



# **Evaluación del rendimiento de una Red Neuronal Generativa Antagónica en la Generación de un banco de imágenes de radiografías panorámicas dentales humanas**

**María Camila Vivas Gasca  
Erlyn Julián Cediél Sánchez**

Universidad Antonio Nariño  
Facultad de Ingeniería Mecánica, Electrónica y Biomédica  
Neiva, Colombia  
2020

# **Evaluación del rendimiento de una Red Neuronal Generativa Antagónica en la Generación de un banco de imágenes de radiografías panorámicas dentales humanas**

**María Camila Vivas Gasca  
Erlyn Julián Cediél Sánchez**

Proyecto de grado presentado como requisito parcial para optar al título de:  
**Ingeniero Electrónico**

Director (a):

PhD. MARIO ENRIQUE DUARTE GONZÁLEZ

Línea de Investigación:

Inteligencia Computacional

Grupo de Investigación:

GIBIO (Grupo de Investigación en Bio-instrumentación y Control)

Universidad Antonio Nariño

Facultad de Ingeniería Mecánica, Electrónica y Biomédica

Neiva, Colombia

2020

## *Dedicatoria*

*Como primer lugar quiero dedicar a Dios y a la santísima Virgen María este trabajo. A mis padres María del Pilar Gasca y Hernando Vivas, por su amor, apoyo incondicional y su manera de enfrentar las dificultades que se presentan. A mi hermana Diana Carolina Vivas por su ejemplo de persistencia y dedicación. Gracias a ellos, le puse todo mi empeño a este trabajo.*

*María Camila Vivas Gasca*

*Primero que todo agradezco a Dios, mi tesis la dedico a mis padres Héctor Cediél y Eidalý Sánchez por su sacrificio y esfuerzo, por haberme formado como persona, en ellos veo el espejo en el que me quiero reflejar por sus grandes virtudes que me llevan a admirarlos. Gracias, padre y madre.*

*Erlyn Julián Cediél Sánchez*

## **Agradecimientos**

A Dios y a la santísima Virgen por su intersección durante el desarrollo del trabajo, a mi padre Hernando Vivas Ramírez por ser la fuerza en situaciones adversas, por sus enseñanzas y sacrificios, a mi madre María del Pilar Gasca por su incondicional apoyo, comprensión, paciencia y amor brindado, a mi hermana Diana Carolina Vivas por ser ejemplo de persistencia, a toda mi familia por su cimiento de sabiduría y cariño ofrecido y a mi compañero Erlyn Julián Cediel por su entrega, dedicación y apoyo.

*María Camila Vivas Gasca*

En primera instancia agradezco a Dios por permitirme gozar de salud a mí y a mi familia para poder disfrutar de ellos cada día y poder apoyarme en cada paso que doy en mi vida y enseñarme lo bondadosa que es la vida cuando se hacen las cosas con compromiso y amor, a mi compañera María Camila Vivas por sus esfuerzos y compromisos para el desarrollo de la tesis.

*Erlyn Julián Cediel Sánchez*

Total, Admiración y agradecimiento a PhD. Mario Enrique Duarte González quien depositó su confianza en nuestro proyecto, agradecemos por su paciencia, dedicación, tiempo, amor y entrega durante el desarrollo de este trabajo, así mismo, a los doctores, odontólogos, especialistas que hicieron esto posible.

Agradecemos a nuestra Universidad Antonio Nariño por abrirnos la puerta del baúl del conocimiento, por permitirnos compartir con excelentes compañeros, por brindarnos todas las herramientas y recursos para enfrentarnos a los retos académicos, en especial un agradecimiento infinito al personal administrativo de la sede Neiva Buganviles, al Vicerrector seccional, a la Secretaría Académica, a la coordinadora de Bienestar, La

vicedecana de la facultad y todos los colaboradores de la institución por apoyarnos en nuestro proceso de formación profesional y por impulsarnos a culminar con plena satisfacción esta etapa.

## Resumen

Desde la ingeniería se han planteado diferentes herramientas tecnológicas para apoyar el ejercicio de los profesionales de la salud, en tales desarrollos se analizan y procesan grandes volúmenes de información médica con la que se caracterizan las poblaciones que se pretenden beneficiar. Sin embargo, para acceder a los datos de registros médicos de una persona es necesario tener su permiso, pues es información privada y confidencial, por lo que la consecución de varios miles de datos puede tornarse tediosa, demorar el proceso investigativo o limitar los resultados. Tal es el caso de varios proyectos que se han desarrollado en el área de Odontología, en particular los trabajos relacionados con el uso de algoritmos de procesamiento digital de imágenes y técnicas de inteligencia artificial, en los que los autores plantean la necesidad de acceder a bancos de imágenes más numerosos para mejorar el rendimiento de sus soluciones. Una alternativa es la creación de imágenes sintéticas realistas por medio de la edición digital y recientemente a través de la implementación de redes neuronales generativas antagónicas. Por tal motivo, en este documento, se evalúa el rendimiento de una Red Neuronal Generativa Antagónica en la generación de un banco de imágenes de radiografías panorámicas dentales humanas a partir de 300 imágenes reales, verificando la calidad de las imágenes generadas del algoritmo de aprendizaje automático por medio de una encuesta que se les realizó a profesionales de la salud dental y personas que no tienen conocimiento alguno sobre el tema; por medio de esta se concluye que la características para determinar si una imagen es real o no, es la exaltación de puntos y distorsión de la imagen. Se evidencia que para el mejor caso de experimento, se encontró que la probabilidad dado que una imagen se presenta como creada y pase como imagen real fue del 0,4 en promedio para ambos grupos encuestados.

**Palabras clave:** GAN, Radiografías Panorámicas Dentales, Banco de Imágenes

## Abstract

From engineering, different technological tools have been proposed to support the exercise of health professionals, in such developments large volumes of medical information are analyzed and processed with which the populations that are intended to be beneficiaries are characterized. However, to access a person's medical record data, it is necessary to have their permission, as it is private and confidential information, so obtaining several miles of data can become tedious, delay the investigative process or limit the results. Such is the case of several projects that have been developed in the area of Dentistry, particularly work related to the use of digital image processing algorithms and artificial intelligence techniques, in which the authors raise the need to access banks more images to improve the performance of your solutions. An alternative is the creation of realistic synthetic images through digital editing and recently through the implementation of antagonistic generative neural networks. For this reason, in this document, the performance of an Antagonic Generative Neural Network is evaluated in the generation of an image bank of panoramic human dental radiographs from 300 real images, which verified the quality of the images generated by the algorithm of machine learning through a survey that was carried out to dental health professionals and people who do not know whatsoever on the subject, whereby means of this it is concluded that the characteristics to determine whether an image is real or not, are the exaltation of points and distortion of the image, where it is evidenced that for the best case of an experiment, it was found that the probability given that an image is presented as created and passes the image as real was 0.4 on average for both groups surveyed

**Keywords: GAN, Panoramic Dental Radiographs, Image Bank**

# Contenido

	Pág.
INTRODUCCIÓN.....	1
PLANTEAMIENTO DEL PROBLEMA.....	4
JUSTIFICACIÓN.....	5
ESTADO DE ARTE.....	7
OBJETIVOS.....	13
OBJETIVO GENERAL.....	13
OBJETIVOS ESPECÍFICOS.....	13
<b>CAPÍTULO 1.....</b>	<b>14</b>
<b>1. MARCO REFERENCIAL.....</b>	<b>14</b>
1.1 MARCO CONCEPTUAL.....	14
1.1.1 <i>Redes Neuronales Artificiales</i> .....	14
1.1.2 <i>Redes Neuronales Generativas Antagónicas</i> .....	15
1.1.3 <i>Modelo Generador (G)</i> .....	16
1.1.4 <i>Modelo Discriminador (D)</i> .....	18
1.1.5 <i>Procesamiento de Imagen médica</i> .....	19
1.2 MARCO LEGAL.....	19
<b>CAPÍTULO 2.....</b>	<b>21</b>
<b>2. METODOLOGÍA.....</b>	<b>21</b>
2.1 ARQUITECTURA.....	27
2.1.1 <i>Organización del directorio del banco de imágenes Rx panorámicas dentales de entrada</i> .....	27
2.1.2 <i>Ruido</i> .....	28
2.1.3 <i>Arquitectura de la Red Neuronal Generadora</i> .....	29
2.1.4 <i>Normalización de Datos</i> .....	31
2.1.5 <i>Arquitectura de la Red Neuronal Discriminadora</i> .....	32
2.2 ENTRENAMIENTO.....	33
2.2.1 <i>Entrenamiento de la Red Discriminadora</i> .....	33
2.3 CREACIÓN DE LA RED NEURONAL GENERATIVA ANTAGÓNICA.....	35
2.4 PRODUCCIÓN DE IMÁGENES DE RAYOS X PANORÁMICAS DENTALES HUMANAS.....	35

---

2.5	HERRAMIENTA COMPUTACIONAL PARA LA CONSTRUCCIÓN DE LOS ALGORITMOS .....	36
2.6	CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN .....	36
2.7	CARACTERÍSTICAS DE CLASIFICACIÓN DE LA IMAGEN .....	37
2.8	EVALUACIÓN DE LAS IMÁGENES GENERADAS .....	37
<b>CAPÍTULO 3 .....</b>		<b>40</b>
<b>3.</b>	<b>EXPERIMENTOS, EVALUACIÓN, RESULTADOS, LIMITACIONES Y DISCUSIONES .....</b>	<b>40</b>
3.1	EXPERIMENTOS REALIZADOS .....	40
3.2	EVALUACIÓN.....	42
3.3	RESULTADOS.....	43
3.4	LIMITACIONES .....	45
3.5	DISCUSIONES .....	46
<b>CAPÍTULO 4 .....</b>		<b>50</b>
<b>4.</b>	<b>CONCLUSIONES Y RECOMENDACIONES.....</b>	<b>50</b>
4.1	CONCLUSIONES .....	50
4.2	RECOMENDACIONES .....	51
<b>5.</b>	<b>ANEXOS .....</b>	<b>53</b>
5.1	ENCUESTA .....	53
5.2	BANCO DE IMÁGENES GENERADO POR MEDIO DE LA GAN .....	59
5.3	TABLAS DE CONFUSIÓN DE LOS EXPERIMENTOS .....	59
<b>6.</b>	<b>BIBLIOGRAFÍA .....</b>	<b>61</b>

## Lista de figuras

	<b>Pág.</b>
<b>Figura 1- 1:</b> Modelo Generador(G)	16
<b>Figura 1- 2:</b> Modelo Discriminador (D)	18
<b>Figura 2- 1:</b> Metodología para llevar a cabo la evaluación del rendimiento de una red neuronal generativa antagónica	21
<b>Figura 2- 2:</b> Esquema de organización del directorio de entrada para la Evaluación del rendimiento de una Red Neuronal Generativa Antagónica	23
<b>Figura 2- 3:</b> Resumen de la arquitectura de la Red Neuronal Generadora	25
<b>Figura 2- 4:</b> Resumen de la arquitectura de la Red Neuronal Discriminadora	27
<b>Figura 2- 5:</b> Respuesta de Precisión de la Imagen entrenada en el discriminador	29
<b>Figura 2- 6:</b> Imagen generada del tamaño 128x96 pixeles en el primer experimento con 300 épocas	

## Lista de tablas

	<b>Pág.</b>
<b>Tabla 1:</b> Datos de entrenamiento	22
<b>Tabla 2:</b> Experimentos realizados	41
<b>Tabla 3:</b> Resultados de la evaluación de los experimentos	43
<b>Tabla 4:</b> Resultados generales de las respuestas de los Profesionales en el área de salud dental	46
<b>Tabla 5:</b> Resultados generales de las respuestas de las personas que no tienen conocimiento en el área	47

## Lista de Imágenes

	<b>Pág.</b>
<b>Imagen 1:</b> Ejemplo de imágenes real y creada en el experimento 1.	23
<b>Imagen 2:</b> Ejemplo de imágenes real y creada en el experimento 2.	24
<b>Imagen 3:</b> Ejemplo de imágenes real y creada en el experimento 3.	24
<b>Imagen 4:</b> Ejemplo de imágenes real y creada en el experimento 4.	25
<b>Imagen 5:</b> Ejemplo de imágenes real y creada en el experimento 5.	25
<b>Imagen 6:</b> Ejemplo de imágenes real y creada en el experimento 6.	25
<b>Imagen 7:</b> Ejemplo de imágenes real y creada en el experimento 7.	26
<b>Imagen 8:</b> Ejemplo de imágenes real y creada en el experimento 8.	26

## Lista de Símbolos y abreviaturas

### Símbolos con letras latinas

Símbolo	Término	Unidad SI	Definición
$X$	Ancho de la imagen	$P$	Ec. 1.1
$Y$	Largo de la imagen	$P$	Ec. 1.2
$S_X$	Stride en X	1	Ec. 1.1
$S_Y$	Stride en Y	1	Ec. 1.2
$K$	Kernel	1	Ec. 1.1
$N_d$	Normalización de datos	1	Ec. 1.3
$V_d$	Valor de dimensión de la imagen	1	Ec. 1.3
$m$	Mediana	1	Ec. 1.3
$P_c$	Probabilidad Condicional	1	Ec. 1.4
<i>ClaReal</i>	Imágenes clasificadas como Real	1	Ec. 1.4
<i>PreApa</i>	Imágenes presentadas como aparentes	1	Ec. 1.4
$E_s$	Entropía Condicional	1	Ec. 1.5
$P_i$	Probabilidad condicional de un experimento	1	Ec. 1.5

### Subíndices

Subíndice	Término
$n$	Número de Imágenes
$i$	Número de respuestas

### Abreviaturas

Abreviatura	Término
GAN'	Redes Neuronales Generativas Antagónicas
AI	Inteligencia Artificial
G	Red Generadora
D	Red Discriminadora



# Introducción

Una Red Neuronal Generativa Antagónica es un modelo discriminativo de aprendizaje automático en el que dos redes neuronales trabajan de forma competitiva, tras ser entrenadas empleando el mismo conjunto de datos. Una de las redes se conoce como generativa, es la encargada de producir nuevas señales a partir de la combinación de sus entradas. La otra red es conocida como antagónica o discriminadora, el cuál compara las señales generadas artificialmente y las usadas durante el entrenamiento para determinar si las creadas por su oponente son o no falsas. Cuando la tasa de falsas detectadas es significativa, la red generativa reajusta sus parámetros y crea nuevas señales; este proceso se repite cíclicamente hasta que la red discriminativa es incapaz de identificar que las señales generadas son falsas. En pocas palabras una Red Neuronal Generativa Antagónica, se encarga de realizar el modelamiento de un prototipo de distribución de dato o imagen real, exigiéndole a los datos creados que pasen como desapercibidos dentro de un conjunto de datos donde se encuentren ambos ejemplares (datos reales y aparentes) (Goodfellow, Pouget-Abadie, Mirza, Xu, Warde-Farley, Ozair & Bengio, 2014).

Las Redes Neuronales Generativas Antagónicas, poseen múltiples aplicaciones enfocadas en la generación de imágenes como, por ejemplo, se han implementado ampliamente en el área de multimedia para la creación de fotos y personas no reales, los resultados obtenidos en general son bastantes realistas y es complejo diferenciar entre los rasgos reales y los creados por medio de un algoritmo de aprendizaje (Sandoval, Pérez, González., Jaque & Infante, 2016).

El auge de las GAN inició en el año 2014, con la manipulación de datos reales como imágenes de personas, videos estatales y edición del audio (Torres, 2020) desde entonces, se han ido incrementando sus aplicaciones en diferentes áreas como: La Ingeniería Informática (Azuar, 2019), ingeniería Biomédica (Fernández, 2019), ingeniería Eólica

(Almeida, 2019), Biotecnología (Franco & Ramos, 2019), Multimedia (Denton, Chintala & Fergus 2015), etc.

En particular, desde el 2016 su uso se ha extendido al área de la salud donde se han empleado GAN para: análisis de la sangre para la detección de enfermedades, edición de fotos neuronales, mapeo de características interpretables en fisiopatología, generación de imágenes de rayos X (GAN'S, 2018), despeje de visibilidad en laparoscopias ( Zhang, Suk, Wang, Li, Shen & Ji, 2014), detección de enfermedad cerebral temprana (Choi, Biswal, Malin, Duke, Stewart & Sun ,2017), detección de anomalías en datos de movilidad humana, y generación de datos sintéticos de pacientes (Miyato, Kataoka, Koyama & Yoshida, 2018).

Los trabajos relacionados con la generación de registros médicos sintéticos por medio de GAN aún son pocos, sin embargo, esta es una aplicación promisoría de este tipo de redes pues representa una alternativa para la creación de grandes bases de datos con información médica a partir de unos cientos ejemplos de entrenamiento (Miyato, Kataoka, Koyama & Yoshida, 2018).

Como un ejemplo del área de la salud, la odontología emplea con frecuencia imágenes radiológicas panorámicas para el diagnóstico de diferentes patologías asociadas a los daños producidos por bacterias, fracturas o defectos congénitos en la dentadura; siendo las radiografías panorámicas de los dientes una de las más comunes (Silva, Oliveira, & Pithon, 2018)

Desde la ingeniería se han desarrollado varios trabajos en el área de la inteligencia artificial para apoyar al personal médico en el diagnóstico de lesiones por medio del procesamiento digital de imágenes combinado con algoritmos de aprendizaje automático (Silva, Oliveira & Pithon, 2018), (Mantilla & Vega, 2011), (González, 2019), (Rudas & Sánchez Torres, 2013), (Oliveira, 2009). Sin embargo, tales trabajos reportan entre sus limitaciones la falta de acceso a suficientes imágenes, por lo que plantean que, para mejorar la exactitud de sus implementaciones, es necesario entre otras cosas contar con un banco de imágenes de entrada más numeroso.

La problemática que supone la solicitud de datos y registros médicos que se ha creado entorno a la Ley Estatutaria 1581 de 2012, "Por la cuál se dictan disposiciones generales para la protección de datos personales" (Colombia, 1581 de 2012). En esta ley, se

evidencia la necesidad de desarrollar alternativas que permitan recrear e incluso aumentar los distintos conjuntos de datos de supuestos pacientes para generar una base sólida llevar a cabo las diferentes aplicaciones.

Los registros generados pueden eventualmente emplearse con fines investigativos especialmente en proyectos que involucran el desarrollo de algoritmos de inteligencia artificial como apoyo al diagnóstico médico, sin embargo, la utilidad que le puedan dar a esta es dependiente de los parámetros requeridos por el investigador o la persona que haga uso de estos, pues debido a las necesidades se presente, así mismo será su porcentaje de eficiencia.

## Planteamiento del Problema

En el área de la salud, la odontología emplea con frecuencia imágenes radiológicas panorámicas para el diagnóstico de diferentes patologías asociadas a los daños producidos por bacterias, fracturas o defectos congénitos en la dentadura, siendo las radiografías panorámicas de los dientes una de las técnicas más comunes para su detección, por el valor del procedimiento y por la alta calidad de imagen mostrada (Silva, Oliveira & Pithon, 2018).

La disponibilidad de un mayor número de imágenes médicas está supeditada al acceso a los registros de los pacientes, los cuales de acuerdo con las reglamentaciones de protección de datos personales son de carácter confidencial, por lo que con frecuencia se requiere el permiso de cada persona para usar la información (Miyato, Kataoka, Koyama & Yoshida, 2018), independientemente de si los fines son investigativos o académicos. El proceso de autorización es tedioso, en especial cuando el objetivo es elaborar grandes bancos de registros que almacenen miles o millones de datos para ser analizados o procesados por algoritmos de inteligencia artificial.

En este contexto, se propone evaluar el rendimiento de una Red Neuronal Generativa Antagónica en la producción de un banco de imágenes de radiografías panorámicas dentales humanas, para establecer si el realismo de las imágenes generadas es el requerido en la implementación de algoritmos de aprendizaje automático, lo que equivale a que sean realistas incluso bajo la evaluación de un especialista.

## Justificación

Las GAN se han ido consolidando como herramientas de apoyo en el área de procesamiento de imágenes médicas, los investigadores (Sorin, Barash, Konen, & Klang, 2020) presentan una exhaustiva revisión de varios trabajos destacados en esta área que han sido publicados en el período 2017 -2019. Se reportan alrededor de 33 proyectos, de los cuales 14 se relacionan con radiografías y 6 específicamente con la generación de imágenes sintéticas.

En (Chuquicusma, Hussein, Burt & Bagci, 2018) emplean las GAN en la generación de imágenes radiográficas para el diagnóstico de cáncer de pulmón, los autores reportan que los radiólogos no identificaron que la mayoría de las imágenes creadas no eran genuinas, en otra aplicación de las GAN se generaron 100.000 imágenes de nódulos pulmonares de forma exitosa, tal que los especialistas no identificaron varias de las imágenes sintéticas, este mismo tipo de imágenes se generaron para entrenar un algoritmo de clasificación de los nódulos pulmonares, el cual al usar mejoró su exactitud después de ser entrenado con el conjunto de imágenes generadas (Onishi, Teramoto, Tsujimoto, Tsukamoto, Saito, Toyama & Fujita, 2019), por su parte, en (Gadermayr, Li, Müller, Truhn, Krämer, Merhof & Gess, 2019) se modificaron imágenes de resonancia magnética de músculos de pacientes normales con infiltraciones de grasa para entrenar un algoritmo de aprendizaje profundo que mejoró su desempeño al incluir el conjunto de datos sintéticos, también, en (Chi, Du, Ye, Kou, Qiu, Wang & Chen, 2014) se implementaron GAN para crear imágenes realistas de resonancias magnéticas del cerebro, de acuerdo con los autores un 71% de las imágenes del conjunto generado fueron aceptadas por los especialistas como genuinas, por último, en (Russ, Goertler, Schnurr, Bauer, Hatamikia, Schad & Chung, 2019) por medio de GAN se generaron imágenes de tomografía computarizada para entrenar un

algoritmo que identifica vasos en el cuerpo, el rendimiento en la detección aumentó cuando se usó el conjunto de datos generado.

Es importante destacar que en la literatura consultada no se encontró reporte de trabajos en los que se implemente una GAN para la generación de radiografías panorámicas dentales humanas sintéticas. Por tanto, basados en los resultados presentados en la literatura y en el positivo rendimiento que han reportado las GAN en la creación de nuevas imágenes a partir de un conjunto de entrada compuesto por fotos homogéneas (Chuquicusma, Hussein, Burt & Bagci, 2018), (Onishi, Teramoto, Tsujimoto, Tsukamoto, Saito, Toyama & Fujita, 2019), (Gadermayr, Li, Müller, Truhn, Krämer, Merhof & Gess, 2019), (Chi, Du, Ye, Kou, Qiu, Wang & Chen, 2014), (Russ, Goertler, Schnurr, Bauer, Hatamikia, Schad & Chung, 2019) (Yi, Walia & Babyn 2019), (Creswell, White, Dumoulin, Arulkumaran, Sengupta & Bharath, 2018), (Yang, Yu, Dong, Slabaugh, Dragotti, Ye & Firmin, 2017) se propone el desarrollo de una GAN para evaluar su rendimiento en la creación de un banco de imágenes realista de radiografías panorámicas dentales humanas.

## Estado de Arte

A continuación, se presentan trabajos científicos recientes y destacados de Aplicaciones relacionadas con Redes Neuronales Generativas Antagónicas en la generación de bancos de imágenes, donde se exponen los objetivos de cada estudio consultado y su aporte al área de investigación.

En la revisión sistemática titulada creación de imágenes artificiales para aplicaciones de radiología utilizando redes generativas adversas (GAN) (Sorin, Barash, Konen & Klang, 2020), se estudiaron mas de 33 trabajos contextualizados con la aplicación de la red GAN para imágenes radiográficas, investigados en fuentes indexadas como MEDLINE y Google académico, con palabras claves como GAN, Adversarial Network, Radiology y Medical Imaging, que fueron clasificados de acuerdo a dos pautas, la primera fue que estuvieran en una fuente verídica como este tipo de fuentes y que estuvieran presentes en una revista de publicaciones de alto impacto, y la segunda fue que todo artículo que se fuera a analizar debería estar en lengua inglesa, por tal motivo se realizo la exclusión de bastantes trabajos. Sin embargo, se encontró calidad y cantidad, como 14 trabajos relacionados con la eliminación del ruido, 6 de aumento de datos, 8 de transferencia entre modalidades y 5 de segmentación de imágenes, el cual se concluyo que para todos los trabajos fue un éxito total, pues en toda la eficiencia del entrenamiento fue optima y los resultados fueron los esperados. Los trabajos más destacados se mencionan a continuación.

En la investigación denominada como generación de registros de salud electrónicos discretos de etiquetas múltiples utilizando medgan (Choi, Biswal, Malin, Duke, Stewart & Sun, 2017), El objetivo es la aplicación de una red MedGan por medio de la captura directa de los datos discretos generales de los registros de salud y luego evaluarlos de forma cualitativa utilizando diferentes variables de registro patológico, el cuál no se centrará en

enfermedades específicas, sino en las características sobresalientes de dos conjuntos de datos de entrada cuyo origen del primer conjunto es de la Fundación médica de Sutter palo Alto (PAMF) con 258.000 registros de pacientes entre lo 50-90 años. El segundo conjunto de datos proviene de una Base de datos libre llamada MIMIC-III, que posee 46.000 registros de pacientes de la unidad de cuidados intensivos. Los conjuntos de datos mencionados anteriormente se prueban en diversas versiones de comparación de la MedGan, donde se hace uso del modelo básico que consiste en un pre-entreno de red, también el uso de un Pre-entreno de autoencoder y Red Gan, por último, el uso de un PD y un PA, ambos pre-entrenados por un autoencoder, pero difiere en que el primero hace uso del minibatch y el segundo del promedio de este.

No solo se realizan pruebas de comparación, también se generaron experimentos con métodos muy populares generativos para evaluar y comparar el rendimiento de la Red MedGan como el Ruido Aleatorio(RN), Muestreo independiente(IS), RBM apilado(DBN) y Autoencoder (VAE); donde efectivamente en la evaluación cualitativa para variables binarias se determinó que el rendimiento del modelo para para este tipo de variables es mas desafiante por tanto como es de esperarse a la hora de la predicción de las dimensiones, que el método de IS no fue capaz de llevar a cabo una relación interdimensional, debido a su método genuino de muestreo que consiste en la estimación de densidad del núcleo para cada código para continuamente tomar muestras de esa distribución, como también en el método del VAE, se evidencia un comportamiento con baja probabilidad de ocurrencia y por último al compararlo con el DBN muestra un mejor rendimiento pero aún nueve veces más bajo que el método de MedGan.

Finalmente, posterior a realizar la evaluación comparativa de rendimiento computacional, se hizo la evaluación de comparación cualitativa por el ojo humano, que consistió en mostrar 100 datos aleatorios entre genuinos y aparentes a un medico internista, donde en una escala de 1 a 10, 7 fue la calificación de la veracidad de datos, y se concluyo que la calificación fue acertada, debido a que se presentaron errores de escasos de datos en los suministros de entrada de las patologías, frecuencias de visita y ordenes erróneas de medicación, pero en sí la red fue eficiente a pesar que en algunas imágenes se cruzaran patologías de sexo.

Un segundo trabajo fue: ¿como engañar a los radiólogos con redes adversarias generativas? Una prueba turística visual para el diagnóstico de cáncer de pulmón (Onishi,

Teramoto, Tsujimoto, Tsukamoto, Saito, Toyama, & Fujita, 2019). Para entrar más en el tema, como dato importante se obtiene que aproximadamente 1,59 millones de personas en el mundo mueren por cáncer de pulmón y las tomografías computarizadas ayudan a la detección de este en un diagnóstico temprano; siempre y cuando se observen e interpreten en las primeras etapas del cáncer, pues la aparición de Nódulos pulmonares (benignos y malignos) han sido un obstáculo ya que conducen a diagnósticos erróneos. Generar los nódulos de alta calidad, permitirá discernir características específicas de ambos grupos, que evaden los problemas que producen su baja calidad de imagen, generando características cualitativas y cuantitativas.

En este contexto, se presenta una hipótesis la cual presume que las características de cada imagen de los nódulos pulmonares falsos a comparación de los reales son complejos de discriminar. Para la prueba de tal, se planteó la prueba Visual de Turing a dos Radiólogos; además de evaluar, el propósito es capacitarlos con estas nuevas herramientas y mejorar la calidad del diagnóstico.

El conjunto de datos experimentales del presente proyecto está disponible libremente en la web, el cual se denomina LIDC-IDRI, de los cuales se aprovecharon 1145 nódulos, 635 fueron benignos y 510 malignos que se encontraban en tomografías computarizadas de tórax. Y la arquitectura implementada para la red, fue el de una red convolucional generativa antagónica profunda (DC- GAN), Este tipo de arquitectura aumenta el rendimiento de una GAN estándar mediante la normalización por lotes y la eliminación de capas, el cual solo hace uso de tres capas convolucionales con normalización por lotes y una función de activación aplicada en su última capa; también incluye un discriminador con dos capas deconvolucionales con ReLu y una capa con 3136 dimensiones con activación. Esta arquitectura se capacitó para utilizar un lote de 64 con una tasa de aprendizaje de 0.001 y 0.002 para D y G. (Después de 99000 iteraciones no se evidencia mejora en el conjunto de datos cruzados. como también, después de 114000 y 110000 respectivamente, de muestras benignas y malignas.)

Con respecto a la evaluación del experimento, se propuso la implementación de la prueba visual de Turing, con dos radiólogos de 13 y 5 años de experiencia, donde ambos fueron cegados por las muestras generadas ante los experimentos. Por tal motivo, se consideró un éxito la implementación de la DG-GAN, pues se obtuvo una calificación del 67% y 100% por parte de los especialistas.

Como tercer trabajo destacado, se encuentra el trabajo denominado “Aumento de imagen médica sintética basada en GAN para aumento del rendimiento de CNN en la clasificación de lesiones hepáticas para la detección temprana y diagnóstico rápido del cáncer hepático” (Frid-Adar, Diamant, Klang, Amitai, Goldberger & Greenspan, 2018). Se han presentado diversos métodos de clasificación automática, por medio de imágenes de tomografías computarizadas; a raíz de estos, se presenta un contexto de clasificación de lesiones hepáticas sobre una arquitectura de una red neuronal convolucional y un conjunto de datos de registros médicos que presentan quistes metastásicos y hemangiomas del Shebal Medical Center, lugar donde se adquirieron dichos casos entre los años 2009 y 2014, por medio de tomografías computarizadas con diferentes parámetros de espesor que fueron aprobados por una junta institucional.

Del conjunto de datos mencionado anteriormente, se aprovecharon 182 imágenes de tomografías computarizadas en dos dimensiones, de las cuales 53 fueron de quistes, 64 de metástasis y 65 de hemangiomas. Para dicho conjunto, se presentó una arquitectura de la red neuronal convolucional, donde se fijó un tamaño para las imágenes de entrada, en conjunto se implementó un gradiente estocástico de optimización descendiente (Nestov) para evidenciar la mejora en el proceso de optimización. Esta red se usa ampliamente para resolver tareas que intervengan en la clasificación de las imágenes digitalizadas o por computación; generalmente contiene un menor grupo de capas convolucionales, debido a que se maneja un conjunto de datos pequeño.

Como la barrera de la arquitectura de una red CNN es la falta de datos, como en todo algoritmo de aprendizaje; dado así su primer objetivo será ampliar el conjunto de datos de entrenamiento por medio de imágenes conocidas y síntesis de estas mismas y de imágenes generadas. Para el aumento de datos; la solución clásica interviene todo tipo de transformaciones afines (traslación, rotación, escalado, etc.), dado esto; después del entrenamiento de las dos redes que se enfrentan (D y G) se procede a la normalización de lote de cada red, excepto el lote de las capas de entrada y salida; el cuál se toma como tasa de aprendizaje a 0.0002 para un lote de 70.

Por último, se genera la síntesis de los tres tipos de lesiones de Beled para condicionarlas. Para probar los resultados de la clasificación anteriormente expuesta, se emplea la arquitectura de la red CNN, para posteriormente analizar el efecto que genera el aumento de datos; y para la generación de las lesiones sintéticas se implementó la arquitectura de

una DC-GAN, que por medio de la medida de precisión de clasificación total, se evidencio un buen rendimiento del aumento de datos sintéticos por medio de técnicas clásicas; aunque se determinó que agregar más datos no mejora los resultados a la hora de generar un diagnóstico.

Cómo se mencionaba en trabajos anteriores, el cáncer de pulmón es una de las principales causas de muerte en el mundo, y para la detección de este qué mejor que las imágenes de tomografía computarizada que muestran los distintos nódulos pulmonares, Tanto malignos como benignos, donde se generan en muchas ocasiones diagnósticos erróneos que conllevan a la práctica de exámenes invasivos; por tal motivo en el trabajo de clasificación automatizada de nódulo pulmonar en imágenes de tomografía computarizada por medio de una red neuronal convolucional profunda entrenada por red adversas generativas (Zhao, Liu, Qi, Teng, Li & Qian, 2018), el objetivo principal es la generación de un banco de imágenes de alta precisión para su correcta clasificación por medio de la utilización de una red neuronal convencional profunda (DE) cómo también la utilización de redes adversas generativas (GAN). En el presente contexto extraen un volumen de datos centrado en imágenes de tomografías Computarizadas y se crean imágenes utilizando secciones axiales y datos aumentados donde por medio del entrenamiento de un algoritmo de red neuronal profunda con imágenes sintéticas De nódulos provenientes de una red de arquitectura de red Neuronal generativa analógica para proceder a la construcción de imágenes aparentemente genuinas de nódulos benignos y malignos.

El conjunto de datos implementado en dicho procedimiento se obtuvo del Fujita Health University Hospital en Japón, Del cual se aprovecharon 60 imágenes de radiografías computarizadas de tórax con presencia de diagnósticos patológicos, De los cual es 27 pertenecían a nódulos benignos y 33 pertenecían a nódulos malignos qué como resultado de un proceso de entrenamiento y ajuste, se logró determinar la clasificación de los nódulos en un 66,7% y 93,9% de los nódulos benignos y malignos respectivamente. Lo que indica que efectivamente se puede mejorar la calidad del diagnóstico para disminuir la aplicación de exámenes invasivos, como también indican que el método que se propone en el presente contexto, Mejora la clasificación de nódulos en un 20% comparándolos con los métodos tradicionales.



## Objetivos

### Objetivo general

Evaluar el rendimiento de una Red Neuronal Generativa Antagónica en la generación de un banco de imágenes realistas de radiografías panorámicas dentales humanas para investigaciones académicas

### Objetivos específicos

- Establecer características y cantidad de radiografías panorámicas dentales genuinas para el desarrollo de la GAN.
- Implementar una GAN a partir del banco de radiografías panorámicas dentales humanas genuinas definido
- Determinar el rendimiento de la GAN a través de la evaluación del realismo de las imágenes del banco generado por parte de tres profesionales del área odontológica.

# Capítulo 1

## 1. Marco Referencial

En este capítulo se presentan los conceptos más relevantes asociados con las Redes Neuronales Generativas Antagónicas, las teorías aplicadas durante el desarrollo del proyecto. Adicionalmente, en la última sección se exponen las investigaciones que se han desarrollado en el área de Generación de banco de imágenes aplicando Redes Neuronales Generativas Antagónicas

### 1.1 Marco Conceptual

#### 1.1.1 Redes Neuronales Artificiales

Una red Neuronal biológica, es el sistema de conexión que posee el cerebro para el funcionamiento de todas las partes del cuerpo humano, desde los músculos hasta los procesos más complejos que puede generar el cuerpo para la eliminación de anticuerpos. Ahora bien, una red neuronal artificial también es conocida como un sistema de conexión, pero esta vez de modelos matemáticos conectados entre sí, cuyo fundamento básico, es el proceso de aprendizaje e imitación de datos reales por medio de una computadora.

Tal herramienta, hace parte de la actual Inteligencia Artificial (AI), que imita las respuestas biológicas que se generan dentro de la maquina de mando del cuerpo humano (cerebro) (Sandoval, Pérez, González, Jaque & Infante, 2016).

Así mismo, dentro de estas nuevas tecnologías de la Inteligencia Artificial, se encuentran las diferentes ramas como el machine learning que es una forma de aprendizaje de la inteligencia computacional el cual se da para el aprendizaje automático por medio de un algoritmo de carácter explícito, el cual se considera como un proceso complejo de entrenamiento al que hay que brindarle un modelamiento de entrada y se proporciona de

la misma manera, y un modelamiento para predecir una salida. Así mismo, el machine learning tiene unos enfoques específicos que se dividen en:

**Aprendizaje Supervisado:** Su principal función es la búsqueda de patrones dentro de un conjunto de datos de entrada etiquetados, para que estos puedan entrar a un proceso de análisis de información

**Aprendizaje No Supervisado:** A diferencia del aprendizaje supervisado, se trabaja con un conjunto de datos masivos sin etiquetar, pero tiene las mismas características y funcionalidad.

**Deep Learning:** Enfocado en Redes Neuronales, para la creación e imitación de respuestas biológicas (IBM,2020)

### 1.1.2 Redes Neuronales Generativas Antagónicas

Las Redes Neuronales Generativas Antagónicas (GAN's) se definen como una estructura enmarcada del Deep Learning, cuyo propósito se enfoca en la producción de un modelamiento específico que reproduce una distribución similar a un conjunto de datos reales; esta estructura se encuentra dividida en una estructura generadora y otra discriminadora, donde la estructura generadora se encarga de producir la distribución del modelamiento y la estructura discriminatoria, es la encargada de discernir aquellos datos no aptos en la distribución entregada por el anterior modelo (Durugkar, Gemp, & Mahadevan, 2016).

La noción de la Red Generativa Antagónica se basa en el entrenamiento secuencial por medio de capas por determinada distribución entregada por la estructura generadora y la estructura antagónica, con un único propósito de disminuir la disparidad que se encuentra dentro del modelo y el objetivo (Yi, Walia & Babyn 2019).

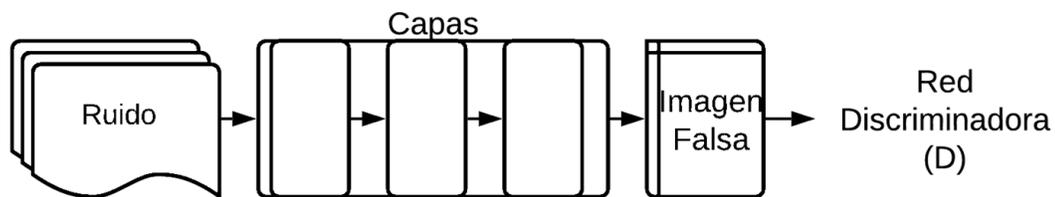
Este tipo de estructura que pertenece a la inteligencia Artificial (AI), ha sido de gran relevancia para el aprendizaje de carácter autónomo por sus características teóricas y por

su capacidad controlar los datos dispersos que impiden obtener un modelo de predicción, como sucede con otras estructuras (Radford, Metz & Chintala, 2015).

### 1.1.3 Modelo Generador (G)

Como primera instancia, para llevar a cabo un entrenamiento de Deep Learning, es necesario aclarar los modelos a implementar. Mayormente, en el Deep Learning se hace uso del Modelamiento de una red que presenta una estructura generadora como primera opción; generando como su entrada un ruido del mismo tamaño del dato que se quiere adquirir, debido a que por medio de este ruido o interferencia se crear un conjunto de datos de parámetros deseados, tal como se ilustra en la **Figura 1-1**.

**Figura 1- 1:** Modelo Generador(G)



Fuente: Autores

Este modelo empieza con una capa que anteriormente mencionamos por medio del Ruido, que en el entrenamiento se le nombra como la capa densa; cuyo propósito es recopilar el vector ruido del dataset que ingresa y lo transforma en un tensor tridimensional, que en sucesivas capas se va transformando hasta llegar a una salida de tipo (x,y,z) (Grau Romero, 2020), las capas que se presentan en el modelo generador, se mencionan a continuación:

**Dense:** Encargada de vectorizar datos para la creación de interferencia/ruido del mismo tamaño de los datos de entrada.

**Con2Dtranspose:** También llamado deconvolución. Es la capa que permite realizar la convolución hacia atrás, en el caso de dos dimensiones; el cuál consiste en el fenómeno

de agrandar (Upscale) la imagen o los datos de entrada, cuantas veces sea necesario. Esta capa es de uso frecuente por su bajo costo computacional, pues si no se aplica esta, se puede implementar una segunda opción que consiste en aplicar una función UpSampling2D seguido de una función Conv2D que arrojaran el mismo resultado esperado.

**LeakyRelu:** Encargada de convertir los datos negativos (no útiles), en parámetros (datos útiles) para cada una de las neuronas conectadas. Como se mencionaba anteriormente, esta capa proporciona un ahorro en el costo computacional, las cuales se evidencian en la evasión del problema del desvanecimiento del gradiente que se encuentra presente en todos los modelamientos de redes neuronales, principalmente en métodos de aprendizaje cuya base es el descenso estocástico entre el gradiente y la re-propagación generada.

**BatchNormalization:** Usada como capa **para** generar la normalización, las veces que se entrena la red y que realiza las debidas convoluciones. Es usada para tener mejores resultados, en su defecto aún mejores.

**Reshape:** Su función consiste en realizar la conversión de determinante vector de una sola dimensión en un conjunto de datos de una imagen.

Además, se debe tener en cuenta la estimación del tamaño de la salida del presente modelo generador pues esta debe ser igual que el tamaño dato como dato real de entrada.

Para poder llegar al mismo tamaño de la imagen de entrada, se realiza el aumento del vector de ruido hasta conseguir una imagen del tamaño de salida. Para realizar lo mencionado anteriormente se hace uso de la capa "Conv2Dtranspose", haciendo uso de los Strides, el cual se definen como números (Xu, Ren, Liu & Jia, 2014)

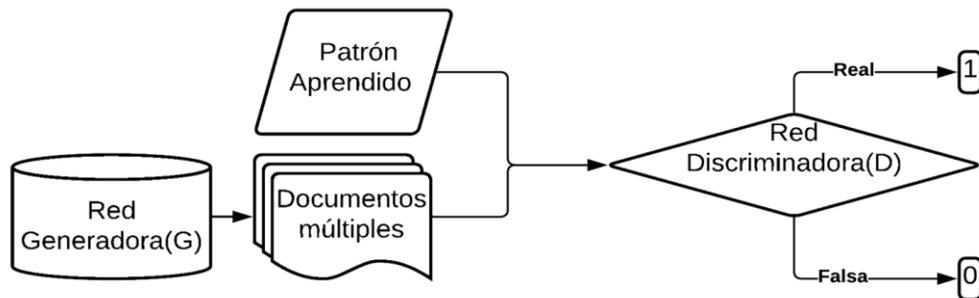
Es decir, podemos ver que la red neuronal aumenta los tamaños de los mapas de características, la cual es el propósito de la red en su modelamiento.

Intuitivamente, para comprender la operación de convolución traspuesta que es la función que realiza, se explica de la siguiente forma

### 1.1.4 Modelo Discriminador (D)

Por otro lado, el modelamiento de la red discriminadora hace la recepción de una imagen de la forma  $(x, y)$  por pixeles; por medio de este se obtiene la probabilidad que se mostrará si los datos o imagen que proviene de un modelamiento generativo se puede considerar como genuina, por tal motivo esta realiza la clasificación de los datos reales sobre los datos ordinarios (falsos) (Yi, Walia, & Babyn, 2019).

**Figura 1- 2:** Modelo Discriminador (D)



Fuente: Autores

Este modelamiento de red tiene una estructura básica de tres layers (Capas) que realizan la acción de convolución de base 32, 64 y 128, estos números nombrados anteriormente son neuronas que en el modelamiento de una Red Neuronal Generativa Antagónica implementa las capas mencionadas en el modelamiento generativo, que son:

- LeakyRelu
- BatchNormalization:

Siendo la última capa de esta estructura generadora una capa que cumple la función de activación sigmoide. Esta capa se caracteriza por ser densa.

En resumen, el modelamiento de la red discriminadora es usada para este caso, para la clasificación de las imágenes provenientes del modelo generativo como genuinas o falsas, por medio de la generación de valores mínimos y máximos, un valor máximo (1) para aquellos datos considerados como genuinos y un valor mínimo (0) o cercanos a este valor,

para los valores considerados como fake (falsos) tal como se muestra en la **Figura 1-2**. (Dumoulin & Visin, 2016).

### **1.1.5 Procesamiento de Imagen médica**

En ámbito de la medicina y aún más en el procesamiento de imágenes, este enfoque abarca diferentes aplicaciones, el cual son herramientas útiles para facilitar algunos diagnósticos e investigaciones. El uso de estos sistemas hace parte del procesamiento de datos de la Inteligencia Artificial (AI), aún más en el Deep Learning cuya relación más estrecha la realiza con el procesamiento y análisis de datos médicos y cada vez se irá fortaleciendo como se evidencia en los trabajos realizados entre los años 2012 al 2017 (Litjens, Kooi, Bejnordi, Setio, Ciompi, Ghafoorian & Sánchez, 2017).

Dentro del Deep Learning existen múltiples aplicaciones que no sólo se enfoca en el procesamiento de la imagen médica, aunque este sea su fuerte, aunque tenga pocas publicaciones de trabajos relacionados, en él se evidencian múltiples resultados óptimos, a la hora de realizar un entrenamiento para análisis de datos discretos, como los dictámenes médicos o continuos como las imágenes de rayos x (Fernández Blanco, 2019)

## **1.2 Marco Legal**

Según la Ley Estatutaria No. 1581 del año 2012, El Congreso de la República colombiana, crea las diversas disposiciones de carácter general para la creación de la protección de datos delicados, el cual se definen como datos personales.

Tal derecho Constitucional, deben conocerlo toda aquella persona que desee tener acceso, conocimiento, actualización, manipulación o rectificación de la información que contienen tales datos de carácter susceptible y delicado, sin exclusión a entidades de carácter público o privado.

Dentro de la normatividad, para que un tercero pueda tener el acceso a esta base de datos, sea de tipo público como información de seguridad nacional, defensa territorial, etc., o sea de tipo privado como información íntima, historia clínica, etc. Se debe realizar la debida solicitud de la persona.

Esta ley fue creada por la particularidad de que a estos datos se les realizaba un incorrecto uso y se estaba afectando la vida íntima del tercero, generando discriminación y violación del derecho a la privacidad. Estos datos comúnmente suelen ser los relacionados a los historiales clínicos y la orientación sexual de la persona.

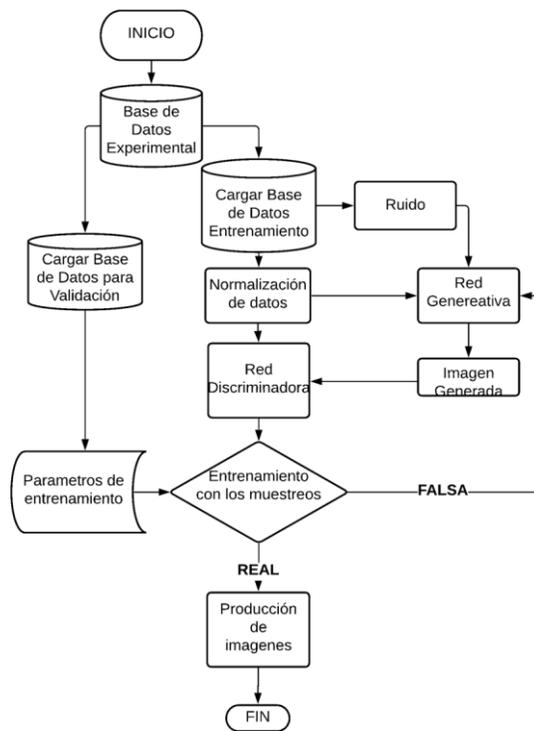
El tratamiento, uso y manipulación de esta clase de información tiene diferentes excepciones, entre las principales se encuentran estas cinco: cuando se requiere hacer empleo con fines de historia, estadísticas y científica en los cuales se deban adoptar las diferentes medidas necesarias para suprimir la identidad de los Titulares, como es el caso del presente trabajo de grado, o la segunda opción comprende que a la persona a la cual se le soliciten tales datos, se le emita una solicitud de uso formal u autorización para el tratamiento de estos ("Ley 1581 de 2012 - Gestor Normativo Función Pública," 2012)

# Capítulo 2

## 2. Metodología

En este capítulo se presenta la metodología utilizada para llevar a cabo la Evaluación del rendimiento de una Red Neuronal Generativa Antagónica en la Generación de un banco de imágenes de radiografías panorámicas dentales humanas. En la **Figura 2- 1** se muestra la arquitectura, las capas ocultas y la aplicación de una Red Neuronal en la extracción de datos para la construcción de un banco de datos con imágenes aparentemente reales.

**Figura 2- 1:** Metodología para llevar a cabo la evaluación del rendimiento de una red neuronal generativa antagónica



Fuente: Autores

En la **Figura 2- 1** se muestra el procedimiento realizado en este proyecto para la evaluación del rendimiento de una Red Neuronal Generativa Antagónica. En primera instancia, se ingresan las imágenes reales que corresponden respectivamente a 25 y 70 imágenes de Radiografías dentales panorámicas humanas de tamaño 2903x1536 píxeles como dataset de entrada y se realiza un ajuste a su tamaño en la aplicación para ordenadores llamada Irfan View 64.

Las Imágenes de Rayos X panorámicas dentales humanas fueron obtenidas de una entidad privada especializada en la toma de exámenes e imágenes orales de la ciudad de Neiva, que solicitó reservar su nombre por temas legales. Se ofrecieron 340 imágenes del tamaño 2903x1536 pixeles, del cual se clasificaron de forma manual para el entrenamiento 300 imágenes de rayos x panorámicas, se realizó esta clasificación debido a que hay algunas características muy relevantes que exaltan más que otras, por tanto, se excluyen las imágenes de la dentadura con brackets. Estas imágenes fueron tomadas por un equipo de rayos x panorámico y perfil veraviewepocs 2d de la marca J Morita, Fabricado en Japón. La toma de este examen comprende en el escaneo de la parte interior del rostro donde abarca todo el cuerpo de la cavidad oral. De acuerdo con el Marco legal presentado en la sección 1.2 con la empresa se firmó un compromiso donde los resultados de este trabajo de grado eran con fines académicos e investigativos, por tal motivo, las imágenes que se brindaron para emplear en este trabajo fueron cortadas previamente por operarios de la entidad.

**Tabla 1:** Datos de entrenamiento

ENTRENAMIENTO DE LOS EXPERIMENTOS			
Experimentos	No. Imágenes Ingresadas	Tamaño de las Imagenes	No. de Epocas
1	25	128x96	300
2	70	128x96	300
3	25	128x96	150
4	70	128x96	150
5	30	256x192	300
6	50	256x192	300
7	30	256x192	150
8	50	256x192	150

Fuente: Autores

“La GAN fue entrenada con imágenes de distintos tamaños para verificar su desempeño. Se realizaron 8 experimentos como se evidencia en la **Tabla 1**, donde se encuentran los datos de entrenamiento. En los experimentos, se realiza un barrido de experimentos a escala 2:2 de la base de datos original de acuerdo a los criterios utilizados para la escogencia de los tamaños (Layers, horas de entrenamiento y épocas usadas) de las imágenes de 128x96 pixeles y de 256x192 pixeles fueron de acuerdo a la visibilidad de la imagen, su definición y su entrenamiento, debido a que son tamaños donde se pueden observar perfectamente las patologías y los puntos de interés (como calzas y materiales osteosintéticos), pues si se realiza de tamaños inferiores no se visibilizan y si se realiza de tamaños superiores a este, no es posible llevar a cabo el entrenamiento, debido a que este supera la RAM del entorno. así como de la cantidad de imágenes para cada experimento fueron escogidas aleatoriamente 4 reales y 4 creadas. Se tomaron estos números de imágenes debido a que cada encuestado se toma aproximadamente de 20 a 30 segundos por imagen evaluada en la primera sección de la encuesta que se lleva a cabo, y son un total de 64 imágenes por encuesta (de 30 min a 40 min), por tanto, un mayor número de experimentos generados, implicaría que las personas no contesten la encuesta, por tanto, no evalúen.

El Primer Experimento; 25 imágenes de entrada con un tamaño de 128x96 pixeles, 6 capas, con 300 épocas y 5 horas con 25 minutos de entrenamiento (Ver (**Imagen 1**)).

**Imagen 1:** Ejemplo de imágenes real y creada en el experimento 1.

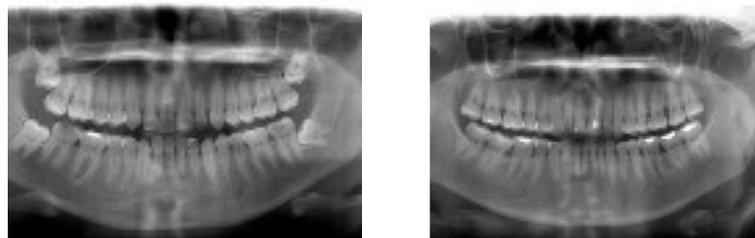


Imagen Real

Imagen Creada

Fuente: Autores

Segundo experimento; 70 imágenes de entrada con un tamaño de 128x96 pixeles, 6 capas, con 300 épocas y 7 horas de entrenamiento (Ver (**Imagen 2**)).

**Imagen 2:** Ejemplo de imágenes real y creada en el experimento 2.



Imagen Real

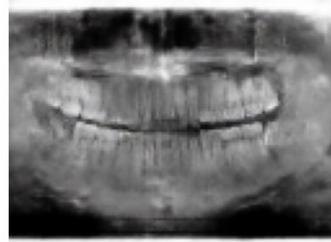


Imagen Creada

Fuente: Autores

Tercer experimento; 25 imágenes de entrada con un tamaño de 128x96 píxeles, 6 capas, con 150 épocas y 1 hora con 45 minutos de entrenamiento (Ver (**Imagen 3**)).

**Imagen 3:** Ejemplo de imágenes real y creada en el experimento 3.



Imagen Real

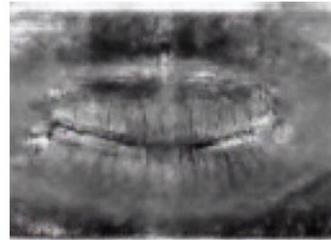


Imagen Creada

Fuente: Autores

Cuarto experimento; 70 imágenes de entrada con un tamaño de 128x96 píxeles, 6 capas, con 150 épocas y 2 horas con 50 minutos de entrenamiento (Ver (**Imagen 4**)).

**Imagen 4:** Ejemplo de imágenes real y creada en el experimento 4.



Imagen Real

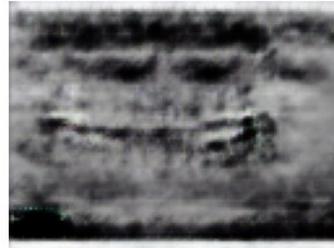


Imagen Creada

Fuente: Autores

Quinto experimento; 30 imágenes de entrada con un tamaño de 256x192 píxeles, 7 capas, con 300 épocas y 9 horas de entrenamiento (Ver (**Imagen 5**)).

**Imagen 5:** Ejemplo de imágenes real y creada en el experimento 5.



Imagen Real

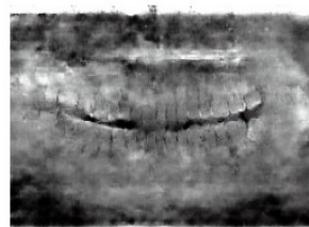


Imagen Creada

Fuente: Autores

Sexto experimento; 50 imágenes de entrada con un tamaño de 256x192 píxeles, 7 capas, con 300 épocas y 7 horas de entrenamiento (Ver (**Imagen 6**)).

**Imagen 6:** Ejemplo de imágenes real y creada en el experimento 6.



Imagen Real

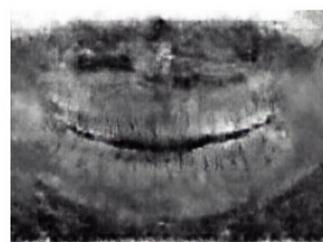


Imagen Creada

Fuente: Autores

Séptimo experimento; 30 imágenes de entrada con un tamaño de 256x192 píxeles, 7 capas, con 150 épocas y 7 horas con 54 minutos, por último (Ver (**Imagen 7**)).

**Imagen 7:** Ejemplo de imágenes real y creada en el experimento 7.



Imagen Real



Imagen Creada

Fuente: Autores

Octavo experimento; contiene 50 imágenes de entrada con un tamaño de 256x192 píxeles, 7 capas, con 150 épocas y 7 horas de entrenamiento de entrenamiento (Ver (**Imagen 8**)).

**Imagen 8:** Ejemplo de imágenes real y creada en el experimento 8.



Imagen Real

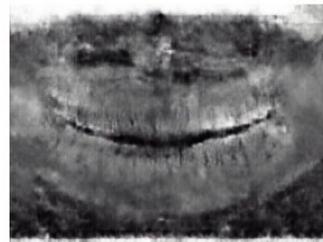


Imagen Creada

Fuente: Autores

Para el primer experimento, se realizó un ajuste del tamaño de 128x96 píxeles; en el segundo ensayo se les realiza un ajuste para que su tamaño quede igual a 256x192 píxeles, donde luego se ingresan sus datos para la emisión del ruido de cada imagen, posteriormente son ingresados a una red Generadora. así mismo los datos de entrada son tomados como muestras experimentales para el ajuste de los parámetros de entrenamiento y antes de ser ingresados la red discriminadora son normalizados. Al

ingresar los datos de las imágenes creadas por la red generadora y las imágenes genuinas, la red discriminadora toma la determinación si estas son reales o son falsas, si estas pasan como imágenes con datos reales, pasan a ser reproducidas por la red, en cambio, si estas pasan como imágenes no genuinas (Falsas), estas vuelven a realizar el proceso completo de entrenamiento, hasta volver a ingresar por la red discriminadora, para que esa imagen construida pueda engañarla.

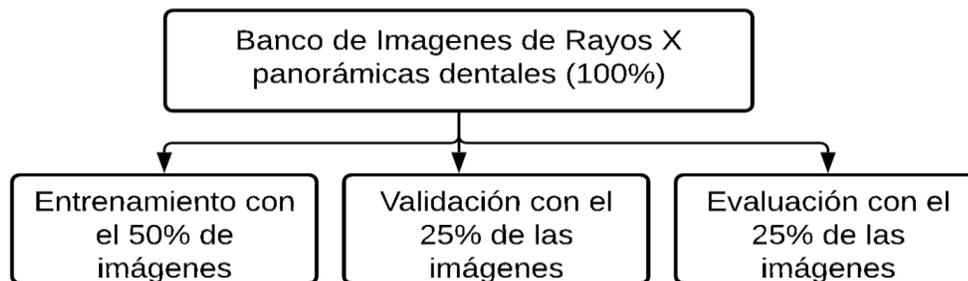
## 2.1 Arquitectura

### 2.1.1 Organización del directorio del banco de imágenes Rx panorámicas dentales de entrada

Para la implementación de las Arquitecturas generativas y discriminadoras, se tomaron respectivamente 25 imágenes para el primer y tercer experimento, 70 imágenes para el segundo y cuarto experimento, 30 para el quinto y séptimo experimento y 50 para el experimento seis y ocho.

Para la evaluación de la red GAN por parte de los profesionales de la salud y los no profesionales, se tomaron 4 imágenes escogidas al azar dentro del conjunto de imágenes generadas por la GAN pertenecientes a cada experimento, y 4 imágenes escogidas al azar de la base de datos de imágenes genuinas. Estas imágenes se organizan aleatoriamente para la evaluación llevada a cabo por los profesionales en el área de la salud dental, así como se ilustra en la **Figura 2-2**, todas con la misma dimensión.

**Figura 2- 2:** Esquema de organización del directorio de entrada para la Evaluación del rendimiento de una Red Neuronal Generativa Antagónica



Fuente: Torres, 2020

Para el entrenamiento se sugiere tener máximo el 50% de las imágenes para la obtención de resultados, asemejados a la apariencia real, debido a las múltiples características que se pueden presentar por cada tramo de imagen, por tal motivo se requiere hacer una clasificación manual y visual del banco de datos con las imágenes a implementar dentro de esta, ya que de las imágenes seleccionadas la red tomará las características (puntos) más relevantes del Rx panorámico dental (Torres, 2020).

### 2.1.2 Ruido

La Red neuronal tiene un punto de partida, el cual se encarga de añadir exclusivamente en el momento de entrenar el ruido en ella, por cada neurona perteneciente a la red generadora. Esta es tomada como la primera capa del entrenamiento del modelo generador de manera oculta, donde directamente influye en la salida entregada por el modelamiento.

Para llevar a cabo el entrenamiento y obtener los óptimos resultados es necesario la realización del vector de esta, pues este vector de ruido, es graduado y transformado a medida que se entrena cada imagen, y se adapta al tamaño de la imagen, es decir el ruido presente en los primero cuatro experimentos, el tamaño del vector es igual a 96x128x3 que equivale a las dimensiones de la imagen de entrada, y posteriormente, los siguiente

cuatro experimentos el vector de ruido es igual a  $192 \times 256 \times 3$ , donde el número 3 equivale al canal donde se encuentra la imagen de rayos x panorámica dental.

El modelo empieza con una capa llamada Dense, el cual recoge el vector de ruido con distribución estadística aleatoria de entrada y lo transforma en un tensor tridimensional, Por cada imagen ingresada en el entrenamiento, se produce un vector de ruido, de la misma dimensión del vector de la imagen de entrada, pues se parte de la aleatoriedad del conjunto de ruido, para que a medida que se entrene el conjunto y se lleven a cabo las convoluciones, se vayan integrando los datos de cada imagen de salida (Alvear, Villaverde, 2018).

### 2.1.3 Arquitectura de la Red Neuronal Generadora

Como se mencionaba en la sección anterior, el entrenamiento de la red generadora parte de un vector de ruido como entrada por imagen y a partir de este vector se genera cada imagen falsa del tamaño requerido.

Posteriormente al cargar las características del vector de ruido por imagen, se procede a cargar tres funciones necesarias para el entrenamiento; el cuál, en primera instancia se encuentra la función **Dense**, que es la capa de ruido oculta, **Conv2Dtranspose**, encargada de modificar la dimensión y el tamaño de entrada por medio de los strides para conseguir la imagen del modelamiento, y, por último, la función **LeakyReLU**, encargada de ahorrar en el tiempo y costo computacional.

**Figura 2- 3:** Resumen de la arquitectura de la Red Neuronal Generadora

```

Model: "sequential"

```

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 3072)	310272
leaky_re_lu (LeakyReLU)	(None, 3072)	0
reshape (Reshape)	(None, 3, 4, 256)	0
conv2d_transpose (Conv2DTran	(None, 6, 8, 128)	295040
leaky_re_lu_1 (LeakyReLU)	(None, 6, 8, 128)	0
conv2d_transpose_1 (Conv2DTr	(None, 12, 16, 128)	147584
leaky_re_lu_2 (LeakyReLU)	(None, 12, 16, 128)	0
conv2d_transpose_2 (Conv2DTr	(None, 24, 32, 64)	73792
leaky_re_lu_3 (LeakyReLU)	(None, 24, 32, 64)	0
conv2d_transpose_3 (Conv2DTr	(None, 48, 64, 64)	36928
leaky_re_lu_4 (LeakyReLU)	(None, 48, 64, 64)	0
conv2d_transpose_4 (Conv2DTr	(None, 96, 128, 32)	18464
leaky_re_lu_5 (LeakyReLU)	(None, 96, 128, 32)	0
conv2d_transpose_5 (Conv2DTr	(None, 192, 256, 32)	9248
leaky_re_lu_6 (LeakyReLU)	(None, 192, 256, 32)	0
conv2d (Conv2D)	(None, 192, 256, 3)	867

```

Total params: 892,195
Trainable params: 892,195
Non-trainable params: 0

```

Fuente: Autores

Como se evidencia en la **Figura 2-3**, el conjunto de las tres funciones se repite las veces que sea necesario hasta llegar al tamaño de la imagen que se quiera obtener por medio del tamaño del **Kernel** y el tamaño del **Stride** a utilizar, en este caso el kernel es de 3 y el Stride es de 2 Dado que el stride hace referencia al desplazamiento que realiza el kernel para poder realizar una convolución; por ejemplo para el anchor ( $X$ ) de la imagen, expresada en pixeles, se divide sobre el número del kernel ( $K$ ); Como se evidencia en la **Ecuación 1.1**, que se usa para hallar  $S_x$  el cual es el Stride en el anchor.

$$S_X = \frac{X}{K} \quad (1.1)$$

Así mismo, se halla para el Stride del largor ( $S_Y$ ) de la imagen, expresada en píxeles, se divide sobre el número del kernel ( $K$ ), la dimensión del largor ( $Y$ ), tal como se evidencia en la **Ecuación 1.2**

$$S_Y = \frac{Y}{K} \quad (1.2)$$

Inversamente, sucederá con las entradas y los strides, manteniendo las proporciones de las dimensiones.

Aparte de lo mencionado anteriormente, cabe resaltar que la salida de la presente red, como única condición que posee es que esta tenga la misma dimensión que la imagen genuina que ingresó al modelo, para poder generar este fenómeno del mismo tamaño, es necesario aumentar el tamaño de la imagen por cada convolución hasta obtener el tamaño deseado.

Adicionalmente, como se evidencia en la **Figura 2-3**, no se encuentra a plena vista debido a que se encuentra oculta, es la función tangencial **Tanh**, capa que asegura que los valores oscilen entre 1 y -1.

### 2.1.4 Normalización de Datos

Para que el entrenamiento se pueda realizar, es necesario encontrar la forma de que los vectores de datos de las imágenes genuinas que se presentan como entrada, estén en una escala entre los valores de  $-1$  y  $1$ , tal proceso se denomina Normalización.

$$Nd = \frac{D_v - m}{m} \quad (1.3)$$

Como la Normalización de datos ( $Nd$ ) es de acuerdo con las capas de la Imagen RGB, y estas corresponden a valores de bits que se encuentran 0 y 255, se lleva a cabo la operación de la **Ecuación 1-3**, donde se procede a realizar una substracción entre el valor de la dimensión ( $D_v$ ) y la media ( $m$ ) correspondiente a los bits de la imagen RGB y se divide su resultado sobre este mismo valor, creando como resultados valores entre  $-1$  y próximos a 1.

### 2.1.5 Arquitectura de la Red Neuronal Discriminadora

Como entrada en la red discriminadora, se toman las muestras creadas y las muestras reales normalizadas por la red generadora (ver **(Figura 2-0)**), el cual se considera como una red de convolución corriente, por el motivo de emitir un valor máximo (1) o mínimo (0), como salida única.

Posteriormente de aplicar las mismas capas que se toman en la red generadora (ver **(Figura 2-4)**), en esta red se ingresa una capa oculta con una función para generar la respectiva activación; en este caso se usa la función **Sigmoide**, que tiene por objeto la clasificación entre genuina y falsa.

**Figura 2- 4:** Resumen de la arquitectura de la Red Neuronal Discriminadora

```

Model: "sequential_1"
Layer (type)                Output Shape                Param #
-----
conv2d_1 (Conv2D)           (None, 192, 256, 64)       1792
leaky_re_lu_7 (LeakyReLU)   (None, 192, 256, 64)       0
conv2d_2 (Conv2D)           (None, 96, 128, 128)       73856
leaky_re_lu_8 (LeakyReLU)   (None, 96, 128, 128)       0
conv2d_3 (Conv2D)           (None, 48, 64, 128)        147584
leaky_re_lu_9 (LeakyReLU)   (None, 48, 64, 128)        0
conv2d_4 (Conv2D)           (None, 24, 32, 256)        295168
leaky_re_lu_10 (LeakyReLU)  (None, 24, 32, 256)        0
conv2d_5 (Conv2D)           (None, 12, 16, 256)        590080
leaky_re_lu_11 (LeakyReLU)  (None, 12, 16, 256)        0
conv2d_6 (Conv2D)           (None, 6, 8, 256)          590080
leaky_re_lu_12 (LeakyReLU)  (None, 6, 8, 256)          0
conv2d_7 (Conv2D)           (None, 3, 4, 256)          590080
leaky_re_lu_13 (LeakyReLU)  (None, 3, 4, 256)          0
flatten (Flatten)           (None, 3072)                0
dropout (Dropout)           (None, 3072)                0
dense_1 (Dense)             (None, 1)                    3073
-----
Total params: 2,291,713
Trainable params: 2,291,713
Non-trainable params: 0

```

Fuente: Autores

Finalmente, para optimizar la red, se hace uso de la función optimizadora **Adam**, también es una capa oculta, que es usada para bases de datos grandes y su rendimiento se evidencia en el costo computacional, cuyo entorno se corrió en una GPU de la nube de GoogleColab, cuyo lenguaje es Python.

Además, se toma como tasa de aprendizaje para la red el valor de 0,0002 y una beta de 0,5. Estos valores se tomaron en referencia a los trabajos tomados como base en el estado del arte, donde especifican que estos valores se presentan óptimos para salidas estimadas.

## 2.2 Entrenamiento

Luego de definir la arquitectura y la normalización de los datos, se lleva a cabo el entrenamiento de la Red Neuronal Generativa Antagónica (GAN), es decir, se unen las arquitecturas mencionadas anteriormente.

Para iniciar el entrenamiento, se procede a llamar los datos desde el ordenador donde se encuentran almacenadas, por motivo que el código se encuentra hospedado en un colaborador de Google, porque el costo computacional de este es alto y es necesario el uso de una GPU o TPU.

### 2.2.1 Entrenamiento de la Red Discriminadora

Posteriormente a tener la base de datos genuinas cargadas en el código, se procede al entrenamiento de la red discriminadora. Para realizar el entrenamiento, es necesario tener dos bases de datos como entradas. Una de las entradas, será un grupo de imágenes reales que se toman para determinar los parámetros de entrenamiento y la segunda base de datos es proveniente de red generadora, que es la encargada de producir imágenes aparentemente genuinas.

Para tener en cuenta, es necesario considerar el tamaño de la imagen proveniente, en la cual para los experimentos se tomaron dos tamaños, que corresponden a 96x128x3 y

192x256x3 para generar n cantidad de imágenes de igual dimensión de las de entrada. En este caso se generarán 150 y 300 imágenes, que serán igual a una por época.

La función del discriminador dentro del entrenamiento será la predicción de que una imagen sea genuina. Lo cual es de vital importancia realizar un preentrenamiento de red.

Para verificar que se este realizando un entrenamiento de forma correcta se solicita que genere y devuelva los datos de precisión del entrenamiento por imagen, como se evidencia en la **Figura 2-5**, también es llamado **Accuracy**.

**Figura 2- 5:** Respuesta de Precisión de la Imagen entrenada en el discriminador

```
1 Real:35.9375, Fake:1.5625
2 Real:100.0, Fake:6.25
3 Real:100.0, Fake:37.5
4 Real:100.0, Fake:76.5625
5 Real:100.0, Fake:100.0
6 Real:100.0, Fake:100.0
7 Real:100.0, Fake:100.0
8 Real:100.0, Fake:100.0
9 Real:100.0, Fake:100.0
```

Fuente: Autores

Esto se realiza para determinar el medio Batch (lotes) que corresponde a la ultima capa de la arquitectura de la red, que son los grupos independientes de datos genuinos y falsos, el cual garantiza El procesamiento de grandes grupos de datos para ser calculados en pequeñas partes, para si poder aumentar la eficiencia de la depuración del código.

La capa mencionada anteriormente es normalizada, y se denomina BatchNormalization, donde se implementa la técnica desarrollada en el 2015 por Ian Goodfellow, cuya base consistía en la normalización de todos los datos que ingresaban a la capa, tal que tuvieran directamente su salida de activación media de 0 y una desviación estándar de uno. Es un proceso similar a como se estandarizan los datos que ingresan a las capas iniciales.

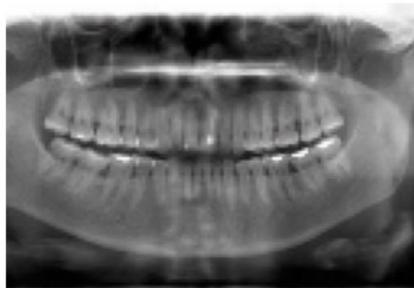
## 2.3 Creación de la Red Neuronal Generativa Antagónica

Para aclarar, dentro del entrenamiento, es la encargada de producir y la discriminadora aprende de sus datos producidos por medio de aprendizaje. El proceso de aprendizaje mencionado anteriormente genera que los dos modelamientos se unan de tal forma que su salida si aun no es aprendida, o pasa como falsa, esta se devuelve al entrenamiento de la red discriminadora para que esta aprenda muy bien sus características hasta que su salida de muy próxima a un dato aprendido o genuino. Y por medio de la función **binary\_crossentropy**, que es una función de costo, que permite que las imágenes, que se obtienen como salida, sean clasificadas de dos tipos, el primer tipo es la imagen genuina, que tomara un valor de salida 1, y el segundo grupo hacen parte las imágenes falsas que tomara un valor de salida 0.

## 2.4 Producción de Imágenes de Rayos X Panorámicas dentales Humanas

Procediendo de crear la Red Generativa Antagónica y de iniciar el entrenamiento compacto de esta, se espera que empiece a generar como primera instancia un experimento de los ocho diferentes que se esperan realizar, con el fin de llevar a cabo cada una de las evaluaciones adecuadas para determinar el funcionamiento de la Red Neuronal aplicada a este tipo de datos continuos (Imágenes), (ver (**Figura 2-6**)).

**Figura 2- 6:** Imagen generada del tamaño 128x96 pixeles en el primer experimento con 300 épocas



Fuente: Autores

## **2.5 Herramienta Computacional para la construcción de los algoritmos**

El nivel de complejidad de los algoritmos implementados exige que las características del equipo empleado para las simulaciones sean mayores a los requerimientos mínimos que Python en la versión 3.8 (el cuál es su última versión) establece para ejecutarse. Específicamente se requiere, una GPU con mejor desempeño para garantizar la lectura y representación eficiente de la cantidad de señales externas que se procesan en este proyecto, una capacidad de memoria RAM superior a las 8GB para la ejecución de los diversos subprocesos que se generan durante la reconstrucción de la imagen. Los ordenadores que se poseen no cuentan con estas características, debido a que se contaban con dos de ellos; el primero es un ordenador de la marca Acer, con procesador Core i3, 4GB de memoria RAM y el segundo ordenador es un MacBook Air con procesador Core i5, 8GB de memoria RAM, Por tal motivo se hizo uso de la herramienta de Google, denominada Google Colaboratory, el cuál es un entorno de ejecución en la nube para ejecutar códigos de Python, esta herramienta se usa para generar modelos de Machine learning, con la gran ventaja de hacer uso de GPU y TPU. Se hizo uso de la herramienta de Google Colab debido a que libera a la máquina de la CPU de llevar consigo la ejecución de algoritmos pesados como este, y ya que este entorno ofrece mejores ventajas que el equipo, como memoria RAM de 12GB, por tanto, se realizó por medio de esta.

## **2.6 Criterios de inclusión y exclusión**

Inicialmente se contaba con una base de datos de 400 imágenes de Radiografías dentales panorámicas humanas de tamaño 2903x1536 píxeles. Como se mencionaba al inicio de la metodología, se realiza un ajuste a su tamaño en la aplicación para ordenadores llamada Irfan View 64, las cuales se toman de dos tamaños, el primero es de 128x96 píxeles y el segundo 256x192 píxeles, debido que no es suficiente la memoria RAM de google Colab que es de 12GB disponibles para el entrenamiento para el tamaño original, así mismo se realiza el ajuste a estos tamaños de acuerdo con la cantidad de Layers (corresponden a 6

y 7 layers respectivamente), que contienen cada Experimento ilustrados en la **Tabla 1**. El corte de las imágenes se realizó a 300 imágenes, debido a que se excluyeron 100 imágenes que presentaban brackets, materiales osteo-sintéticos predominantes, como también se excluyen las imágenes de Rx panorámicas de dentales de infantes, las cuales se evidenciaba el crecimiento de dientes, por lo que se presentaban uno encima de otro. Estas imágenes se excluyen debido a que en el entrenamiento son un obstáculo para la visibilidad de los resultados, llegando al punto de alterarlos.

## 2.7 Características de clasificación de la Imagen

Las características que llevaron a la calificación de la imagen fueron los de distorsión de la imagen y exaltación de puntos, debido a que se tomó la opinión y el conocimiento de los profesionales en el área de la salud dental. En este caso como es una imagen de Rayos x panorámica dental, la característica de distorsión de la imagen se evidencia por las líneas de corte de las áreas de la cavidad oral y la característica de exaltación de puntos se evidencia en las patologías presentes en la dentadura, como las incrustaciones de materiales osteo-sintéticos, brackets y calzas. Estas características son usadas como criterios de identificación para que las imágenes sea clasificadas como reales o falsas.

## 2.8 Evaluación de las Imágenes generadas

Para poder crear las combinaciones se crean las diferentes tablas de confusión de los experimentos, que consiste en tomar diversos criterios básicos para realizar un ajuste, entre una condición y su relación con los experimentos y mostrar la cantidad de los que se tomaron en cada una de las respuestas de la encuesta. (Irala, Martínez & Grima, 2001) Estas tablas se pueden evidenciar en el **Capítulo 5**, como anexo 5.3, donde se muestra la totalidad de los experimentos generados; así mismo con estos resultados se realiza la probabilidad condicional, que es una definición teórica para la elaboración de un área de muestreo. (Condicionales e Independencia, 2005). (Ver (**Ec. 1.4**)) de 4 eventos; donde la probabilidad de interés fue el evento donde el número de imágenes clasificadas como reales (*ClaReal*) cuando la imagen es aparente, se divide sobre el número de imágenes presentadas como Aparentes (*PreApa*).

$$P_c = \frac{ClaReal}{PreApa} \quad (1.4)$$

Los eventos que se tomaron en cuenta para hacer la probabilidad condicional se presentan a continuación: El primero; consiste en dado que la imagen se presente como real, sea tomada como aparente, El segundo evento consiste en que la imagen sea presentada como real y se tome como aparente, el tercer evento consiste en que la imagen sea presentada como aparente y se tome como tal y el cuarto y último evento es el que se usa para determinar la entropía condicional, que es el evento que se menciona para explicar la **Ecuación 1.4**.

Para apoyar la investigación de la evaluación de las GAN, se hizo un análisis estadístico por medio de la Probabilidad condicional, que como se mencionaba anteriormente en conocer el suceso X, teniendo el conocimiento que existe un experimento Y, que sucederá al tiempo que sucede X. También, se apoyan los resultados de la evaluación en los cálculos de la Entropía condicional, el cual consiste en que tan disperso se encuentran los resultados de los experimentos al objetivo deseado (Bilkis, 2018), que es el experimento de la imagen creada pasando desapercibida por el ojo humano como imagen aparentemente real, dado esto, que entre menor sea su valor (cerca a 0) menor es su dispersión, y viceversa, entre mayor sea su valor (cercano a 1) mayor será la dispersión de sus datos, tal como se evidencia en la **Ecuación 1.5**.

$$E_{(s)} = \sum_{i=1}^c -P_i \log_2 P_i \quad (1.5)$$

Donde  $E_{(s)}$  es la entropía condicional del experimento de las imágenes creadas que son tomadas como aparentemente reales; desarrollándose de tal forma que  $P_i$  es la probabilidad del experimento mencionado multiplicado por el  $\log_2$  del experimento ( $P_i$ ), menos la probabilidad que suceda el experimento contrario (que la imagen aparente, efectivamente sea tomada como aparente) por la probabilidad del presente experimento; El cuál se determina para hallar la incertidumbre presente en la totalidad de los

encuestados y de cada uno de los grupos de conocedores del tema y no conocedores del tema.

## Capítulo 3

### 3. Experimentos, Evaluación, Resultados, Limitaciones y Discusiones

En esta sección se presentan los experimentos, evaluación, resultados, limitaciones y Discusiones obtenidas correspondientes a cada uno de los ocho experimentos generados por las Redes Neuronales Generativas antagónicas para la generación de un banco de imágenes de Rayos x panorámicas dentales, a tiempos computacionales, con el Número de salidas generadas y entradas, como también las diferentes combinaciones entre estas.

Para poder dar resultados, fueron necesarios 8 experimentos, de los cuales se evaluaron por medio de especialistas en el área de la salud dental y como también por medio de personas que no tuvieran conocimiento en el área.

#### 3.1 Experimentos realizados

Se realizaron ocho experimentos, debido a que se tuvo en cuenta el costo computacional que tiene el entrenamiento y la calidad de la imagen. Los ocho experimentos, se pueden evidenciar en la **Tabla 2**, los parámetros implementados.

**Tabla 2:** Experimentos realizados

No.	Tamaño de la imagen en pixeles	Capas por modelo	No. de imágenes entrenadas	Épocas\No. de imágenes generadas	Tiempo de entrenamiento
1	128x96	6	25	300	5 hrs con 25 min
2	128x96	6	70	300	7 hrs
3	128x96	6	25	150	1 hr con 45 min
4	128x96	6	70	150	2 hrs con 50 min
5	256x192	7	30	300	9 hrs
6	256x192	7	50	300	7 hrs
7	256x192	7	30	150	7 hrs con 54 min
8	256x192	7	50	150	7 hrs

Fuente: Autores

Como se puede observar, se realizaron cuatro experimentos por tamaño de imagen. Los primeros cuatro experimentos se realizaron para generar imágenes del tamaño de 128x96 pixeles, así mismo para poder generar este tamaño como salida, se ingresaron en el primer y tercer experimento 25 imágenes reales del mismo tamaño al que se solicitaba en la salida; la diferencia entre estos dos experimentos fue en la cantidad de épocas, que significa la cantidad de salidas requeridas; en el primer experimento la cantidad de épocas solicitadas e ingresadas al programa fueron de 300 y en el tercer experimento se ingresó un número de 150 épocas, para generar la misma cantidad, respectivamente su tiempo de entrenamiento corresponde a 5 horas con 25 minutos y 1 hora con 45 minutos.

Para el segundo y cuarto experimento se tomaron como entrada 70 imágenes reales, del tamaño mencionado anteriormente, respectivamente se ingresaron 300 y 150 épocas, seguido por el tiempo de entrenamiento, que para el segundo experimento fue de 7 horas y para el cuarto experimento, el tiempo necesario fue de 2 horas con 50 minutos.

En el segundo grupo de entrenamientos, se hizo uso de la imagen de tamaño 256x128, así mismo se ingreso el tamaño de las épocas, respectivamente para el quinto y sexto grupo, fueron de 300 épocas y su cantidad de imágenes varía de forma que para el quinto entrenamiento se ingresaron 30 imágenes y para el sexto 50 imágenes; respectivamente el tiempo de entrenamiento invertido fue de 9 horas y 7 horas.

Para el séptimo y octavo entrenamiento, respectivamente se usaron 30 y 50 imágenes como entrada, y su entrenamiento corresponde a 7 horas con 54 minutos y 7 horas; para

las épocas se ingresaron la misma cantidad de épocas para ambas, que fueron 150 imágenes.

## 3.2 Evaluación

Para tener los resultados del proyecto, fue necesario realizar dos tipos de encuesta con las mismas preguntas. Los encuestados fueron 5 profesionales en el área de la salud dental, debido a que son ellos los que realizan el dictamen con este tipo de exámenes que corresponden a Rayos x panorámicas dentales humanas, más no un radiólogo. También, se encuestaron a 87 personas que no tienen conocimiento alguno sobre imágenes orales, por motivo que se quería conocer que capacidad tienen las imágenes generadas, de engañar al ojo humano.

Los especialistas se escogieron de forma aleatoria; tres de ellos tienen su consultorio en la ciudad de Neiva, en el departamento del Huila, uno de ellos del municipio de Palermo del mismo departamento y el quinto odontólogo reside y labora en la ciudad de Medellín en el departamento de Antioquia, y labora en el Hospital de Medellín. Las encuestas se realizaron por medio de una herramienta del navegador de Google denominada Google Forms, el cual permite realizar diferentes cuestionarios, evaluaciones, asistencias, etc... y fue compartida a los odontólogos personalmente por medio de mensajería web, no pudo ser posible realizarla de forma presencial, debido a la contingencia sanitaria que actualmente se está viviendo por el virus del COVID-19. Las 87 personas, se escogieron de forma aleatoria de la misma forma, y se compartió por medio de la dirección que contenía la encuesta en la nube, para así mismo ser diligenciada.

La metodología de la encuesta se divide en dos partes, y ocho secciones que corresponden al número de experimentos; la primera parte consiste en escoger entre las opciones de real o aparente para cada una de las 8 imágenes por sección, donde 4 de ellas son reales y 4 de ellas son aparentes (se escogieron de cada Dataset generado por experimento), ubicadas aleatoriamente. La segunda parte corresponde a las preguntas

relacionadas con la calificación de la imagen y las características que hicieron distinguir en entre las imágenes generadas e imágenes reales.

### 3.3 Resultados

Para generar una comparación y respectiva evaluación del modelo de la GAN se realizaron dos grupos de experimentos, cada uno corresponde a 4 secciones del tamaño de 128x96 pixeles y 256x192 pixeles, tal como se evidencia en la **Tabla 3** donde fueron evaluados inicialmente por 5 profesionales en la salud dental y 87 personas del común que no tienen conocimiento alguno de esta.

**Tabla 3:** Resultados de la evaluación de los experimentos

Verdaderos/Clasificados		Profesionales		No profesionales	
		Real	Aparente	Real	Aparente
1	Real	40%	60%	51%	49%
	Aparente	30%	70%	44%	56%
2	Real	40%	60%	29%	71%
	Aparente	40%	60%	48%	52%
3	Real	40%	60%	42%	58%
	Aparente	0%	10%	37%	63%
4	Real	75%	25%	39%	61%
	Aparente	0%	100%	42%	58%
5	Real	88%	12%	51%	48%
	Aparente	10%	90%	49%	51%
6	Real	84%	21%	48%	52%
	Aparente	0%	100%	52%	48%
7	Real	37%	63%	77%	22%
	Aparente	30%	70%	79%	20%
8	Real	80%	20%	70%	30%
	Aparente	50%	95%	29%	70%

Fuente: Autores

Para todos los experimentos se aplicó la fórmula de probabilidad condicional, el cuál consiste en conocer el suceso X, teniendo el conocimiento que existe un experimento Y que sucederá al tiempo que sucede X. esta probabilidad se describe de la forma  $P(A|B)$ , tal como se ilustra en la **Ecuación 1.4**; y en el presente caso se aplica a las cuatro posibles opciones que son las siguientes; la primera condición consiste en el experimento de las imágenes que originalmente son aparentes, pero lograron engañar el ojo de los

profesionales y las personas que no tienen conocimiento del tema. Así mismo, como segundo experimento condicional, estaban las imágenes que eran reales y pasaron como aparentes, como tercer experimento condicional se encontraban las imágenes que eran reales y se tomaron como reales y por último, las imágenes aparentes que no lograron engañar al ojo humano.

Los siguientes resultados se basan en el primer experimento condicional que consiste en las imágenes aparentes, las cuales fueron presentadas y se tomaron como imágenes reales, este experimento se calculó con la **Ecuación 1.4**, donde el número de imágenes clasificadas como reales (*ClaReal*) cuando la imagen es aparente, se divide sobre el número de imágenes presentadas como Aparentes (*PreApa*).

El primer experimento corresponde al tamaño de 128x96 píxeles, con 300 épocas y 25 imágenes de entrada; donde el 30% de las imágenes pasaron como reales ante el dictamen de un profesional en el área de la salud dental, y para las personas no tienen conocimiento en el área pasaron como reales sobre el 44%. Para el segundo experimento se tenían los parámetros del tamaño de 128x96 píxeles, con 300 épocas y 70 imágenes de entrada, donde el 40% de las imágenes pasaron como reales frente a un profesional en el área de la salud dental, y para las personas del común el 48% de las imágenes fueron reales. Para el tercer experimento, del tamaño de la imagen de 128x96 píxeles, con 150 épocas y 25 imágenes de entrada; el cuál ninguna imagen fue tomada como real, que fuese una imagen aparente para los cinco profesionales, el mismo suceso ocurre en el experimento 4 y seis, donde estas imágenes pasaron 100% aparentes. para los 87 encuestados en el experimento 3, el 37% fue aprobado como aparentemente real. Para el cuarto experimento, que consiste en el tamaño de 128x96 píxeles, con 150 épocas y 70 imágenes de entrada, para las personas que no tienen conocimiento del tema, el 42% de las imágenes pasaron como aparentemente reales; por último, experimento del primer grupo de tamaño 128x96 píxeles, se encuentra con 300 épocas y 30 imágenes de entrada y en este experimento, para las personas no expertas en el área, el 49% de las imágenes presentadas como aparentes, pasaron como reales.

Para el segundo grupo de los 8, se tiene un quinto experimento con 300 épocas y 30 imágenes de entrada, para los profesionales en el área el 1% de las imágenes pasaron como aparentemente reales y para aquellos que no sabían del tema el 49% de las imágenes fueron reales las mismas imágenes. Para el sexto experimento, con 150 épocas y 30 imágenes de entrada, el 52% de las imágenes creadas pasaron como aparentes, en cambio para el séptimo experimento con 150 épocas y 30 imágenes de entrada, el 79% fueron las imágenes tomadas como reales del conjunto de imágenes creadas y para los profesionales solo el 30% de las imágenes creadas, fueron tomadas como reales. Por último, en el octavo experimento con 150 épocas y 50 imágenes de entrada; el 5% de las imágenes creadas fueron aceptadas por los odontólogos como reales y el 29% fue tomado por aquellas personas sin conocimiento alguno sobre el área

### 3.4 Limitaciones

La mayor limitación dentro del entrenamiento, fue el costo computacional debido a que la única forma de ejecutarlo era por un entorno que se encontrara en la nube, para que los ordenadores no saturaran, ya que el procesamiento de las imágenes médicas dentro de un modelamiento de una red neuronal, implica que el entorno pueda correr en un servidor mayor a 8GB de RAM, y esta característica la brinda el Colaborador de google, el cuál es un entorno que posee hasta 12,9 GB de RAM para brindarle a cualquier ordenador, ya sea por medio de una GPU o TPU. En el caso, cuando se hizo uso de la GPU, a la hora de optimizarla no fue suficiente, debido a que el tiempo uso del colaborador excedía y paraba el entrenamiento, aún así cuando se opto por trabajar con la TPU y optimizarla, el tiempo de entrenamiento se agotaba, pero esta vez difería en el 50% de tiempo menos que el GPU, sin embargo, no se pudieron realizar más experimentos, debido a que a medida que se aumentaban la cantidad de imágenes ingresadas, el tamaño en pixeles y las épocas, el entrenamiento no podía llegar a su totalidad, porque el tiempo del colaborador se agotaba y para volver a entrenar con el mismo usuario deberán pasar 14 horas hasta poder usarlo de nuevo.

### 3.5 Discusiones

A continuación, se muestran las discusiones derivadas de las encuestas aplicadas a los profesionales de salud dental y a los no profesionales de salud dental.

Como resultado de la evaluación del rendimiento de una Red Neuronal Generativa Antagónica en la generación de un banco de imágenes de radiografías panorámicas dentales humanas por los profesionales en salud dental, se evidenció que, para el mejor caso, la probabilidad condicional que una imagen creada sea considerada como una imagen real es 0,4 (ver Tabla 1); es decir, el 40% de las imágenes creadas fueron consideradas como reales por los profesionales de salud dental. Las imágenes, con respecto a calidad de la imagen y usando una escala de 1 a 5, obtuvieron una puntuación de 2,2 y la principal característica que permitió diferenciar entre una imagen real y una creada fue la distorsión de la imagen.

Respectivamente, de acuerdo con la evaluación que emitieron las personas que no tenían conocimiento sobre salud dental; para el mejor caso, la probabilidad condicional fue 0,48 (ver Tabla 1); es decir, el 48% de las imágenes creadas fueron consideradas como reales. Las imágenes creadas recibieron una puntuación aproximada de 3,2. Nuevamente, la principal característica que permitió diferenciar entre una imagen real y una creada fue la distorsión de la imagen.

**Tabla 4:** Resultados generales de las respuestas de los Profesionales en el área de salud dental

Profesionales en el área de salud dental					
Experimento	Epocas	Imágenes ingresadas	No. de Imágenes ingresadas	Probabilidad Condicional	Entropía Condicional (bits)
1	300	128x96	25	0,3	0,881
2	300	128x96	70	0,4	0,97
3	150	128x96	25	0	0
4	150	128x96	70	0	0
5	300	256x192	30	0,1	0,468
6	300	256x192	50	0	0
7	150	256x192	30	0,3	0,881
8	150	256x192	50	0,05	0,286

Fuente: Autores

Los resultados muestran que, a pesar de que las imágenes no tienen una gran resolución, las imágenes creadas por la red antagónica no tienen exaltación de puntos evidentes. Es decir, las imágenes creadas son coherentes con la forma anatómica “normal” que se detalla en las radiografías panorámicas dentales. Adicionalmente, se evidencia que, para los mejores casos, es más difícil confundir a los profesionales de salud dental.

**Tabla 5:** Resultados generales de las respuestas de las personas que no tienen conocimiento en el área

No Profesionales en el área de salud dental					
Experimento	Epocas	Imágenes ingresadas	No. de Imágenes ingresadas	Probabilidad Condicional	Entropía Condicional (bits)
1	300	128x96	25	0,44	0,99
2	300	128x96	70	0,48	0,998
3	150	128x96	25	0,37	0,953
4	150	128x96	70	0,42	0,982
5	300	256x192	30	0,49	0,999
6	300	256x192	50	0,52	0,998
7	150	256x192	30	0,79	0,726
8	150	256x192	50	0,29	0,871

Fuente: Autores

La entropía condicional permite medir el nivel de consenso entre los encuestados (hay mayor consenso cuando la entropía o incertidumbre es baja), por lo tanto, al comparar las **Tablas 1 y 2**, se observa que, de manera general, la Entropía condicional de los profesionales es menor que la reportada para los No profesionales, lo cual indica, cómo se esperaba, que es más difícil para los no profesionales identificar las imágenes aparentes.

Al comparar las probabilidades condicionales de los experimentos: uno con dos, tres con cuatro y cinco con seis, se puede concluir que, a mayor cantidad de imágenes, mayor es la probabilidad de seleccionar una imagen creada como real. Lo anterior es lo esperado porque la red antagónica tiene más ejemplos para el entrenamiento de la correspondiente red discriminadora.

De igual forma, al comparar las probabilidades condicionales de los experimentos: tres con uno y cuatro con dos, se puede concluir que el aumento del número de épocas aporta positivamente a la probabilidad de seleccionar una imagen creada como real. Sin embargo,

más experimentos deben ser llevados a cabo para entender el compromiso con el número de épocas porque puede existir un sobre entrenamiento de la red, tal como los muestran los experimentos siete y seis; donde la probabilidad disminuye con el aumento del número de épocas.

Considerando las opiniones de los profesionales de salud y los no profesionales, se evidencia que el mejor desempeño de la red antagónica corresponde con el experimento 7, cuya probabilidad que una imagen creada pase como real fue 0,3 y 0,79, respectivamente.

Cabe destacar, que la limitación del costo computacional del estudio y los recursos disponibles en Google Colab, no permite que se generen más experimentos de tamaños superiores a 256x192. El costo computacional del entrenamiento aumenta con el número de capas, coeficientes de las capas y la cantidad de imágenes de entrada (Ver (**Tabla 2**)). A medida que se aumenta el número de épocas o imágenes que se espera en el conjunto de salida o resolución en píxeles de las imágenes, también aumenta el tiempo de entrenamiento de la red y la cantidad de espacios en RAM. Inclusive, aumenta la probabilidad que se agoten los recursos de cómputo.



# Capítulo 4

## 4. Conclusiones y recomendaciones

### 4.1 Conclusiones

Para concluir, de acuerdo con los resultados de la evaluación de la implementación de una Red Neuronal Generativa Antagónica para la creación de un banco de imágenes de radiografías panorámicas dentales humanas, se evidencia que el Experimento 1 que corresponde al tamaño de 128x96 pixeles, con 300 épocas, 25 imágenes de entrada y con un tiempo de entrenamiento de 5 horas con 25 minutos , y respectivamente el Experimento 2 que corresponde al tamaño de 128x96 pixeles, con 300 épocas, 70 imágenes de entrada y con un tiempo de entrenamiento de 7 horas; y ambas con 6 capas; obtuvieron una puntuación promedio del 0,45 entre los dos grupos evaluadores (Profesionales en el área de la salud dental y no profesionales en esta misma área) ,por medio de sus respuestas se dio a conocer que estas bases de datos creadas pasaron como aparentemente real.

Gracias a la evaluación realizada se pudo establecer la característica que hace que una imagen creada por medio de una GAN pase como una imagen genuina, la cuál es la baja distorsión que puede traer la imagen. Como también, se pudo concluir que la cantidad de radiografías panorámicas dentales genuinas para el buen desarrollo de la GAN debe ser inferior al 50% de los datos del dataset original.

Se estableció según la puntuación generada por medio de la evaluación a los bancos de imágenes mencionados anteriormente, el rendimiento de la GAN a través de la evaluación del realismo de las imágenes del banco generado por parte de profesionales del área odontológica y personas no expertas en el área es de aproximadamente el 0,40 conservando la misma resolución (264 Pixeles) que tiene el dataset de entrenamiento.

## 4.2 Recomendaciones

Para fortalecer la investigación se propone realizar una inversión de un equipo con mayor capacidad de memoria RAM, que supere los 8GB, ya que se recomendaría la compra del paquete de Google Colaboratory Pro, que brinda mas capacidad de RAM y tiempo de entrenamiento ilimitado, pero esta opción es para quienes residen en Norteamérica (Estados unidos y Canadá).

Como alternativas a próximos trabajos, a medida que vayan aumentando la cantidad de imágenes a generar, proporcionalmente se realice la modificación a los parámetros de entrenamiento, para poder llevar a cabo una clasificación de patologías que inciden con frecuencia en las imágenes, realizándolo con una cantidad de imágenes más reducidas y optando por la inclusión de otras herramientas del Deep learning y de las Gans; estas pueden ser las Gans condicionales GAN cíclicas o GAN Pix2Pix.



## 5. Anexos

### 5.1 Encuesta

# Evaluación del rendimiento de una Red Neuronal Generativa Antagónica en la Generación de un banco de imágenes de radiografías panorámicas dentales humanas

El presente test se le realiza a profesionales en el área de la salud dental, con el propósito de evaluar que tan reales pueden llegar a ser las imágenes de radiografías panorámicas dentales humanas generadas por una herramienta de Inteligencia Artificial en el área del Deep Learning (Redes Neuronales Generativas Antagónicas) Por tal motivo es de vital importancia que sea totalmente franco a la hora de responder.

Este Trabajo Integral de Grado (TIG), se realiza desde la facultad de Ingeniería Electrónica, Mecánica y Biomédica (FIMEB), de la Universidad Antonio Nariño, para obtener el título como Ingeniero Electrónico.

De antemano Agradecemos el aporte de su tiempo y conocimiento brindado

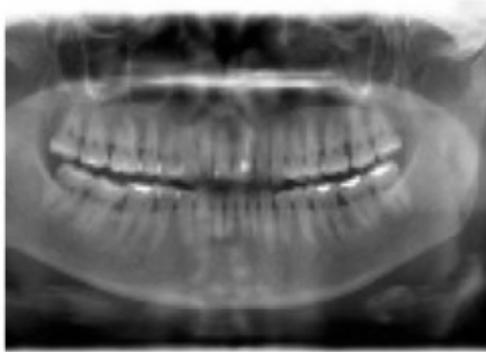
Cordialmente,  
Maria Camila Vivas Gasca y Erlyn Julian Cediel Sánchez

EVENTO  
1

Este Banco de imágenes fue desarrollado en base a 25 imágenes reales con un tamaño de 128x96 imágenes panorámicas dentales, y se crearon 300 imágenes en un tiempo de 5horas con 25min

1. La siguiente imagen para usted es:

0 puntos



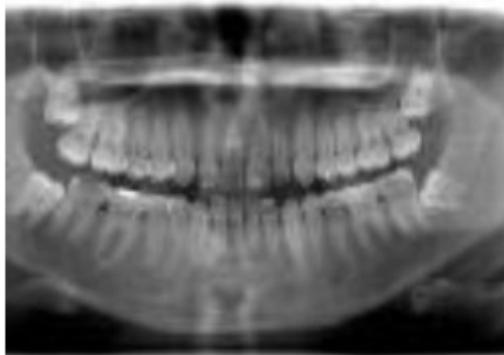
*Marca solo un óvalo.*

Real

Aparente

2. La siguiente imagen para usted es:

0 puntos



*Marca solo un óvalo.*

Real

Aparente

3. La siguiente imagen para usted es:

0 puntos



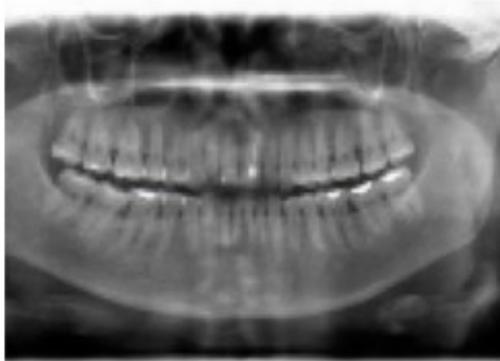
*Marca solo un óvalo.*

Real

Aparente

4. La siguiente imagen para usted es:

0 puntos



*Marca solo un óvalo.*

Real

Aparente

5. La siguiente imagen para usted es:

0 puntos

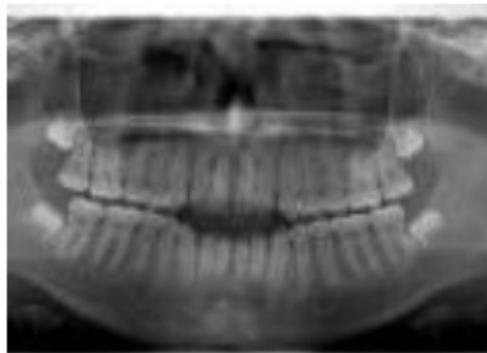


*Marca solo un óvalo.*

- Real
- Aparente

6. La siguiente imagen para usted es:

0 puntos

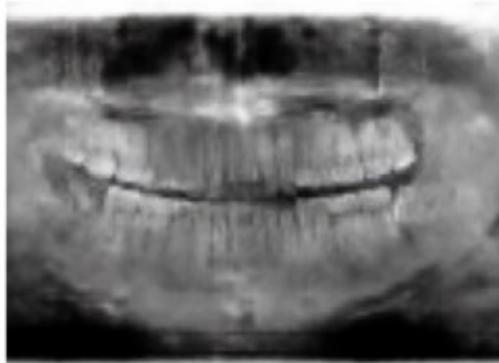


*Marca solo un óvalo.*

- Real
- Aparente

7. La siguiente imagen para usted es:

0 puntos



Marca solo un óvalo.

- Real
- Aparente

8. La siguiente imagen para usted es:

0 puntos



Marca solo un óvalo.

- Real
- Aparente

## 9. Que lo llevo a comprobar la falsedad de las imágenes ?

Nota: Exaltación de puntos, hace referencia a lo que hace característico la imagen (Brackets, Caries, etc...)

*Marca solo un óvalo.*

- Distorsion de la Imagen
- Exaltación de puntos
- Otra

## 10. Si su respuesta en la sección anterior fue "Otra", por favor de una breve descripción

---

---

---

---

---

## 11. En la Escala de 1 a 5, qué calificación le daría usted a la calidad de las imágenes radiográficas panorámicas dentales humanas mostradas ?

*Marca solo un óvalo.*

1	2	3	4	5
<input type="radio"/>				

---

## 5.2 Banco de Imágenes generado por medio de la GAN

[https://drive.google.com/drive/folders/1hYgh2x\\_6lQnYzOFkUqju7QHo4zHJ3QWq?usp=sharing](https://drive.google.com/drive/folders/1hYgh2x_6lQnYzOFkUqju7QHo4zHJ3QWq?usp=sharing)

## 5.3 Tablas de Confusión de los experimentos

Tablas de cofusión de las respuestas para los Profesionales en la Salud dental									
<b>Experimento 1</b>									
Respuesta correcta		Aparente	Real	Real	Aparente	Aparente	Real	Aparente	Real
	Real/Real	0	2	2	0	0	2	0	2
	Aparente/Aparente	3	0	0	3	4	0	4	0
	Real/Aparente	0	3	3	0	0	3	0	3
	Aparente/Real	2	0	0	2	1	0	1	0
<b>Experimento 2</b>									
Respuesta correcta		Real	Aparente	Aparente	Real	Real	Real	Aparente	Aparente
	Real/Real	2	0	0	2	2	2	0	0
	Aparente/Aparente	0	3	3	0	0	0	3	3
	Real/Aparente	3	0	0	3	3	3	0	0
	Aparente/Real	0	2	2	0	0	0	2	2
<b>Experimento 3</b>									
Respuesta correcta		Aparente	Real	Real	Aparente	Aparente	Real	Aparente	Real
	Real/Real	0	0	2	2	2	0	0	2
	Aparente/Aparente	5	5	0	0	0	5	5	0
	Real/Aparente	0	0	3	3	3	0	0	3
	Aparente/Real	0	0	0	0	0	0	0	0
<b>Experimento 4</b>									
Respuesta correcta		Real	Aparente	Aparente	Real	Real	Real	Aparente	Aparente
	Real/Real	4	0	3	0	4	4	0	0
	Aparente/Aparente	0	5	0	5	0	0	5	5
	Real/Aparente	1	0	2	0	1	1	0	0
	Aparente/Real	0	0	0	0	0	0	0	0
<b>Experimento 5</b>									
Respuesta correcta		Aparente	Real	Real	Aparente	Aparente	Real	Aparente	Real
	Real/Real	0	4	0	3	4	4	0	0
	Aparente/Aparente	5	0	5	0	0	0	4	4
	Real/Aparente	0	1	0	2	1	1	0	0
	Aparente/Real	0	0	0	0	0	0	1	1
<b>Experimento 6</b>									
Respuesta correcta		Real	Aparente	Aparente	Real	Real	Real	Aparente	Aparente
	Real/Real	0	0	4	4	4	0	0	4
	Aparente/Aparente	5	5	0	0	0	5	5	0
	Real/Aparente	0	0	1	1	1	0	0	1
	Aparente/Real	0	0	0	0	0	0	0	0
<b>Experimento 7</b>									
Respuesta correcta		Aparente	Real	Real	Aparente	Aparente	Real	Aparente	Real
	Real/Real	4	0	0	4	0	4	4	0
	Aparente/Aparente	0	1	1	0	3	0	0	3
	Real/Aparente	1	0	0	1	0	1	1	0
	Aparente/Real	0	4	4	0	2	0	0	2
<b>Experimento 8</b>									
Respuesta correcta		Real	Aparente	Aparente	Real	Real	Real	Aparente	Aparente
	Real/Real	0	4	4	0	0	0	4	4
	Aparente/Aparente	4	0	0	5	5	5	0	0
	Real/Aparente	0	1	1	0	0	0	1	1
	Aparente/Real	1	0	0	0	0	0	0	0

Tablas de cofusión de las respuestas para los No Profesionales en la Salud dental								
<b>Experimento 1</b>								
Respuesta correcta	Aparente	Real	Real	Aparente	Aparente	Real	Aparente	Real
Real/Real	0	54	28	0	0	44	0	53
Aparente/Aparente	35	0	0	34	54	0	70	0
Real/Aparente	0	33	59	0	0	43	0	34
Aparente/Real	52	0	0	53	32	0	17	0
<b>Experimento 2</b>								
Respuesta correcta	Real	Aparente	Aparente	Real	Real	Real	Aparente	Aparente
Real/Real	0	10	14	0	0	57	0	17
Aparente/Aparente	24	0	0	46	35	0	74	0
Real/Aparente	0	74	72	0	0	28	0	69
Aparente/Real	61	0	0	40	51	0	12	0
<b>Experimento 3</b>								
Respuesta correcta	Aparente	Real	Real	Aparente	Aparente	Real	Aparente	Real
Real/Real	0	8	73	0	0	8	0	55
Aparente/Aparente	78	0	0	32	23	0	80	0
Real/Aparente	0	77	12	0	0	77	0	30
Aparente/Real	7	0	0	53	62	0	5	0
<b>Experimento 4</b>								
Respuesta correcta	Real	Aparente	Aparente	Real	Real	Real	Aparente	Aparente
Real/Real	0	7	53	0	0	70	0	5
Aparente/Aparente	13	0	0	81	22	0	82	0
Real/Aparente	0	78	33	0	0	16	0	81
Aparente/Real	73	0	0	5	63	0	4	0
<b>Experimento 5</b>								
Respuesta correcta	Aparente	Real	Real	Aparente	Aparente	Real	Aparente	Real
Real/Real	0	80	9	0	0	78	0	10
Aparente/Aparente	75	0	0	10	15	0	75	0
Real/Aparente	0	6	77	0	0	8	0	75
Aparente/Real	10	0	0	76	71	0	11	0
<b>Experimento 6</b>								
Respuesta correcta	Real	Aparente	Aparente	Real	Real	Real	Aparente	Aparente
Real/Real	0	8	76	0	0	5	0	75
Aparente/Aparente	78	0	0	4	5	0	77	0
Real/Aparente	0	78	10	0	0	81	0	11
Aparente/Real	7	0	0	82	80	0	9	0
<b>Experimento 7</b>								
Respuesta correcta	Aparente	Real	Real	Aparente	Aparente	Real	Aparente	Real
Real/Real	0	72	75	0	0	70	0	48
Aparente/Aparente	8	0	0	8	43	0	10	0
Real/Aparente	0	13	11	0	0	15	0	37
Aparente/Real	78	0	0	78	41	0	75	0
<b>Experimento 8</b>								
Respuesta correcta	Real	Aparente	Aparente	Real	Real	Real	Aparente	Aparente
Real/Real	0	80	83	0	0	10	0	67
Aparente/Aparente	78	0	0	78	77	0	9	0
Real/Aparente	0	5	3	0	0	75	0	19
Aparente/Real	7	0	0	7	9	0	77	0

## 6. Bibliografía

Azuar Alonso, D. (2019). Transformación de emociones mediante redes generativas antagónicas.

Almeida Lucas, E. (2019). Pronóstico de energía eólica para horizontes temporales de corto plazo en base a modelo numérico de mesoescala y redes neuronales artificiales.

Bilkis, M. (2018). Entropía condicional y correlaciones cuánticas (Doctoral dissertation, Universidad Nacional de La Plata).

Bogotá, C. D. C. (2012). Ley 1581 de 2012.

Creswell, A., White, T., Dumoulin, V., Arulkumaran, K., Sengupta, B., & Bharath, A. A. (2018). Generative adversarial networks: An overview. *IEEE Signal Processing Magazine*.

Condiciona, C. I. D. L. P., & Independencia, E. (2005). Razonamiento sobre probabilidad condicional e implicaciones para la enseñanza de la estadística. *Epsilon*, *59*, 245-260.

- Choi, E., Biswal, S., Malin, B., Duke, J., Stewart, W. F., & Sun, J. (2017). Generating multi-label discrete patient records using generative adversarial networks. arXiv preprint arXiv:1703.06490.
- Colombia, L. E. 1581 de 2012, por la cual se dictan disposiciones generales para la protección de datos personales, 48.587 Diario Oficial, 18 de octubre de 2012.
- Chuquicusma, M. J., Hussein, S., Burt, J., & Bagci, U. (2018, April). How to fool radiologists with generative adversarial networks? a visual Turing test for lung cancer diagnosis. In 2018 IEEE 15th international symposium on biomedical imaging (ISBI 2018) (pp. 240-244). IEEE.
- Chi, C., Du, Y., Ye, J., Kou, D., Qiu, J., Wang, J., ... & Chen, X. (2014). Intraoperative imaging-guided cancer surgery: from current fluorescence molecular imaging methods to future multi-modality imaging technology. *Theranostics*, 4(11), 1072
- Denton, E. L., Chintala, S., & Fergus, R. (2015). Deep generative image models using a [00] laplacian pyramid of adversarial networks. In *Advances in neural information processing systems* (pp. 1486-1494).
- Dumoulin, V., & Visin, F. (2016). A guide to convolution arithmetic for deep learning. arXiv preprint arXiv:1603.07285.
- Durugkar, I., Gemp, I., & Mahadevan, S. (2016). Generative multi-adversarial networks. arXiv preprint arXiv:1611.01673.
- Fernández Blanco, R. (2019). Deep Learning para la generación de imágenes histopatológicas realistas mediante aritmética de vectores conceptuales.

- Frid-Adar, M., Diamant, I., Klang, E., Amitai, M., Goldberger, J., & Greenspan, H. (2018). GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification. *Neurocomputing*, 321, 321-331.
- Franco, E. F., & Ramos, R. J. (2019). Aprendizaje de máquina y aprendizaje profundo en biotecnología: aplicaciones, impactos y desafíos. *Ciencia, Ambiente y Clima*, 2(2), 7-26.
- González-Islas, J. C. (2019). Aprendizaje Automático en Aplicaciones Fisioterapéuticas. *Pädi Boletín Científico de Ciencias Básicas e Ingenierías del ICBI*, 7(Especial), 104-110.
- Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). Generative Adversarial Networks. jun 2014a. URL <http://arxiv.org/abs/1406.2661>.
- GAN'S. (2018). GitHub. <https://github.com/hindupuravinash/the-gan-zoo/blob/master/gans.tsv>
- Grau Romero, M. (2020). Clasificador de modelos de movilidad mediante Deep Learning.
- Gadermayr, M., Li, K., Müller, M., Truhn, D., Krämer, N., Merhof, D., & Gess, B. (2019). Domain-specific data augmentation for segmenting MR images of fatty infiltrated human thighs with neural networks. *Journal of Magnetic Resonance Imaging*, 49(6), 1676-1683.
- IBM. (2020). Inteligencia artificial. [https://www.ibm.com/ar-es/analytics/machine-learning?p1=Search&p4=43700053692634426&p5=b&cm\\_mmc=Search\\_Google\\_-\\_1S\\_1S\\_-\\_LA\\_ISA\\_-\\_datos%20%2Bmachine%20%2Blearning\\_b&cm\\_mmca7=71700000065289299&cm\\_mmca8=kwd-1097762210552&cm\\_mmca9=CjwKCAjwrKr8BRB\\_EiwA7eFapopIBXhOjyB0gi1Tz](https://www.ibm.com/ar-es/analytics/machine-learning?p1=Search&p4=43700053692634426&p5=b&cm_mmc=Search_Google_-_1S_1S_-_LA_ISA_-_datos%20%2Bmachine%20%2Blearning_b&cm_mmca7=71700000065289299&cm_mmca8=kwd-1097762210552&cm_mmca9=CjwKCAjwrKr8BRB_EiwA7eFapopIBXhOjyB0gi1Tz)

dft5sS0nEeMRpTLXrAMBd6Ka1ermUjkH5SqVxoCSLgQAvD\_BwE&cm\_mmca10=451404725204&cm\_mmca11=b&gclid=CjwKCAjwrKr8BRB\_EiwA7eFapopIBXhOjyB0gi1Tzdft5sS0nEeMRpTLXrAMBd6Ka1ermUjkH5SqVxoCSLgQAvD\_BwE&gclid=aw.ds. [https://www.ibm.com/ar-es/analytics/machine-learning?p1=Search&p4=43700053692634426&p5=b&cm\\_mmc=Search\\_Google\\_-\\_1S\\_1S\\_-\\_LA\\_ISA\\_-\\_datos%20%2Bmachine%20%2Blearning\\_b&cm\\_mmca7=71700000065289299&cm\\_mmca8=kwd-1097762210552&cm\\_mmca9=CjwKCAjwrKr8BRB\\_EiwA7eFapopIBXhOjyB0gi1Tzdft5sS0nEeMRpTLXrAMBd6Ka1ermUjkH5SqVxoCSLgQAvD\\_BwE&cm\\_mmca10=451404725204&cm\\_mmca11=b&gclid=CjwKCAjwrKr8BRB\\_EiwA7eFapopIBXhOjyB0gi1Tzdft5sS0nEeMRpTLXrAMBd6Ka1ermUjkH5SqVxoCSLgQAvD\\_BwE&gclid=aw.ds](https://www.ibm.com/ar-es/analytics/machine-learning?p1=Search&p4=43700053692634426&p5=b&cm_mmc=Search_Google_-_1S_1S_-_LA_ISA_-_datos%20%2Bmachine%20%2Blearning_b&cm_mmca7=71700000065289299&cm_mmca8=kwd-1097762210552&cm_mmca9=CjwKCAjwrKr8BRB_EiwA7eFapopIBXhOjyB0gi1Tzdft5sS0nEeMRpTLXrAMBd6Ka1ermUjkH5SqVxoCSLgQAvD_BwE&cm_mmca10=451404725204&cm_mmca11=b&gclid=CjwKCAjwrKr8BRB_EiwA7eFapopIBXhOjyB0gi1Tzdft5sS0nEeMRpTLXrAMBd6Ka1ermUjkH5SqVxoCSLgQAvD_BwE&gclid=aw.ds)

Irala, J., Martínez-González, M. Á., & Grima, F. G. (2001). ¿ Qué es una variable de confusión?. *Medicina clínica*, 117(10), 377-385.

Li, R., Zhang, W., Suk, H. I., Wang, L., Li, J., Shen, D., & Ji, S. (2014, September). Deep learning based imaging data completion for improved brain disease diagnosis. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 305-312). Springer, Cham.

Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60-88.

Miyato, T., Kataoka, T., Koyama, M., & Yoshida, Y. (2018). Spectral normalization for generative adversarial networks. *arXiv preprint arXiv:1802.05957*.

Mantilla Mendez, A., & Vega Arango, J. S. (2011). *Magi: Sistema Basado En Técnicas De Inteligencia Artificial Y De Tratamiento Digital De Imágenes Para La Detección De*

Tumores Cerebrales (Doctoral dissertation, Universidad Industrial de Santander, Escuela De Ing. De Sistemas).

Onishi, Y., Teramoto, A., Tsujimoto, M., Tsukamoto, T., Saito, K., Toyama, H., ... & Fujita, H. (2019). Automated pulmonary nodule classification in computed tomography images using a deep convolutional neural network trained by generative adversarial networks. *BioMed research international*, 2019.

Radford, A., Metz, L., & Chintala, S. (2015). Unsupervised representation learning with deep convolutional generative adversarial networks. *arXiv preprint arXiv:1511.06434*.

Russ, T., Goertler, S., Schnurr, A. K., Bauer, D. F., Hatamikia, S., Schad, L. R., ... & Chung, K. (2019). Synthesis of CT images from digital body phantoms using CycleGAN. *International Journal of Computer Assisted Radiology and Surgery*, 14(10), 1741-1750.

Rudas, J., & Sánchez Torres, G. (2013). Detección de patologías derivadas de las afecciones diabéticas: una revisión del análisis digital de imágenes de retina. *Revista Científica Ingeniería y Desarrollo*, 31(2), 316-338.

Sandoval, T. C. N., Pérez, S. V. G., González, F. A., Jaque, R. A., & Infante, C. (2016). Uso de redes neuronales artificiales en predicción de morfología mandibular a través de variables craneomaxilares en una vista posteroanterior/Use of Artificial Neural Networks for Mandibular Morphology Prediction through Craniomaxillar Variables... *Universitas Odontológica*, 35(74), 21-28.

Silva, G., Oliveira, L., & Pithon, M. (2018). Corrigendum to "Automatic segmenting teeth in X-ray images: Trends, a novel data set, benchmarking and future perspectives"[*Expert Systems with Applications*, Vol. 107 (2018) 15-31]. *Expert Syst. Appl.*, 112, 61.

- Sorin, V., Barash, Y., Konen, E., & Klang, E. (2020). Creating Artificial Images for Radiology Applications Using Generative Adversarial Networks (GANs)—A Systematic Review. *Academic Radiology*.
- Torres, J. (2020). *Python Deep Learning, Introducción práctica con Keras y TensorFlow 2*. alphaeditorial.
- Xu, L., Ren, J. S., Liu, C., & Jia, J. (2014). Deep convolutional neural network for image deconvolution. In *Advances in neural information processing systems* (pp. 1790-1798).
- Yang, G., Yu, S., Dong, H., Slabaugh, G., Dragotti, P. L., Ye, X., ... & Firmin, D. (2017). DAGAN: Deep de-aliasing generative adversarial networks for fast compressed sensing MRI reconstruction. *IEEE transactions on medical imaging*, 37(6), 1310-1321.
- Yi, X., Walia, E., & Babyn, P. (2019). Generative adversarial network in medical imaging: A review. *Medical image analysis*, 58, 101552.
- Zhao, X., Liu, L., Qi, S., Teng, Y., Li, J., & Qian, W. (2018). Agile convolutional neural network for pulmonary nodule classification using CT images. *International journal of computer assisted radiology and surgery*, 13(4), 585-595.