VGG160), sus valores obtenidos de igual manera son proporcionales a su exactitud, al reportar que la red con mayor exactitud presenta la mayor sensibilidad, especificidad y valor-f (EfficientNet-B0 con un porcentaje de exactitud de 88.02%, sensibilidad de 88.03%, valor-f de 88%), y por consiguiente la CNN con la segunda exactitud más alta es la misma que tiene los siguientes valores más altos de sensibilidad, especificidad y valor -f (51).

Para finalizar podemos concluir que la detección de los tejidos blandos (vía aérea superior) por parte de las CNNs resultaron con porcentajes favorables. En última instancia, es importante destacar que la mayoría de los estudios que utilizan CNNs para la clasificación de imágenes bidimensionales, como radiografías, se centran en la detección de tejidos duros, como huesos. Sin embargo, este estudio se enfoca en la vía aérea superior, la cual consiste en tejidos blandos. Identificar tejidos blandos es posiblemente uno de los desafíos más complejos en la aplicación de inteligencia artificial, al menos en radiografías bidimensionales. Esto se debe a que los tejidos blandos tienen un bajo contraste en los rayos-X y tienden a tener niveles de intensidad similares, lo que dificulta que las CNNs los distingan entre sí, además, pueden superponerse con estructuras circundantes, como huesos u órganos, lo que dificulta aún más que las CNNs establezcan los límites de los tejidos blandos (58). A pesar de las limitaciones de los tejidos blandos, en este estudio se obtuvieron porcentajes de exactitud superiores al 80%, anteriormente Song et al. estudiaron anomalías y calcificaciones en tejidos blandos que se pueden encontrar en la radiografía panorámica, analizaron ganglios linfáticos y la arteria carótida (72% y 92% de exactitud respectivamente), estructuras que no suelen identificarse en una radiografía panorámica, pero con las CNN lograron obtener buenos resultados en la identificación de determinadas anomalías (59).

CONCLUSIONES

Las redes neuronales convolucionales son capaces de identificar y clasificar la vía aérea superior a partir de una radiografía lateral de cráneo.

El aumento de datos es una estrategia que te permite seleccionar las CNNs más prometedoras para el análisis de imágenes cuando estas son escasas o cuando no existe un precedente de uso de la CNN con el objetivo planteado.

La exactitud obtenida por las CNNs evaluadas, sugiere que pueden ser un instrumento de gran utilidad en la fase diagnóstica para el ortodoncista.

BIBLIOGRAFÍA

1. Plaza S, Reimpell A, Silva J, Montoya D. Relationship between skeletal class II and class III malocclusions with vertical skeletal pattern. *Dental Press J of Orthod.* 2019;24(4).
2. Di Carlo G, Gili T, Caldarelli G, Polimeni A, Cattaneo PM. A community detection analysis of malocclusion classes from orthodontics and upper airway data. *Orthod Craniofac Res.* 2021;24(2):172-180.
3. Jeong Y, Nang Y, Zhao Z. Automated Evaluation of Upper Airway Obstruction Based on Deep Learning. *BioMED Research International.* 2023.
4. Castro D, Freeman LA. Oropharyngeal Airway. *Stat Pearls Publis,* 2023;1(2).
5. Agrawal A, Chaturvedi TP, Raghav M. Oropharyngeal Airway: The Orthodontist Perspective. *Int J Orthod Milwaukee.* ;27(3):51-56.
6. Jadhav P, Sonawane S, Mahajan N, Chavan B, Korde S, et al. Correlation of Pharyngeal Airway Dimensions with Maxillomandibular Skeletal Relation and Mandibular Morphology in Subjects with Skeletal Class I and Class II Malocclusions and Different Growth Patterns: A Cephalometric Study in Selected Local Population. *J Pharm Bioallied Sci.* 2021;13(1).
7. Quevedo M, Hernández A, Zambrano E, Domingos V. Upper airways evaluation through cephalometric tracings. *Rev. Odontol Univ Cid. São Paulo.* 2017; 29(3) 276-88.
8. Lee JJ, Sundar KM. Evaluation and Management of Adults with Obstructive Sleep Apnea Syndrome. *Lung.* 2021;199(2):87-101.
9. Arnaud C, Bochaton T, Pépin J, Belaidi E. Obstructive sleep apnea and cardiovascular consequences: Pathophysiological mechanisms. *Arch Cardiovasc Dis.* 2020;113(5):350-358.
10. Tepedino M, Illuzzi G, Laurenziello M, Perillo L, Taurino AM, et al. Craniofacial morphology in patients with obstructive sleep apnea: cephalometric evaluation. *Braz J Otorhinolaryngol.* 2022;88(2):228-234.
11. Shan T, Tay FR, Gu L. Application of Artificial Intelligence in Dentistry. *J Dent Res.* 2021;100(3):232-244.


12. Schwendicke F, Samek W, Krois J. Artificial Intelligence in Dentistry: Chances and Challenges. *J Dent Res.* 2020;99(7):769-774.
13. Ghosh A, Sultana F, Sufian A, Chakrabarti A, De D. Fundamental concepts of Convolutional Neural Network. *Research Gate.* 2020;1(1): 2-40.
14. Kabir H. Convolutional Neural Network. *Research Gate.* 2021;1(1); 1-9.
15. Teuwen J, Moriakov N. Convolutional Neural Networks. *Handbook of Med Ima Compu and comput Assit Inter.* 2020;20(1);481-501.
16. LeCunn Y, Bengio Y, Hinton G. Deep learning. *Nature* 2015;521;436-444.
17. Bezdán T, Bacanin N. Convolutional Neural Network layers and architecture. *Sinteza.* 2019;1; 445-451.
18. Yang J, Zhao J, Lu L, Pan T, Jubair S. A New Improved Learning Algorithm for Convolutional Neural Networks. *Processes.* 2020; 1(8); 295.
19. Borja R, Monleón A, Rodellar J. Standardization of performance metrics for classifiers. *Machine y Deep Learning. Iber Jour of Inform Systems and Technologies.* 2020; 30(6);184-196.
20. Suresh A. What is a confusion matrix?. *Analyt Vydhia.* 2020; 1(2);1-10.
21. Schwendicke F, Rossi J, Göstemeyer G, Elhennawy K, Cantu AG, et al. Cost-effectiveness of Artificial Intelligence for Proximal Caries Detection. *J Dent Res.* 2021;100(4):369-376.
22. Liu J, Chen Y, Li S, Zhao Z, Wu Z. Machine learning in orthodontics: Challenges and perspectives. *Adv Clin Exp Med.* 2021;30(10):1065-1074.
23. Yassir YA, Salman AR, Nabbat SA. The accuracy and reliability of WebCeph for cephalometric analysis. *J Taibah Univ Med Sci.* 2021 Sep 22;17(1):57-66.
24. Kunz F, Stellzig-Eisenhauer A, Zeman F, Boldt J. Artificial intelligence in orthodontics: Evaluation of a fully automated cephalometric analysis using a customized convolutional neural network. *J Orofac Orthop.* 2020;81(1):52-68.
25. Kök H, Acilar A, İzgi M. Usage and comparison of artificial intelligence algorithms for determination of growth and development by cervical vertebrae stages in orthodontics. *Prog Orthod.* 2019 Nov 15;20(1):41.

26. Kim E, Oh I, So J, Kang J, Le V, et al. Estimating Cervical Vertebral Maturation with a Lateral Cephalogram Using the Convolutional Neural Network. *J Clin Med*. 2021 Nov 19;10(22):5400.
27. Yao J, Zeng W, He T, Zhou S, Zhang Y, et al. Automatic Localization of Cephalometric Landmarks Based on Convolutional Neural Network. *AmerJourn of Orthod and Dento Orthop*. 2022. 161(3): 250–e259.
28. Li H, Chen Y, Wang Q, Gong X, Lei Y, et al. Convolutional Neural Network-Based Automatic Cervical Vertebral Maturation Classification Method. *Dentomaxillofac Radiol*. 2022;51(6).
29. Li H, Xu Y, Lei Y, Wang Q, Gao X. Automatic Classification for Sagittal Craniofacial Patterns Based on Different Convolutional Neural Networks. *Diagnostics*. 2022 May 31;12(6):1359.
30. Jeon S, Lee K. Comparison of cephalometric measurements between conventional and automatic cephalometric analysis using convolutional neural network. *Prog Orthod*. 2021; 31;22(1):14.
31. Shujaat S, Jazil O, Willems H, Van Gerven A, Shaheen E, et al. Automatic segmentation of the pharyngeal airway space with convolutional neural network. *J Dent*. 2021;111.
32. LeCun, Y, Bottou, L, Bengio, Y, Haffner, P. Gradient-based learning applied to document recognition: Proceedings of the IEEE. 1998.
33. Kusano, M, Kise, K, Uchida, S, Iwamura, M. Feature Extraction Using Deep Neural Networks for Improving the Classification of Pigmented Skin Lesions: Sensors. 2021.
34. Krizhevsky A, Sutskever I, Hinton G. ImageNet Classification with Deep Convolutional Neural Networks. *Neu Info Proc Syst*. 2012; 25(1).
35. Le Cun Y, Boser B, Denker J, Henderson D, Howard R, et al. Handwritten digit recognition with a back-propagation network. In *Advances in neural information processing systems*. 1990.

36. He K, Zhang X, Ren S, Sun J. Deep Residual Learning for Image Recognition: In Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. 2016.
37. Srivastava N, Hinton G, Krizhevsky A, Sutskever I, Salakhutdinov R. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*. 2014; 15:1929–1958.
38. Liang, J. Image classification based on RESNET. *Jour of Phys*. 2020.
39. Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition: In Proceedings of the 3rd International Conference on Learning Representations. 2015.
40. Guan Q, Wang Y, Ping B, Li D, Du J, et al. Deep convolutional neural network VGG-16 model for differential diagnosing of papillary thyroid carcinomas incytological images. *Jour of Canc*. 2019; 10(20): 4876-4882.
41. 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 Jan 17;23(1):28.
42. Vasdev D, Gupta V, Shubham S, Chaudhary A, Jain N, et al. Periapical dental X-ray image classification using deep neural networks. *Ann Oper Res*. 2022 Sep 15:1-29.
43. Khazaei M, Mollabashi V, Khotanlou H, Farhadian M. Automatic determination of pubertal growth spurts based on the cervical vertebral maturation staging using deep convolutional neural networks. *J World Fed Orthod*. 2023 Apr;12(2):56-63.
44. Mutasa S, Sun S, Ha R. Understanding artificial intelligence-based radiology studies: CNN architecture. *Clin Imaging*. 202; 80:72-76.
45. Bichu YM, Hansa I, Bichu AY, Premjani P, Flores-Mir C, et al. Applications of artificial intelligence and machine learning in orthodontics: a scoping review. *Prog Orthod*. 2021 Jul 5;22(1):18.

46. Lopatienė K, Šidlauskas A, Vasiliauskas A, Čečytė L, Švalkauskienė V, et al. Relationship between malocclusion, soft tissue profile, and pharyngeal airways: A cephalometric study. *Medicina*. 2016;52(5):307-314.
47. Showkat S, Qureshi S. Efficacy of Transfer Learning-based ResNet models in Chest X-ray image classification for detecting COVID-19 Pneumonia. *Chemometr Intell Lab Syst*. 2022 May 15;224.
48. Balasubramaniam S, Velmurugan Y, Jaganathan D, Dhanasekaran S. A Modified LeNet CNN for Breast Cancer Diagnosis in Ultrasound Images. *Diagnostics (Basel)*. 2023 Aug 24;13(17):2746.
49. Bashar A, Latif G, Ben Brahim G, Mohammad N, Alghazo J. COVID-19 Pneumonia Detection Using Optimized Deep Learning Techniques. *Diagnostics (Basel)*. 2021 Oct 23;11(11):1972.
50. Alzubaidi L, Zhang J, Humaidi AJ, Al-Dujaili A, Duan Y, et al. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J Big Data*. 2021;8(1):53.
51. Monshi MMA, Poon J, Chung V, Monshi FM. CovidXrayNet: Optimizing data augmentation and CNN hyperparameters for improved COVID-19 detection from CXR. *Comput Biol Med*. 2021 Jun; 133:104375.
52. Gulakala R, Markert B, Stoffel M. Generative adversarial network-based data augmentation for CNN based detection of Covid-19. *Sci Rep*. 2022 Nov 10;12(1):19186.
53. Sarwinda D, Hilya R, Bustamam A, Anggia P. Deep Learning in image classification using Residual Network (ResNet) variants for detection of colorectal cancer. *Procedia Computer Science*. 2021;179: 423-431.
54. Eldem H, Ülker E, Yasar O. AlexNet architecture variations with transfer learning for classification of wound images. *Engineering Science and technology*. 2023;45.
55. Akay G, Akcayol MA, Özdem K, Güngör K. Deep convolutional neural network-the evaluation of cervical vertebrae maturation. *Oral Radiol*. 2023 Oct;39(4):629-638.
56. Tsuiki S, Nagaoka T, Fukuda T, Sakamoto Y, Almeida FR, Nakayama H, Inoue Y, Enno H. Machine learning for image-based detection of patients with obstructive sleep apnea: an exploratory study. *Sleep Breath*. 2021 Dec;25(4):2297-2305.

57. Kong L, Cheng J. Classification and detection of COVID-19 X-Ray images based on DenseNet and VGG16 feature fusion. *Biomedical Signal Processing and Control*. 2022; 77.
58. Masoud A, Alwadei F. Two-dimensional upper airway normative values in children aged 7 to 17 years. *The Jour of Craniomandibular and sleep practice*. 2021.
59. Song Y, Jeong H, Kim C, Kim D, Kim, et. Al. Comparison of detection performance of soft tissue calcifications using artificial intelligence in panoramic radiography. *Scientific reports*. 2022; 12.
60. Ghosh A, Sufian A, Sultana F, Chakrabarti A, De D. Fundamental Concepts of Convolutional Neural Network. *Recen Trend and Adv in Artif Intel and Inter of Things*. 2020; 172: 519-567.
61. Mintz Y, Brodie R. Introduction to artificial intelligence in medicine. *Minim Invasive Ther Allied Technol*. 2019;28(2):73-81.
62. Behrents G, Shelgikar A, Conley R, Flores-Mir C, Hans M, Levine M, Hittner, J. Obstructive sleep apnea and orthodontics: An American Association of Orthodontists White Paper. *Amer Jour of Orthod and Dentof Orthop*. 2019;156(1).
63. Khanagar S, Al-ehaideb A, Maganur P, Vishwanathaiah S, Patil S, et al. Developments, application, and performance of artificial intelligence in dentistry – A systematic review. *Jour of Dent Scien*. 2021; 16 (1): 508-522.
64. Russakovsky O, Deng J, Su H, Krause J, Satheesh S, et al. ImageNet Large Scale Visual Recognition Challenge: *Int. J. Comput. Vis*. 2015.



Otorga este

RECONOCIMIENTO ACADÉMICO

a la *Dra. Maria Paola
Romero Navarro*

Por haber completado el
Programa Calibración VAS y Adenoides,
impartida por la Dra. Maria Isabel Pizano Damasco .

Ma. Isabel Pizano Damasco
Directora Académica

Isabel Bermúdez Pizano
Directora Administrativa

Asunto
Constancia

2022, Año de Ricardo Flores Magón
100 Aniversario de la Escuela Superior de Ingeniería y Arquitectura
50 Aniversario de la UPIICSA
50 Aniversario del CECyT 10 "Carlos Vallejo Márquez"
25 Aniversario del CIECAS, CIITEC y del CIDIR, Unidad Sinaloa

Ciudad de México, 8 de julio de 2022

A quien corresponda
PRESENTE

Por medio de la presente se hace constar que la **C.D. María Paola Romero Navarro** ha concluido satisfactoriamente la materia "**Redes Neuronales Convolucionales**" impartida en modalidad virtual, en el Centro de Innovación y Desarrollo Tecnológico en Cómputo del Instituto Politécnico Nacional.

Sin otro particular, reciba un cordial saludo.

ATENTAMENTE
"La Técnica al Servicio de la Patria"



S. E. P.
INSTITUTO POLITÉCNICO NACIONAL
CENTRO DE INNOVACIÓN Y DESARROLLO
TECNOLÓGICO EN CÓMPUTO

Dr. Elías Jesús Ventura Molina
Jefe del Departamento de Investigación e Innovación Científica y Tecnológica
Centro de Investigación y Desarrollo Tecnológico en Cómputo
Instituto Politécnico Nacional

Tel. 57296000 ext.52523
eventuram@ipn.mx

Av. Juan de Dios Bátiz s/n esq. Miguel Othón de Mendizábal, Col. Nueva Industrial Vallejo, Del. Gustavo A. Madero, Ciudad de México, C.P. 07700.
Tel: (55) 57296000 Ext. 52516, cidetec@ipn.mx



2022 Flores