

	<b>MACROPROCESO DE APOYO</b>	<b>CÓDIGO: AAAR113</b>
	<b>PROCESO GESTIÓN APOYO ACADÉMICO</b>	<b>VERSIÓN: 3</b>
	<b>DESCRIPCIÓN, AUTORIZACIÓN Y LICENCIA DEL REPOSITORIO INSTITUCIONAL</b>	<b>VIGENCIA: 2017-11-16</b>
		<b>PAGINA: 1 de 7</b>

16

<b>FECHA</b>	lunes, 25 de noviembre de 2019
--------------	--------------------------------

Señores  
**UNIVERSIDAD DE CUNDINAMARCA**  
 BIBLIOTECA  
 Ciudad

<b>UNIDAD REGIONAL</b>	Sede Fusagasugá
------------------------	-----------------

<b>TIPO DE DOCUMENTO</b>	Tesis
--------------------------	-------

<b>FACULTAD</b>	Ingeniería
-----------------	------------

<b>NIVEL ACADÉMICO DE FORMACIÓN O PROCESO</b>	Pregrado
---	----------

<b>PROGRAMA ACADÉMICO</b>	Ingeniería de Sistemas
---------------------------	------------------------

El Autor(Es):

<b>APELLIDOS COMPLETOS</b>	<b>NOMBRES COMPLETOS</b>	<b>No. DOCUMENTO DE IDENTIFICACIÓN</b>
BELTRAN LEON	JHON FREDY	1069758190
AREVALO RODRIGUEZ	WILLIAM FABIAN	1069750950

Diagonal 18 No. 20-29 Fusagasugá – Cundinamarca  
 Teléfono (091) 8281483 Línea Gratuita 018000976000  
 www.ucundinamarca.edu.co E-mail: info@ucundinamarca.edu.co  
 NIT: 890.680.062-2

*Documento controlado por el Sistema de Gestión de la Calidad  
 Asegúrese que corresponde a la última versión consultando el Portal Institucional*

	<b>MACROPROCESO DE APOYO</b>	<b>CÓDIGO: AAAr113</b>
	<b>PROCESO GESTIÓN APOYO ACADÉMICO</b>	<b>VERSIÓN: 3</b>
	<b>DESCRIPCIÓN, AUTORIZACIÓN Y LICENCIA DEL REPOSITORIO INSTITUCIONAL</b>	<b>VIGENCIA: 2017-11-16</b>
		<b>PAGINA: 2 de 7</b>

Director(Es) y/o Asesor(Es) del documento:

<b>APELLIDOS COMPLETOS</b>	<b>NOMBRES COMPLETOS</b>
ARENAS AMADO	ANGELA PATRICIA
CAICEDO DORADO	ALEXANDER

<b>TÍTULO DEL DOCUMENTO</b>
<b>SELECCIÓN DE MODELO DE RED NEURONAL PROFUNDA (DEEP LEARNING) ÓPTIMO PARA EL RECONOCIMIENTO DE ENFERMEDADES USANDO IMÁGENES DE RAYOS X</b>

<b>SUBTÍTULO</b> (Aplica solo para Tesis, Artículos Científicos, Disertaciones, Objetos Virtuales de Aprendizaje)

<b>TRABAJO PARA OPTAR AL TÍTULO DE:</b> Aplica para Tesis/Trabajo de Grado/Pasantía
<b>INGENIERO DE SISTEMAS</b>

<b>AÑO DE EDICIÓN DEL DOCUMENTO</b>	<b>NÚMERO DE PÁGINAS</b>
25/11/2019	93

<b>DESCRIPTORES O PALABRAS CLAVES EN ESPAÑOL E INGLÉS</b> (Usar 6 descriptores o palabras claves)	
<b>ESPAÑOL</b>	<b>INGLÉS</b>
1. Rayos X	X-rays
2. Red Neuronal Profunda	Deep Neural Network
3. Entorno Cloud	Cloud Environment
4. Arquitectura modelo	Model Architecture
5. Metodología	Methodology
6.	

Diagonal 18 No. 20-29 Fusagasugá – Cundinamarca  
Teléfono (091) 8281483 Línea Gratuita 018000976000  
www.ucundinamarca.edu.co E-mail: info@ucundinamarca.edu.co  
NIT: 890.680.062-2

*Documento controlado por el Sistema de Gestión de la Calidad  
Asegúrese que corresponde a la última versión consultando el Portal Institucional*



<b>MACROPROCESO DE APOYO</b>	<b>CÓDIGO: AAAR113</b>
<b>PROCESO GESTIÓN APOYO ACADÉMICO</b>	<b>VERSIÓN: 3</b>
<b>DESCRIPCIÓN, AUTORIZACIÓN Y LICENCIA DEL REPOSITORIO INSTITUCIONAL</b>	<b>VIGENCIA: 2017-11-16</b>
	<b>PAGINA: 3 de 7</b>

### RESUMEN DEL CONTENIDO EN ESPAÑOL E INGLÉS

(Máximo 250 palabras – 1530 caracteres, aplica para resumen en español):

En el proyecto, Selección de Modelo de Red Neuronal Profunda (Deep Learning) óptimo para el reconocimiento de enfermedades usando imágenes de Rayos X, comprende la resolución de un problema práctico en el ámbito médico en el que se propone un modelo óptimo y sencillo que permite la clasificación de una lista de enfermedades reconocibles por una red neuronal convolucional. De esta forma se abarca el proyecto a través de diferentes etapas que permiten una resolución semisecuencial, lo que concede una mayor trazabilidad frente a los experimentos que se ejecutan para reconocer la arquitectura que tenga mayor adaptación por lo tanto mayor rendimiento frente al problema. Todos estos experimentos son ejecutados bajo un entorno cloud que permite mayor potencia al momento de entrenar modelos que demanden gran cantidad de recursos. Por último, se realiza una comparativa entre los puntajes arrojados por los modelos entrenados de otras investigaciones, dando como conclusión que el modelo elegido se encuentra al nivel del estado del arte actual para este problema y grupo de datos.

In the project, Selection of Deep Neural Network Model (Deep Learning) optimal for the recognition of diseases using X-ray images, includes the resolution of a practical problem in the medical field in which an optimal and simple model is proposed that allows the classification of a list of recognizable diseases by a convolutional neural network. In this way, the project is covered through different stages that allow a semi-sequential resolution, which gives greater traceability to the experiments that are executed to recognize the architecture that has better adaptation, therefore, better performance against the problem. All these experiments are performed under a cloud environment that allows more power when training models that demand a lot of resources. Finally, a comparison is made between the scores thrown by the trained models of other investigations, giving as conclusion that the chosen model is at the level of the current state of the art for this problem and group of data.

### AUTORIZACION DE PUBLICACIÓN

Por medio del presente escrito autorizo (Autorizamos) a la Universidad de Cundinamarca para que, en desarrollo de la presente licencia de uso parcial, pueda ejercer sobre mí (nuestra) obra las atribuciones que se indican a continuación, teniendo en cuenta que, en cualquier caso, la finalidad perseguida será facilitar, difundir y promover el aprendizaje, la enseñanza y la investigación.

En consecuencia, las atribuciones de usos temporales y parciales que por virtud de la presente licencia se autoriza a la Universidad de Cundinamarca, a los usuarios de la Biblioteca de la Universidad; así como a los usuarios de las redes, bases de datos y demás sitios web con los que la Universidad tenga perfeccionado una alianza, son: Marque con una "X":

Diagonal 18 No. 20-29 Fusagasugá – Cundinamarca  
Teléfono (091) 8281483 Línea Gratuita 018000976000  
www.ucundinamarca.edu.co E-mail: info@ucundinamarca.edu.co  
NIT: 890.680.062-2



<b>MACROPROCESO DE APOYO</b>	<b>CÓDIGO: AAAr113</b>
<b>PROCESO GESTIÓN APOYO ACADÉMICO</b>	<b>VERSIÓN: 3</b>
<b>DESCRIPCIÓN, AUTORIZACIÓN Y LICENCIA DEL REPOSITORIO INSTITUCIONAL</b>	<b>VIGENCIA: 2017-11-16</b>
	<b>PAGINA: 4 de 7</b>

<b>Autorizo (Autorizamos)</b>	<b>SI</b>	<b>NO</b>
1. La reproducción por cualquier formato conocido o por conocer.	X	
2. La comunicación pública por cualquier procedimiento o medio físico o electrónico, así como su puesta a disposición en Internet.	X	
3. La inclusión en bases de datos y en sitios web sean éstos onerosos o gratuitos, existiendo con ellos previa alianza perfeccionada con la Universidad de Cundinamarca para efectos de satisfacer los fines previstos. En este evento, tales sitios y sus usuarios tendrán las mismas facultades que las aquí concedidas con las mismas limitaciones y condiciones.	X	
4. La inclusión en el Repositorio Institucional.	X	

De acuerdo con la naturaleza del uso concedido, la presente licencia parcial se otorga a título gratuito por el máximo tiempo legal colombiano, con el propósito de que en dicho lapso mi (nuestra) obra sea explotada en las condiciones aquí estipuladas y para los fines indicados, respetando siempre la titularidad de los derechos patrimoniales y morales correspondientes, de acuerdo con los usos honrados, de manera proporcional y justificada a la finalidad perseguida, sin ánimo de lucro ni de comercialización.

Para el caso de las Tesis, Trabajo de Grado o Pasantía, de manera complementaria, garantizo(garantizamos) en mi(nuestra) calidad de estudiante(s) y por ende autor(es) exclusivo(s), que la Tesis, Trabajo de Grado o Pasantía en cuestión, es producto de mi(nuestra) plena autoría, de mi(nuestro) esfuerzo personal intelectual, como consecuencia de mi(nuestra) creación original particular y, por tanto, soy(somos) el(los) único(s) titular(es) de la misma. Además, aseguro (aseguramos) que no contiene citas, ni transcripciones de otras obras protegidas, por fuera de los límites autorizados por la ley, según los usos honrados, y en proporción a los fines previstos; ni tampoco contempla declaraciones difamatorias contra terceros; respetando el derecho a la imagen, intimidad, buen nombre y demás derechos constitucionales. Adicionalmente, manifiesto (manifestamos) que no se incluyeron expresiones contrarias al orden público ni a las buenas costumbres. En consecuencia, la responsabilidad directa en la elaboración, presentación, investigación y, en general, contenidos de la Tesis o Trabajo de Grado es de mí (nuestra) competencia exclusiva, eximiendo de toda responsabilidad a la Universidad de Cundinamarca por tales aspectos.

Sin perjuicio de los usos y atribuciones otorgadas en virtud de este documento, continuaré (continuaremos) conservando los correspondientes derechos patrimoniales sin modificación o restricción alguna, puesto que, de acuerdo con la legislación colombiana aplicable, el presente es un acuerdo jurídico que en ningún



<b>MACROPROCESO DE APOYO</b>	<b>CÓDIGO: AAAr113</b>
<b>PROCESO GESTIÓN APOYO ACADÉMICO</b>	<b>VERSIÓN: 3</b>
<b>DESCRIPCIÓN, AUTORIZACIÓN Y LICENCIA DEL REPOSITORIO INSTITUCIONAL</b>	<b>VIGENCIA: 2017-11-16</b>
	<b>PAGINA: 5 de 7</b>

caso conlleva la enajenación de los derechos patrimoniales derivados del régimen del Derecho de Autor.

De conformidad con lo establecido en el artículo 30 de la Ley 23 de 1982 y el artículo 11 de la Decisión Andina 351 de 1993, “*Los derechos morales sobre el trabajo son propiedad de los autores*”, los cuales son irrenunciables, imprescriptibles, inembargables e inalienables. En consecuencia, la Universidad de Cundinamarca está en la obligación de RESPETARLOS Y HACERLOS RESPETAR, para lo cual tomará las medidas correspondientes para garantizar su observancia.

**NOTA:** (Para Tesis, Trabajo de Grado o Pasantía):

**Información Confidencial:**

Esta Tesis, Trabajo de Grado o Pasantía, contiene información privilegiada, estratégica, secreta, confidencial y demás similar, o hace parte de la investigación que se adelanta y cuyos resultados finales no se han publicado.

**SI \_\_\_ NO X.**

En caso afirmativo expresamente indicaré (indicaremos), en carta adjunta tal situación con el fin de que se mantenga la restricción de acceso.

**LICENCIA DE PUBLICACIÓN**

Como titular(es) del derecho de autor, confiero(erimos) a la Universidad de Cundinamarca una licencia no exclusiva, limitada y gratuita sobre la obra que se integrará en el Repositorio Institucional, que se ajusta a las siguientes características:

- a) Estará vigente a partir de la fecha de inclusión en el repositorio, por un plazo de 5 años, que serán prorrogables indefinidamente por el tiempo que dure el derecho patrimonial del autor. El autor podrá dar por terminada la licencia solicitándolo a la Universidad por escrito. (Para el caso de los Recursos Educativos Digitales, la Licencia de Publicación será permanente).
- b) Autoriza a la Universidad de Cundinamarca a publicar la obra en formato y/o soporte digital, conociendo que, dado que se publica en Internet, por este hecho circula con un alcance mundial.
- c) Los titulares aceptan que la autorización se hace a título gratuito, por lo tanto, renuncian a recibir beneficio alguno por la publicación, distribución, comunicación pública y cualquier otro uso que se haga en los términos de la presente licencia y de la licencia de uso con que se publica.



<b>MACROPROCESO DE APOYO</b>	<b>CÓDIGO: AAAR113</b>
<b>PROCESO GESTIÓN APOYO ACADÉMICO</b>	<b>VERSIÓN: 3</b>
<b>DESCRIPCIÓN, AUTORIZACIÓN Y LICENCIA DEL REPOSITORIO INSTITUCIONAL</b>	<b>VIGENCIA: 2017-11-16</b>
	<b>PAGINA: 6 de 7</b>

d) El(Los) Autor(es), garantizo(amos) que el documento en cuestión, es producto de mi(nuestra) plena autoría, de mi(nuestro) esfuerzo personal intelectual, como consecuencia de mi (nuestra) creación original particular y, por tanto, soy(somos) el(los) único(s) titular(es) de la misma. Además, aseguro(aseguramos) que no contiene citas, ni transcripciones de otras obras protegidas, por fuera de los límites autorizados por la ley, según los usos honrados, y en proporción a los fines previstos; ni tampoco contempla declaraciones difamatorias contra terceros; respetando el derecho a la imagen, intimidad, buen nombre y demás derechos constitucionales. Adicionalmente, manifiesto (manifestamos) que no se incluyeron expresiones contrarias al orden público ni a las buenas costumbres. En consecuencia, la responsabilidad directa en la elaboración, presentación, investigación y, en general, contenidos es de mí (nuestro) competencia exclusiva, eximiendo de toda responsabilidad a la Universidad de Cundinamarca por tales aspectos.

e) En todo caso la Universidad de Cundinamarca se compromete a indicar siempre la autoría incluyendo el nombre del autor y la fecha de publicación.

f) Los titulares autorizan a la Universidad para incluir la obra en los índices y buscadores que estimen necesarios para promover su difusión.

g) Los titulares aceptan que la Universidad de Cundinamarca pueda convertir el documento a cualquier medio o formato para propósitos de preservación digital.

h) Los titulares autorizan que la obra sea puesta a disposición del público en los términos autorizados en los literales anteriores bajo los límites definidos por la universidad en el “Manual del Repositorio Institucional AAAM003”

i) Para el caso de los Recursos Educativos Digitales producidos por la Oficina de Educación Virtual, sus contenidos de publicación se rigen bajo la Licencia Creative Commons: Atribución- No comercial- Compartir Igual.



j) Para el caso de los Artículos Científicos y Revistas, sus contenidos se rigen bajo la Licencia Creative Commons Atribución- No comercial- Sin derivar.



**Nota:**

Si el documento se basa en un trabajo que ha sido patrocinado o apoyado por una entidad, con excepción de Universidad de Cundinamarca, los autores garantizan que se ha cumplido con los derechos y obligaciones requeridos por el respectivo contrato o acuerdo.



<b>MACROPROCESO DE APOYO</b>	<b>CÓDIGO: AAAr113</b>
<b>PROCESO GESTIÓN APOYO ACADÉMICO</b>	<b>VERSIÓN: 3</b>
<b>DESCRIPCIÓN, AUTORIZACIÓN Y LICENCIA DEL REPOSITORIO INSTITUCIONAL</b>	<b>VIGENCIA: 2017-11-16</b>
	<b>PAGINA: 7 de 7</b>

La obra que se integrará en el Repositorio Institucional, está en el(los) siguiente(s) archivo(s).

<b>Nombre completo del Archivo Incluida su Extensión (Ej. PerezJuan2017.pdf)</b>	<b>Tipo de documento (ej. Texto, imagen, video, etc.)</b>
1.ARTICULO.pdf	TEXTO
2.LIBRO.pdf	TEXTO
3.Codigo.zip	ARCHIVO COMPRIMIDO
4.modelo_optimo_xrays-multi-densenet121.ipynb	INTERACTIVE PYTHON NOTEBOOK
5. Registro Derecho de Autor.png	PNG IMAGEN
6. URLS Ejecuciones.txt	TEXTO
7. Evento – PayUniversity.pdf	TEXTO

En constancia de lo anterior, Firmo (amos) el presente documento:

<b>APELLIDOS Y NOMBRES COMPLETOS</b>	<b>FIRMA (autógrafa)</b>
BELTRAN LEON JHON FREDY	
AREVALO RODRIGUEZ WILLIAM FABIAN	

21.1-51-20

**SELECCIÓN DE MODELO DE RED NEURONAL PROFUNDA (DEEP LEARNING)  
ÓPTIMO PARA EL RECONOCIMIENTO DE ENFERMEDADES USANDO  
IMÁGENES DE RAYOS X**

JHON FREDY BELTRÁN LEÓN  
WILLIAM FABIAN AREVALO RODRIGUEZ.



UNIVERSIDAD DE CUNDINAMARCA  
FACULTAD DE INGENIERÍA  
PROGRAMA DE INGENIERÍA DE SISTEMAS  
FUSAGASUGÁ  
2019

**SELECCIÓN DE MODELO DE RED NEURONAL PROFUNDA (DEEP LEARNING) ii  
ÓPTIMO PARA EL RECONOCIMIENTO DE ENFERMEDADES USANDO  
IMÁGENES DE RAYOS X**

JHON FREDY BELTRÁN LEÓN  
WILLIAM FABIAN AREVALO RODRIGUEZ.

DOCUMENTO PROYECTO DE GRADO PARA OPTAR EL TÍTULO DE INGENIERO DE  
SISTEMAS DIRECTOR(A): ANGELA PATRICIA ARENAS AMADO

DIRECTOR(A):  
ANGELA PATRICIA ARENAS AMADO

ASESOR(A) EXTERNO:  
ALEXANDER CAICEDO DORADO

UNIVERSIDAD DE CUNDINAMARCA  
FACULTAD DE INGENIERÍA  
PROGRAMA DE INGENIERÍA DE SISTEMAS  
FUSAGASUGÁ  
2019

Copyright © 2019 por Jhon Fredy Beltrán León & William Fabian Arevalo. Todos los derechos reservados.

## **Agradecimientos**

iv

*Damos gracias a nuestros profesores por apoyarnos en todo el trayecto que nos llevó a culminar este proyecto el cual nos ha dejado grandes enseñanzas tanto prácticas como académicas, también queremos agradecer a nuestras familias por todo el apoyo indispensable que nos han brindado en todo momento, y a nuestros amigos por la colaboración y el acompañamiento en esta etapa.*

En el proyecto, Selección de Modelo de Red Neuronal Profunda (Deep Learning) óptimo para el reconocimiento de enfermedades usando imágenes de Rayos X, comprende la resolución de un problema práctico en el ámbito médico en el que se propone un modelo óptimo y sencillo que permite la clasificación de una lista de enfermedades reconocibles por una red neuronal convolucional. De esta forma se abarca el proyecto a través de diferentes etapas que permiten una resolución semisecuencia, lo que concede una mayor trazabilidad frente a los experimentos que se ejecutan para reconocer la arquitectura que tenga mayor adaptación por lo tanto mayor rendimiento frente al problema. Todos estos experimentos son ejecutados bajo un entorno cloud que permite mayor potencia al momento de entrenar modelos que demanden gran cantidad de recursos. Por último, se realiza una comparativa entre los puntajes arrojados por los modelos entrenados de otras investigaciones, dando como conclusión que el modelo elegido se encuentra al nivel del estado del arte actual para este problema y grupo de datos.

Palabras Clave: Rayos X, Red Neuronal Profunda, Entorno Cloud, Arquitectura modelo, Metodología.

In the project, Selection of Deep Neural Network Model (Deep Learning) optimal for the recognition of diseases using X-ray images, includes the resolution of a practical problem in the medical field in which an optimal and simple model is proposed that allows the classification of a list of recognizable diseases by a convolutional neural network. In this way, the project is covered through different stages that allow a semi-sequential resolution, which gives greater traceability to the experiments that are executed to recognize the architecture that has better adaptation, therefore, better performance against the problem. All these experiments are performed under a cloud environment that allows more power when training models that demand a lot of resources. Finally, a comparison is made between the scores thrown by the trained models of other investigations, giving as conclusion that the chosen model is at the level of the current state of the art for this problem and group of data.

Keywords: X-rays, Deep Neural Network, Cloud Environment, Model Architecture, Methodology.

## Tabla de Contenidos

vii

Abreviaturas.....	1
Introducción.....	2
Planteamiento del Problema.....	4
Justificación.....	8
Objetivos.....	10
Objetivo General.....	10
Objetivos Específicos.....	10
Metodología y Conjunto de Datos.....	11
Descripción de los datos.....	11
Metodología de trabajo.....	14
Etapa 1: Comprensión del negocio.....	15
Etapa 2: Enfoque analítico.....	15
Etapa 3: Requisitos de datos.....	15
Etapa 4: Recopilación de datos.....	15
Etapa 5: Compresión de datos.....	15
Etapa 6: Preparación de datos.....	15
Etapa 7: Modelado.....	15
Etapa 8: Evaluación.....	16
Etapa 9: Implementación.....	16
Etapa 10: Retroalimentación.....	16
Antecedentes.....	17
Marco Teórico.....	21
Inteligencia Artificial y tipos de aprendizaje.....	21
Python.....	23
Computación Distribuida.....	23
Kaggle.....	24
Test de Kruskal-Wallis.....	24
One Hot Encoding.....	24
Arquitectura de una red neuronal.....	25
Capas Convolucionales.....	29
Capas de Agrupación.....	30
Capas Completamente Conectadas.....	31
Hiperparámetros.....	32
Random state.....	32
Optimizador.....	32
Taza de aprendizaje.....	33
Épocas.....	33
Pasos por época.....	33
Tamaño del lote.....	33
Pasos de validación.....	33
Función de activación.....	33
Función de pérdida.....	33
Keras.....	33
Las Aplicaciones en Keras.....	34

Transfer Learning.....	viii
Métricas .....	38
Coeficiente de Kappa. ....	38
AUC-ROC.....	38
Perdida (Loss). ....	39
Marco Metodológico.....	41
Etapa 1: Comprensión del negocio. ....	41
Etapa 2: Enfoque analítico.....	42
Etapa 3: Requisitos de datos. ....	43
Etapa 4: Recopilación de datos. ....	43
DataSet.....	46
Notebook.....	46
Etapa 5: Compresión de datos.....	47
Etapa 6: Preparación de datos.....	50
Redimensión.....	50
Segmentación del Conjunto de Datos.....	51
Etiquetado. ....	51
Creación del Flujo de Entrenamiento. ....	52
Etapa 7: Modelado. ....	52
Primera fase estandarización de los hiperparámetros.....	52
Segunda fase experimentación del modelo con mejores resultados. ....	54
Etapa 8: Evaluación.....	54
Etapa 9: Implementación.....	57
Etapa 10: Retroalimentación.....	58
Resultados.....	59
Discusión .....	61
Recomendaciones para la Definición de un Proyecto de ML .....	61
Validar los datos.....	62
Definir cuidadosamente alcance y objetivos.....	62
Que temas estudiar antes de iniciar. ....	62
Conclusiones.....	64
Trabajo Futuro .....	65
Referencias .....	75

Tabla 1. Desempeño de Aplicaciones Seleccionadas al Clasificar Imágenes de Imagenet. ....	34
Tabla 2. Conjuntos de datos y sus características. ....	43
Tabla 3. Hiperparámetros y sus valores para todas las arquitecturas.....	53
Tabla 4. Arquitecturas entrenadas, cuentas e hipervínculos.....	53
Tabla 5. Hiperparámetros y sus valores para la arquitectura con mejores resultados. ....	54
Tabla 6. Puntajes roc para cada enfermedad, promedio, y perdida para cada arquitectura .....	55
Tabla 7. Puntajes roc para cada enfermedad, promedio, y perdida para la arquitectura optima ...	56
Tabla 8. Puntajes roc de la investigación contra otras investigaciones.....	59

## Lista de figuras

x

Figura 1. Metodología Fundamental para la Ciencia de Datos .....	14
Figura 2. Modelo Matemático Básico Para Una neurona .....	26
Figura 3. Flujo básico de una red neuronal. ....	27
Figura 4. Imagen RGB 4x4x3.....	29
Figura 5. Entrada de dimensión 28x28 con campo receptivo de área 5x5.....	30
Figura 6. Maxpooling con área 2x2. ....	31
Figura 7. Una capa totalmente conectada en una red profunda. ....	32
Figura 8. Gráfica de AUC-ROC. ....	38
Figura 9. Representación de una pérdida alta y una baja. ....	39
Figura 10. Representación de sobreajuste, subajuste y ajuste apropiado.....	40
Figura 11. Gestión a través de Trello. ....	41
Figura 12. Algunas enfermedades encontradas dentro del conjunto de imágenes. ....	45
Figura 13. Gráfica de Barras Etiquetas por Cantidad. ....	48
Figura 14. Gráfica de Distribución de Edad Contra Género .....	49
Figura 15. Gráfica de Barras Enfermedad contra Cantidad dependiendo del Género.....	49
Figura 16. Gráfica de Barras Cantidad de Seguimientos con Pacientes. ....	49
Figura 17. Gráfico de Barras Comparación entre Única y Múltiple Etiqueta .....	50
Figura 18. Representación de porcentajes del conjunto de datos .....	51
Figura 19. Imágenes aleatorias con su respectiva etiqueta y predicción.....	58

## **Abreviaturas**

**CNN:** Convolutional Neural Network (Red neuronal Convolucional)

## **Introducción**

En la actualidad las radiografías de tórax hacen parte de los exámenes más extendidos por los hospitales del mundo debido a su bajo coste y a que no son exámenes invasivos. Estas pueden ayudar a detectar enfermedades pulmonares, afecciones cardiacas, fracturas óseas, hernias entre otras, siempre y cuando sean analizadas por un profesional de la salud capacitado.

Un radiólogo como cualquier otro profesional requiere experiencia en su área para ser más preciso en las decisiones que toma, sin embargo, también debe lidiar contra factores como la fatiga visual durante una jornada laboral exigente o la cantidad de pacientes en algunos centros médicos, en donde pueden verse forzados a tomar decisiones en muy poco tiempo, lo cual puede llevarlos a cometer errores que se pueden traducir en diagnósticos errados.

Por otro lado, la capacidad de procesamiento de los dispositivos de cómputo actuales ha renovado el interés por la Inteligencia Artificial impulsando la evolución de diferentes áreas en las que se requiere realizar trabajos repetitivos con cierta experticia sin perder eficacia con el paso del tiempo, como lo puede ser la clasificación de imágenes. Apoyados en el crecimiento de los servicios de computación en la nube y de sus planes que ofrecen una capa gratuita, se abre la posibilidad de llevar este conocimiento a la práctica por parte de cualquier persona con conocimientos afines y acceso a internet.

Dentro de los modelos más eficientes para que un sistema artificial pueda aprender a reconocer patrones en imágenes se encuentran las redes neuronales

convolucionales las cuales en el área de la medicina pueden llegar a ser tan buenas como un radiólogo capacitado.

El propósito de este estudio es comparar el desempeño de algunas arquitecturas de red neuronal convolucional más usadas en la actualidad las cuales deben poder ejecutarse satisfactoriamente dentro de las capacidades de la capa gratuita de un servicio de computación en la nube.

## Planteamiento del Problema

Las radiografías junto con la historia clínica del paciente son generalmente el punto de partida de los médicos a la hora de dar un diagnóstico relacionado con afecciones del tórax siendo cruciales a la hora de detectar de manera temprana enfermedades como la neumonía (Franquet, 2001) la cual para el año 2017 fue una de las diez principales causas de muerte en EE. UU (CDC, 2019). Estas imágenes requieren de un radiólogo capacitado y con experiencia dado que en ocasiones la superposición de tejidos puede llegar a ocultar patologías o pueden ser el único radiólogo disponible y no va a tener manera de discutir sus apreciaciones (Dong, Pan, Zhang & Xu, 2017).

Así mismo como es de esperar, un radiólogo sin experiencia puede llegar a dar diagnósticos errados más frecuentemente que un radiólogo con varios años de experiencia, esta situación puede afectar la precisión de los diagnósticos sometidos a consenso en un grupo de radiólogos con diferentes niveles de experticia, un ejemplo de ello es que en un estudio reciente se compara la precisión de un radiólogo con más de diez años de experiencia y dos radiólogos novatos a la hora de detectar Tuberculosis en un grupo de 210 imágenes, llegando a obtener coeficientes de Cohen's kappa con valores de 0.61, 0.62 y 0.70 agrupados en pares, y un coeficiente de Fleiss' kappa con un valor de 0.64 entre los tres radiólogos (Paul et al., 2018).

Al encontrar desafíos a la hora de analizar las radiografías, los médicos pueden solicitar Resonancias Magnéticas, Tomografías Axiales Computarizadas entre otras. Si bien la solicitud de pruebas diagnósticas especializadas puede proveer más información al médico, suponen un tiempo de espera extra para el paciente, aún más en Colombia

donde se deben emprender engorrosos procesos de autorización con la empresa prestadora de servicios de salud. Por tal razón es pertinente sacarles el mayor provecho a las imágenes de rayos x especialmente porque en algunos lugares del país es costoso y complejo acceder a otro tipo de pruebas fundamentadas en imagen.

Por otro lado, año tras año la capacidad de procesamiento de los dispositivos de cómputo ha ido aumentando y junto con el fortalecimiento de técnicas como la computación distribuida (Bazán et al., 2017) se ha logrado entrenar modelos robustos de aprendizaje de máquina (Fernández, 2014) lo que ha renovado el interés por la Inteligencia Artificial, impulsando la evolución de diferentes áreas en las que se requiere realizar trabajos repetitivos con cierta experticia, sin perder eficacia con el paso del tiempo, como lo puede ser la clasificación de imágenes. Además de ello, apoyados en el crecimiento de los servicios de computación en la nube (Sharma et al., 2016) especialmente en aquellos que ofrecen una capa gratuita de funcionalidades, se abre la posibilidad de llevar este conocimiento a la práctica por parte de cualquier persona con conocimientos afines y acceso a internet. (Lombana, 2018)

Según (Dong, Pan, Zhang & Xu, 2017) cuando se habla de sistemas computarizados para apoyar diagnósticos se evidencia que la gran mayoría de ellos dependen de Tomografías computarizadas o resonancias magnéticas, las cuales son generadas en alta resolución, lo que reduce la cantidad de datos con el cual puede ser alimentado dicho sistema. Para el caso de las radiografías de tórax es evidente que los hospitales generan gran cantidad de estas imágenes lo cual supone un beneficio a la hora de buscar generar soluciones apoyadas en inteligencia artificial.

Para entrenar un sistema que haga uso del aprendizaje de máquina (machine learning) para tareas de clasificación de imágenes, se requiere un conjunto de imágenes etiquetadas, en este caso se requiere un conjunto de radiografías cada una con su respectivo diagnóstico, el cual debe estar estandarizado, para ello se utiliza en el conjunto de datos llamado ChestX-ray14 el cual hace uso de procesamiento natural de lenguaje entre otras técnicas para clasificar los diagnósticos de cada imagen. (Wang et al., 2017)

Luego de tener el conjunto de datos, necesitamos encontrar un modelo que pueda ser entrenado para tareas de clasificación de imágenes, dentro de los más eficientes para que un sistema artificial pueda aprender a reconocer patrones en imágenes se encuentran las regresiones logísticas, las máquinas de soporte de vectores (SVM) hasta las tan conocidas redes neuronales, en las que destacan las redes neuronales convolucionales (CNN) (Krizhevsky, 2017) las cuales por ejemplo en un estudio reciente (Rajpurkar et al., 2018) llegar a ser tan buenas como por ejemplo un radiólogo practicante.

Para hacer uso de las CNN se opta por el apoyo en una de las APIs de alto nivel más sencilla de consumir llamada Keras, escrita en Python, la cual permite hacer uso de librerías de computación numérica como Tensor Flow sin requerir conocimientos profundos sobre el tema y además permite hacer uso de arquitecturas de redes neuronales convolucionales documentadas científicamente.

Como proveedor de servicios de cloud computing se usa a Kaggle el cual ofrece un servicio gratuito orientado a este tipo de soluciones el cual ofrece procesamiento apoyado por GPU.

El propósito de este estudio es comparar el desempeño de las arquitecturas de red neuronal convolucional disponibles en Keras a la hora de clasificar imágenes de rayos X etiquetadas con una o más de las catorce (14) patologías presentes en el conjunto de datos de ChestX-ray14 (Wang et al., 2017) y a su vez que puedan ser ejecutadas con los recursos provistos en la plataforma de Kaggle de forma gratuita.

## **Justificación**

Este proyecto de grado se propone seleccionar el mejor modelo de red neuronal convolucional a la hora de clasificar radiografías de tórax dentro de 14 diferentes enfermedades, las cuales pueden aparecer de manera individual o presentarse varias de ellas en una misma imagen.

Se hace uso del Dataset ChestX-ray14 (Wang et al., 2017) propuesto como una segunda versión al conjunto de datos ChestX-ray8, debido a que es uno de los más completos hasta la fecha, el cual cuenta con un porcentaje de error muy bajo, en lo que se refiere al etiquetado de las imágenes, también porque es posible encontrarlo de manera gratuita y abierta. Como Framework de Machine Learning (API) se hace uso de Keras el cual es un proyecto de código abierto escrito en Python, que permite hacer uso de librerías de computación numérica sin requerir conocimientos profundos sobre el tema y además permite hacer uso de arquitecturas de redes neuronales convolucionales documentadas científicamente, finalmente como proveedor de servicios de cloud computing se utiliza a Kaggle el cual ofrece un servicio gratuito orientado a este tipo de soluciones el cual corre sobre Google Cloud con procesamiento apoyado por GPU.

Todo el stack antes mencionado permite generar la comparación de cada una de las arquitecturas sin poseer conocimientos profundos en clasificación de imágenes y además dar solución al problema de clasificación de radiografías sin tener conocimientos médicos, lo cual permite demostrar la facilidad de acceso que existe actualmente a este tipo de conocimiento así como la posibilidad de generar soluciones de manera gratuita, en la que solo se requiere un equipo con conexión a internet, lo cual puede beneficiar a todas

las personas interesadas en este campo que deseen hacer una primera aproximación a estos temas y no deseen invertir dinero o que directamente no cuenten con los recursos para costear un dispositivo a la altura de las exigencias de este tipo de soluciones.

Por otro lado, al estar escrito en Python puede ser la base para generar un servicio web que sea usado como un apoyo a la hora de determinar un diagnóstico por profesionales de la salud que deseen invertir menor esfuerzo y aprovechar mejor su tiempo.

## **Objetivos**

### **Objetivo General**

Realizar una evaluación la cual permita determinar el modelo más óptimo que permita predecir si el paciente padece de cierta enfermedad a partir de rayos x.

### **Objetivos Específicos**

- Realizar un adecuado proceso de integridad de datos para obtener resultados lo más cercanos a la realidad posible.
- Configurar el modelo con mejor rendimiento a través de hiper parámetros para que genere un mejor desempeño.

## Metodología y Conjunto de Datos

### Descripción de los datos

El conjunto de datos (Wang et al., 2017) ChestX-ray14 es un conjunto de 112.120 imágenes de radiografías de Tórax, propuesta como una versión posterior al conjunto de datos ChestX-ray8 que originalmente tenía ocho clases distintas de enfermedades, con un total de 108.948 imágenes de 32.717 pacientes únicos, este es el conjunto de datos escogido para el proyecto, las razones de su elección se describen en el Marco Metodológico.

El conjunto de datos ChestX-ray14 incluye seis etiquetas más que su predecesor para un total de catorce clases de enfermedades las cuales pueden aparecer de forma simultánea en una misma radiografía.

El conjunto de datos fue extraído de la base de datos clínica PACS, en donde se tomaron en cuenta radiografías entre los años 1992 a 2015. El etiquetado de esta data se realizó haciendo uso de procesamiento natural de lenguaje (NLP) en donde se espera que la precisión de dicho etiquetado sea superior al 90%.

Este conjunto de datos con un peso de 42 GB contiene:

- 112.120 imágenes de radiografías de tórax de 30.805 pacientes únicos, con una resolución de 1024 X 1024px las cuales se encuentran en escala de grises.
- README\_ChestXray.pdf el cual es un documento orientador de la estructura del conjunto de datos.
- BBox\_list\_2017.csv en donde se encuentra la ubicación en coordenadas de las distintas enfermedades presentes en aproximadamente 1000 imágenes, las

columnas que posee son: (a) Image Index: El nombre del archivo png (la radiografía); (b) Finding Label: La enfermedad presente en la imagen y (c) Bbox [x, y, w, h]. [x y] son coordenadas de la esquina superior izquierda y [w h] representa el ancho y la altura de cada cuadro.

- Data\_entry\_2017.csv en el cual se encuentran relacionadas cada imagen con su correspondiente información, las columnas que posee son: (a) Image Index: El nombre del archivo png (la radiografía); (b) Finding Labels: Las enfermedades presentes en la imagen, separadas por un “|”, las cuales son: Atelectasia (Atelectasis), Consolidación (Consolidation), Infiltración (Infiltration), Neumotórax (Pneumothorax), Edema, Enfisema (Emphysema), Fibrosis, Efusión (Effusion), Neumonía (Pneumonia), Engrosamiento pleural (Pleural\_thickening), Cardiomegalia (Cardiomegaly), Nodulo (Nodule), Masa (Mass), Hernia y No Finding: Hace referencia a una radiografía de una persona sana; (c) Follow-up #: Identificador de seguimiento del paciente, este valor hace referencia a las múltiples imágenes que puede tener asociadas un mismo paciente; (d) Patient ID: Identificador único de paciente; (e) Patient Age: Edad del paciente; (f) Patient Gender: Género del paciente; (g) View Position: Posición de la radiografía (Anterior Posterior o Posterior Anterior); (h) OriginalImageWidth: Ancho original de la imagen; (j) OriginalImageHeight: Alto original de la imagen; (k) OriginalImagePixelSpacing\_x: Espacio original entre los píxeles del eje x; (l) OriginalImagePixelSpacing\_y: Espacio original entre los píxeles del eje y.

- Dos segmentaciones del conjunto de datos: test\_list.txt y train\_val\_list.txt en donde todos los estudios de un mismo paciente solamente aparecerán en una de las dos segmentaciones.
- ARXIV\_V5\_CHESTXRAY.pdf: El cual es el estudio original del cual se obtienen las imágenes.
- FAQ CHEST XRAY.pdf: en donde se muestran todas las preguntas frecuentes relacionadas con este conjunto de datos.
- LOG\_CHESTXRAY.pdf: Registro de versiones del conjunto de datos

Dentro de las limitaciones que los autores encuentran a la hora de crear el dataset destacan: (a) El conjunto de datos al tener etiquetas generadas a partir de procesamiento de lenguaje natural puede llegar a tener errores relacionados al 90% de precisión en el etiquetado; (b) Un número muy limitado de enfermedades con coordenadas y (c) Al ser un conjunto de datos público pueden generarse versiones en donde las enfermedades asociadas a cada enfermedad sean cambiadas manualmente, lo cual puede llegar a empeorar la precisión del etiquetado.

Así mismo cabe destacar que el ChestX-ray14 puede poseer etiquetas generadas por diferentes especialistas las cuales no necesariamente han sido puestas a consenso, lo cual, en 2018, Paul et al. muestran que puede llevar a diagnósticos variados para una misma imagen entre radiólogos, especialmente cuando se trata de radiólogos con diferentes niveles de experiencia.

El conjunto de datos en mención fue publicado y actualizado el 21 de febrero de 2018 por el Instituto Nacional de Salud de Estados Unidos (NIH por sus siglas en inglés) sobre la plataforma de Kaggle (NIH, 2018).

### Metodología de trabajo

La metodología de trabajo en la cual se apoya el presente proyecto es llamada Metodología Fundamental para la Ciencia de Datos, la cual es propuesta por IBM. Esta metodología (Rollins, 2015) posee diez etapas con las que busca proporcionar una base estratégica para los científicos de datos, sin importar la tecnología, volúmenes de datos o enfoques con los que trabajen.

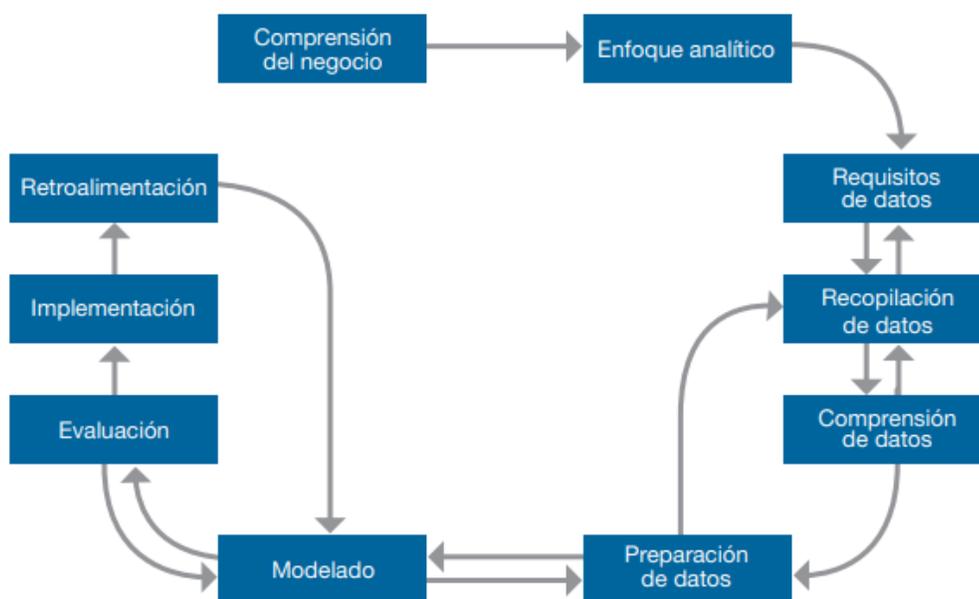


Figura 1. Metodología Fundamental para la Ciencia de Datos

A continuación, se explican brevemente cada una de estas etapas:

Etapa 1: Comprensión del negocio. En esta etapa se define el problema, los objetivos del proyecto y los requisitos de la solución.

Etapa 2: Enfoque analítico. En esta etapa se expresa el problema de una forma más técnica, para este caso en el contexto del aprendizaje de máquina.

Etapa 3: Requisitos de datos. En esta etapa según el enfoque analítico se determinan los requisitos de datos, un ejemplo de ello puede ser, si se tiene un enfoque analítico la intención de clasificar imágenes, los requisitos de datos son como mínimo obtener para cada imagen a clasificar su respectiva etiqueta.

Etapa 4: Recopilación de datos. En esta etapa se identifican y se reúnen los recursos de datos disponibles que sean relevantes para el dominio del problema basados en los requisitos de datos.

Etapa 5: Compresión de datos. En esta etapa los científicos de datos hacen uso de estadística descriptiva y técnicas de visualización para conocer mejor los datos, los resultados de esta etapa pueden hacer que el proceso vuelva a la etapa anterior para obtener mejores datos.

Etapa 6: Preparación de datos. En esta etapa se prepara el conjunto de datos que será usado en la etapa de modelado, se pueden encontrar actividades como:

- Limpieza de datos
- Combinar datos de múltiples fuentes
- Transformar los datos en variables más útiles

Etapa 7: Modelado. En esta etapa se utiliza la primera versión del conjunto de datos (luego de la fase de preparación de datos) y se enfoca en desarrollar modelos predictivos

o descriptivos según el enfoque analítico. Durante este proceso, los científicos de datos pueden obtener resultados intermedios los cuales pueden conducir a realizar ajustes en la preparación de los datos y en la especificación del modelo. En este punto los científicos de datos pueden probar diferentes modelos (algoritmos) para encontrar el que mejor se ajuste a la solución del problema.

Etapa 8: Evaluación. En esta etapa los científicos de datos evalúan el modelo escogido en la etapa anterior, esta evaluación implica el cálculo de varias medidas de diagnóstico, así como de gráficos para visualizar sus resultados y con base a ellos se interpreta el desempeño del modelo. Dependiendo de la significancia estadística de los resultados y de los riesgos que se estén contemplados como aceptables, los científicos de datos pueden decidir si el modelo actual merece ser llevado a la siguiente etapa o por el contrario es necesario regresar una o más etapas atrás.

Etapa 9: Implementación. En esta etapa se lleva el modelo satisfactorio a un entorno de producción en donde se implementa de forma y gradualmente se lleva completamente al usuario final.

Etapa 10: Retroalimentación. En esta etapa se usan los resultados generados por la implementación para ajustar el modelo mejorando así su precisión y utilidad.

## **Antecedentes**

El campo que se abarca en el proyecto ha sido objeto de varias investigaciones y se ha tratado de múltiples formas y enfoques dando como resultado diferentes formas de abarcar el mismo problema, de tal forma se exponen dichos a continuación.

### **CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning:**

Desarrollamos un algoritmo que puede detectar la neumonía de las radiografías de tórax a un nivel superior a los radiólogos practicantes. Nuestro algoritmo, CheXNet, es una red neuronal convolucional de 121 capas capacitada en ChestX-ray14, actualmente el mayor conjunto de datos de rayos X de tórax disponible públicamente, que contiene más de 100,000 imágenes de rayos X de vista frontal con 14 enfermedades. Cuatro radiólogos académicos en ejercicio anotan un conjunto de pruebas, en el que comparamos el rendimiento de CheXNet con el de los radiólogos. Encontramos que CheXNet excede el rendimiento promedio del radiólogo en la métrica F1. Extendemos CheXNet para detectar las 14 enfermedades en ChestX-ray14 y lograr resultados de vanguardia en las 14 enfermedades. (Rajpurkar et al., 2018)

### **ChestX-ray8: Hospital-scale Chest X-ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases:**

En este artículo, presentamos una nueva base de datos de rayos X de tórax, a saber, "ChestX-ray8", que comprende 108,948 imágenes de rayos X de vista frontal de 32,717 pacientes únicos con las etiquetas de imágenes de ocho

enfermedades extraídas de texto (donde cada imagen puede tener multi-etiquetas), de los informes radiológicos asociados utilizando el procesamiento del lenguaje natural. Es importante destacar que demostramos que estas enfermedades torácicas comunes se pueden detectar e incluso ubicar espacialmente a través de un marco de localización de enfermedades y clasificación de imágenes de etiquetas múltiples unificadas y débilmente supervisadas, que se valida utilizando nuestro conjunto de datos propuesto. Aunque los resultados cuantitativos iniciales son prometedores como se informó, la red neuronal convolucional profunda se basa en la "lectura de radiografías de tórax" (es decir, reconocer y localizar los patrones de enfermedades comunes entrenados con solo etiquetas de nivel de imagen) sigue siendo una tarea extenuante para los sistemas CAD de alta precisión totalmente automatizados. (Wang et al., 2017)

### **Weakly Supervised Medical Diagnosis and Localization from Multiple ResolutionshestX-ray8:**

El diagnóstico por imágenes a menudo requiere la identificación simultánea de una multitud de hallazgos de tamaño y apariencia variados. Más allá de la indicación global de dichos hallazgos, la predicción y visualización de información de localización mejora la confianza y la comprensión de los resultados al aumentar el flujo de trabajo clínico. Los datos de capacitación médica rara vez incluyen más que etiquetas de nivel de imagen global, ya que las segmentaciones requieren mucho tiempo y son costosas de recopilar. Introducimos un enfoque para gestionar estas limitaciones prácticas mediante la

aplicación de una arquitectura novedosa que aprende a múltiples resoluciones mientras genera mapas destacados con una supervisión débil. Promover, adicional, parametrizamos la función de agrupación Log-Sum-Exp con una adaptación de límite inferior que se puede aprender (LSE-LBA) para generar una nitidez previa y manejar mejor las anomalías de localización de diferentes tamaños usando solo etiquetas de nivel de imagen. Aplicando este enfoque para interpretar las radiografías de tórax, establecemos el estado del arte en 9 anomalías en el conjunto de datos CXR14 del NIH mientras generamos mapas de saliencia con la resolución más alta hasta la fecha. (Yao et al., 2018)

### **Comparison of Deep Learning Approaches for Multi-Label Chest X-Ray**

#### **Classification:**

La mayor disponibilidad de archivos de imágenes de rayos X (por ejemplo, el conjunto de datos ChestX-ray14 del Centro Clínico NIH) ha provocado un creciente interés en las técnicas de aprendizaje profundo. Para proporcionar una mejor comprensión de los diferentes enfoques y sus aplicaciones para la clasificación de rayos X de tórax, investigamos en detalle una potente arquitectura de red: la ResNet-50. Partiendo del trabajo previo en este dominio, consideramos el aprendizaje de transferencia con y sin ajustes, así como la capacitación de una red de rayos X dedicada desde cero. Para aprovechar la alta resolución espacial de los datos de rayos X, también incluimos una arquitectura ResNet-50 extendida y una red que integra datos sin imágenes (edad del paciente, género y tipo de adquisición) en el proceso de clasificación. En un experimento final, también

investigamos múltiples profundidades de ResNet (es decir, ResNet-38 y ResNet-101). En una evaluación sistemática, usando un muestreo múltiple de 5 veces y una función de pérdida de múltiples etiquetas, comparamos el rendimiento de los diferentes enfoques para la clasificación de patología por las estadísticas ROC y analizamos las diferencias entre los clasificadores usando la correlación de rango. (Ivo Baltruschat, 2018)

### **Breast Cancer Histopathological Image Classification: A Deep Learning**

#### **Approach:**

El cáncer de mama sigue siendo el tipo más común de cáncer y la principal causa de mortalidad inducida por cáncer entre las mujeres con 2,4 millones de casos nuevos diagnosticados y 523,000 muertes por año. Históricamente, un diagnóstico se ha realizado inicialmente mediante cribado clínico seguido de análisis histopatológico. La clasificación automatizada de los cánceres mediante imágenes histopatológicas es una tarea difícil de detección precisa de subtipos de tumores. Este proceso podría facilitarse mediante enfoques de aprendizaje automático, que pueden ser más confiables y económicos en comparación con los métodos convencionales. Para probar este principio, aplicamos redes neuronales profundas pre-entrenadas ajustadas y primero intentamos discriminar entre diferentes tipos de cáncer. Utilizando 6.402 muestras de microarrays de tejido (TMA), los modelos que incluyen el modelo preentrenado ResNetV1-50 predijeron correctamente 99%. (Jannesari et al., 2018)

## **Marco Teórico**

En este apartado, se profundiza en algunas bases teóricas sobre las cuales se basa el presente proyecto, las cuales intervienen en distintas etapas de la metodología escogida.

### **Inteligencia Artificial y tipos de aprendizaje**

Uno de los conceptos predominantes a la hora de buscar darle un mayor valor a la información es el de Inteligencia Artificial. En 2010, Russell, Norvig y Davis establecen que, la inteligencia artificial se enfoca en transformar a un sistema computacional o artificial en un agente racional, el cual pueda actuar para lograr el mejor resultado o, cuando hay incertidumbre, el mejor resultado posible, los cuales pueden desempeñarse en algunas tareas de forma similar o superior al ser humano.

La toma de decisiones con base a la experiencia o la búsqueda de patrones son rasgos característicos de los humanos, los agentes racionales se apoyan en campos de estudio como la lógica, las matemáticas y la estadística para poder inferir y tomar decisiones. Las personas y los agentes racionales hacen uso de datos para aprender, los seres humanos requieren de sus sentidos para obtener los datos, los agentes racionales se valen de la lectura de archivos (internos o en red) de los cuales obtienen toda su experiencia. Sin embargo, los seres humanos no cuentan con la capacidad de recordar o de procesar información a gran escala como sí lo pueden hacer los sistemas artificiales, lo cual supone una ventaja para estos últimos.

La forma en la que un sistema artificial aprende es conocido como Aprendizaje de Máquina (Machine Learning) del que se pueden distinguir tres tipos: el aprendizaje reforzado, el aprendizaje sin supervisión y el aprendizaje supervisado.

En el aprendizaje reforzado se le entrega una retroalimentación al agente, de tal forma que aprenda sin usar un conjunto de datos, sino que lo haga mediante prueba y error. Uno de los ejemplos más destacados en este tipo de aprendizaje es el de los automóviles autónomos. Para el aprendizaje sin supervisión no se requiere tener el conjunto de datos etiquetado, este tipo de aprendizaje es generalmente usado cuando se tiene una gran cantidad de datos y se desea que el agente logre agruparlos sin conocer inicialmente un patrón evidente. Un ejemplo de este tipo de aprendizaje puede ser la clasificación de publicaciones en redes sociales. Finalmente para el aprendizaje supervisado el agente consume un conjunto de datos etiquetados, en donde las etiquetas pueden tener valores continuos o discretos; si los valores son continuos se habla de un problema de predicción, por ejemplo, al buscar establecer el costo de un auto, usando un conjunto de datos con las características de muchos autos junto con su precio, el cual es un valor continuo; si los valores son discretos se está frente a un problema de clasificación, por ejemplo, si se busca establecer la emoción de un rostro humano, usando un conjunto de imágenes de rostros, los cuales deben estar clasificados en una cantidad finita de emociones (Hurwitz & Kirsch, 2018).

Ahora bien, el enfoque analítico del presente problema es un enfoque orientado a lograr que un agente racional logre clasificar imágenes, este caso radiografías dentro de

14 tipos de enfermedades, por tal se está frente a un problema de clasificación el cual se abordará a través del aprendizaje supervisado.

La recopilación de los datos estará enfocada en conseguir un conjunto de datos conformado por parejas integradas por la radiografía y sus enfermedades (etiquetas).

### **Python**

Desde la Etapa 5 de nuestra metodología hasta la número 8, vamos a hacer uso del lenguaje de programación llamado Python en su versión 3. Python es un lenguaje de programación de alto nivel multiparadigma enfocado en la legibilidad del código (Kuhlman, 2011).

Es nuestra elección debido a su fácil sintaxis y a que actualmente posee muchas de las librerías de ciencia de datos e inteligencia artificial en su versión más actualizada.

### **Computación Distribuida**

Los algoritmos de inteligencia artificial requieren de un gran poder de procesamiento computacional, por tal razón es necesario hablar de conceptos que ayuden a aprovechar mejor los recursos computacionales que se poseen en la actualidad como la computación distribuida.

La computación distribuida es una forma de compartir recursos de equipos, conectándolos en una misma red, con un software diseñado para tal fin, los cuales trabajarán de forma sincronizada y coordinada simulando ser un sistema único (Bazán et al., 2017).

## **Kaggle**

Kaggle es una plataforma gratuita propiedad de Google en la cual científicos de datos y personas enfocadas en machine learning pueden encontrar y publicar conjuntos de datos, construir modelos y participar en concursos relacionados a las ciencias de datos en un entorno basado en web (Wikipedia, 2019).

Así mismo esta plataforma permite trabajar Notebooks con dos lenguajes de programación: R y Python, estos notebooks tienen su origen en la librería Jupyter (Jupyter Team, s.f.) la cual genera un conjunto de celdas en las que se puede ejecutar código de manera secuencial (Kaggle, 2019).

Trabaja apoyada en computación distribuida, sobre la cual característica más destacada es que ofrece memorias GPU.

## **Test de Kruskal-Wallis**

Es una prueba estadística, no paramétrica la cual prueba la hipótesis nula de que la mediana de la población de todos los grupos es igual. La prueba funciona en 2 o más muestras independientes, que pueden tener diferentes tamaños. (Kruskal & Wallis, 1952)

## **One Hot Encoding**

Debido a que se desean clasificar radiografías según las enfermedades que contengan, las cuales pueden ser más de una, se requiere efectuar un proceso para que la red neuronal solamente reciba un único parámetro de etiqueta.

Inicialmente, por ejemplo, se tiene una imagen  $x$  la cual tiene asociadas las enfermedades:  $a$  y  $b$  las cuales hacen parte del conjunto total de enfermedades:  $a, b, c, d$  y  $e$ . Estas enfermedades al no guardar ninguna relación ordinal se sigue un proceso

denominado Hot Encoding, el cual va a generar un vector de la misma longitud que el total de etiquetas posibles.

Para este ejemplo la cantidad de etiquetas posibles es 5, lo cual significa que luego de llevar a cabo el proceso de One Hot Encoding se obtiene para cada imagen  $x$  un vector de longitud 5, en donde ordenadamente se dispone un uno “1” si la imagen posee la enfermedad y un cero “0” si no la posee, obteniendo finalmente que para la imagen  $x$  antes mencionada un valor  $y$  asociado igual a un vector: [1, 1, 0, 0] correspondiente a un vector ordenado de enfermedades [a, b, c, d] (Cerdeira, Varoquaux & Kégl, 2018).

### **Arquitectura de una red neuronal**

En 2010, Russell, Norvig y Davis definen los principios básicos de una red neuronal como:

Uno de los algoritmos más usados en machine learning son las redes neuronales, las cuales se componen de nodos o unidades conectadas por enlaces directos. Estas unidades en su forma más básica reciben una función  $in_j$  la cual es una sumatoria ponderada de los enlaces que tiene como entrada. Esta función es pasada como parámetro a otra función llamada función de activación  $g$  y este resultado es la salida  $a_j$  de esta neurona.

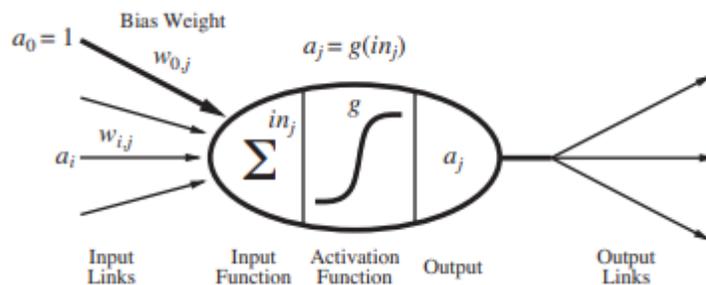


Figura 2. Modelo Matemático Básico Para Una neurona

Un enlace de la unidad  $i$  a la unidad  $j$  sirve para propagar la activación  $a_i$  de  $i$  a  $j$ . Cada enlace también tiene una ponderación numérica  $w_{ij}$  asociada (peso), la cual determina la fuerza y el signo de la conexión.

Se puede interpretar que cada peso,  $w_{ij}$ , representa la influencia relativa de la entrada por la cual se multiplica,  $x_i$ . A menudo al término  $b$  le llama sesgo (en inglés bias), ya que controla qué tan dispuesta está la neurona a disparar un 1 o un 0 independiente de los pesos. Un sesgo alto hace que la neurona requiera una entrada más alta para generar una salida de 1. Un sesgo bajo lo hace más fácil.

El objetivo de entrenar un algoritmo de machine learning es determinar el peso o ponderación numérica ideal para cada atributo. Si un peso es 0, su atributo correspondiente no contribuye al modelo.

Así mismo definen que una de las formas fundamentales de conectar estas unidades de procesamiento es llamada red de retroalimentación (feed-forward) en donde las conexiones existen en una sola dirección; cada nodo al interior de la red neuronal recibe una entrada del nodo inmediatamente anterior y genera una salida que alimenta al nodo inmediatamente posterior. Una red de retroalimentación está usualmente organizada en capas, la primera capa es llamada capa de entrada, la última capa es llamada capa de

salida y las capas intermedias son llamadas capas ocultas, las cuales pueden ser una o más. El proceso de aprendizaje en este tipo de redes se da bajo el concepto de retropropagación (backpropagation) el cual busca minimizar el error ajustando los pesos desde las neuronas de salida hacia atrás.

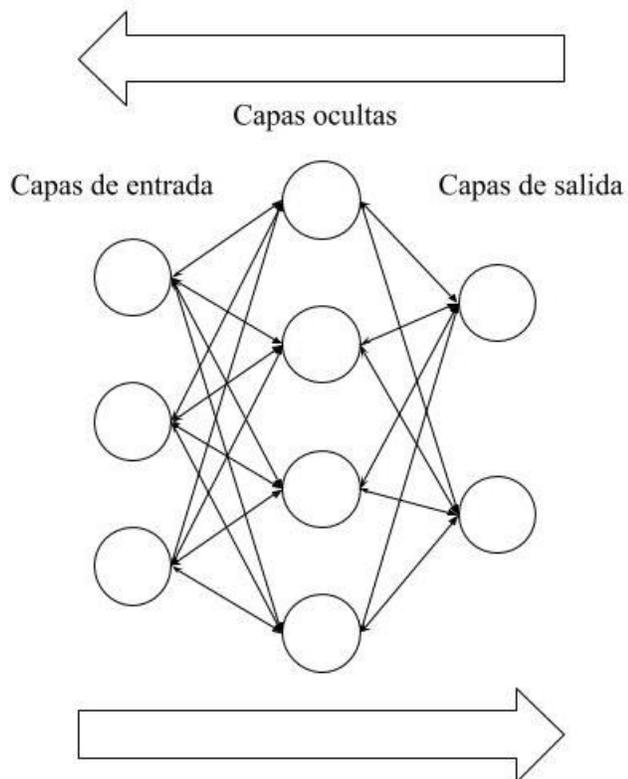


Figura 3. Flujo básico de una red neuronal.

Por ejemplo, para problemas de clasificación de imágenes bajo aprendizaje supervisado usando una red neuronal, se tendría, en su fase de entrenamiento:

- En la capa de entrada: imágenes de entrada con sus respectivas etiquetas.
- En las capas ocultas: una cantidad de nodos y de conexiones variable dependiendo de la arquitectura usada
- En la capa de salida: tantos nodos como etiquetas existan en el conjunto de datos.

Una red neuronal de retroalimentación con múltiples capas ocultas es usualmente conocida como red neuronal profunda (Deep Neural Network). Una red neuronal convolucional (CNN) es una clase de red neuronal de retroalimentación (Liu, Fang, Zhao, Wang & Zhang, 2015). La idea básica de las CNN, por ejemplo, en el proceso de reconocimiento de imágenes es que a partir de una imagen de entrenamiento, las primeras capas ocultas van filtrar patrones básicos como contornos (líneas o bordes) y a medida que esta información va pasando a través de las demás capas ocultas se podrán filtrar patrones con detalles más complejos (Alves, 2018).

Cabe destacar que cuando se dice que la CNN recibe una “imagen” de entrenamiento se hace referencia a una matriz la cual posee tantas dimensiones como canales de color y píxeles posea la imagen, para el caso de una imagen RGB de 224 píxeles de alto por 224 píxeles de ancho, se tendrá una matriz la cual se puede representar:  $m = [[224 \times 224], [224 \times 224], [224 \times 224]]$  en la cual están contenidos los valores numéricos de los píxeles, donde  $m[0]$  contiene los valores de los píxeles equivalentes al canal rojo (Red),  $m[1]$  contiene los valores de los píxeles equivalentes al canal verde (Green) y  $m[2]$  contiene los valores de los píxeles equivalentes al canal azul (Blue).

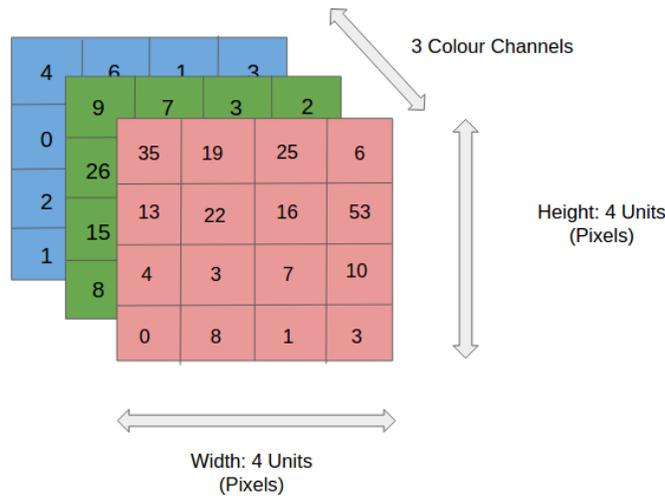


Figura 4. Imagen RGB 4x4x3.

Las características básicas de una CNN son:

Capas Convolucionales. Las capas convolucionales se encargan de aprender características de la entrada, la capa convolucional está compuesta de varios núcleos de convolución los cuales son usados para computar diferentes características de los datos de entrada (Gu et al., 2017),

las convoluciones funcionan como filtros que ven pequeños cuadrados y se "deslizan" por toda la imagen capturando las características más llamativas. Para decirlo mejor, con una imagen de  $32 \times 32 \times 3$  y un filtro que cubre un área de  $5 \times 5$  de la imagen de movimiento de 2 saltos (llamada zancada), el filtro pasará por toda la imagen a través de cada canal, formando un mapa de características o activación. Mapa  $28 \times 28 \times 1$ . (Alves, 2018)

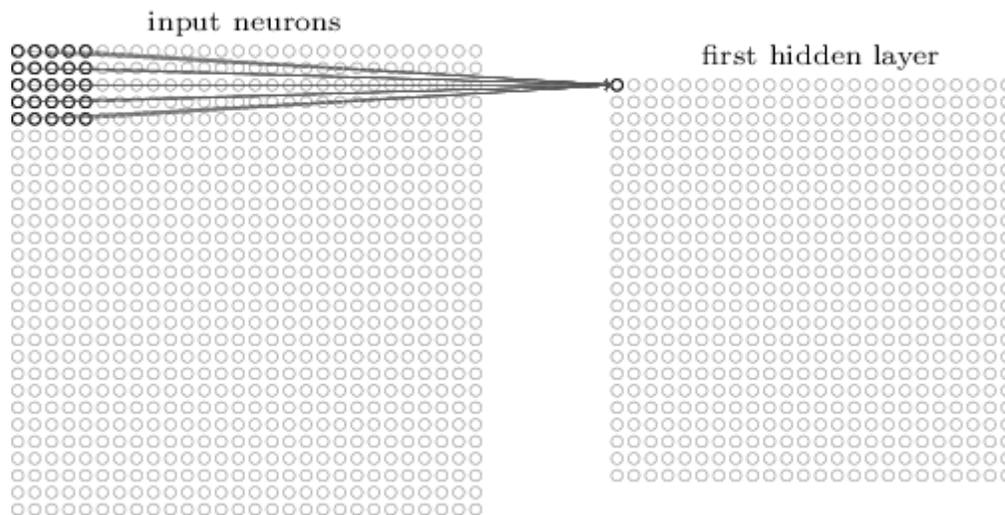


Figura 5. Entrada de dimensión 28x28 con campo receptivo de área 5x5.

El filtro, que también se conoce como kernel, está compuesto por pesos inicializados aleatoriamente, actualizándolos con cada nueva entrada durante el proceso de retropropagación. La pequeña región de la entrada donde se aplica el filtro se llama campo receptivo. (Alves, 2018)

Capas de Agrupación. Las capas de agrupación (pooling) se enfocan en reducir la resolución de los mapas de características (producto de las capas convolucionales) y las capas completamente conectadas (fully-connected) las cuales realizan un razonamiento de alto nivel (Gu et al., 2017). De la misma forma que en las capas convolucionales, se elige una unidad de área, por ejemplo, 2x2, para transitar la salida completa de la capa anterior. La unidad es responsable de resumir la información en esa área en un solo valor. Si la salida de capa anterior es 24x24, la salida de agrupación es 12x12. Además, debe elegir cómo se realizará el resumen. El método más utilizado es maxpooling, donde solo se pasa el número de unidad más grande a la salida. Este resumen de datos sirve para

disminuir la cantidad de peso que se debe aprender y también para evitar el sobreajuste.

(Alves, 2018)

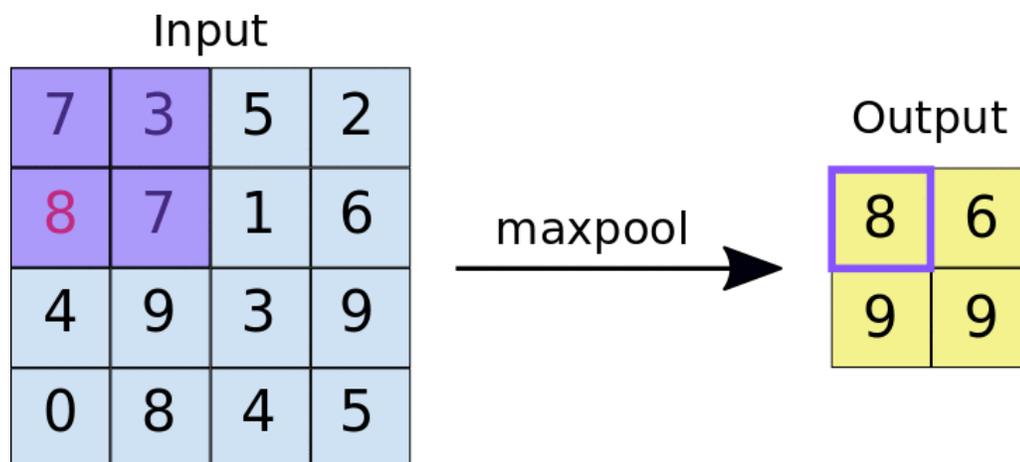
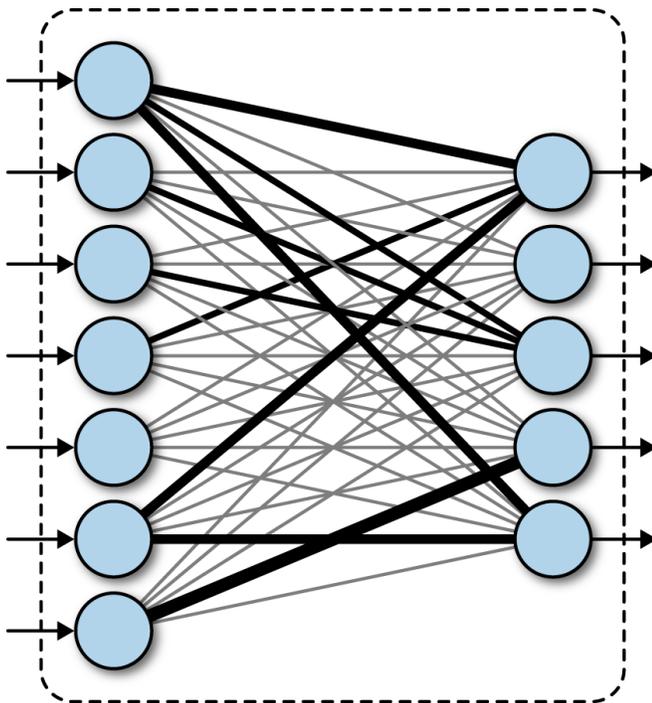


Figura 6. Maxpooling con área 2x2.

Capas Completamente Conectadas. Al final de la estructura de estas redes, es posible encontrar una o varias capas de neuronas completamente conectadas, donde su entrada es la salida de la capa anterior y su salida es el número de clases que se requieren clasificar.



*Figura 7.* Una capa totalmente conectada en una red profunda.

CNN es un algoritmo de reconocimiento eficiente que se usa ampliamente en el reconocimiento de patrones y el procesamiento de imágenes. Tiene muchas características como una simple estructura, menos parámetros de entrenamiento y adaptabilidad. Se ha convertido en un tema importante en el análisis de voz y el reconocimiento de imágenes. Su estructura de red compartida de peso la hace más similar a las redes neuronales biológicas, además reduce la complejidad del modelo de red y la cantidad de pesos (Liu, Fang, Zhao, Wang & Zhang, 2015).

Para este proyecto se busca comparar diferentes arquitecturas de red neuronal convolucional en la tarea de clasificar imágenes de radiografías de rayos X etiquetadas con 14 enfermedades, de tal forma que puede ser catalogado como un problema que será abordado usando el aprendizaje supervisado en donde el conjunto de datos serán las imágenes con su respectiva enfermedad.

### **Hiperparámetros**

Los Hiperparámetros son todos los valores que se pueden manipular de un determinado modelo con la intención de hacerlo más preciso o que se adapte de mejor forma a de los datos. Los hiperparámetros considerados en este estudio son:

Random state. Es la semilla utilizada por el generador de números aleatorios (Scikit-learn, s.f.)

Optimizador. Es una variación del algoritmo de descenso de gradiente (Google Developers, s.f.), es posible que diferentes optimizadores aprovechen uno o más de los siguientes conceptos para mejorar la efectividad del descenso de gradientes en un

conjunto de entrenamiento: (a) Momento; (b) Frecuencia de actualización y (c)

Dispersión/regularización.

Taza de aprendizaje. Escalar que se usa para entrenar un modelo a través del descenso de gradientes durante cada iteración, el algoritmo de descenso de gradientes multiplica la tasa de aprendizaje por el gradiente. El producto resultante se denomina paso de gradiente. La tasa de aprendizaje es un hiperparámetro fundamental.

Épocas. Representa un entrenamiento completo por todo el conjunto de datos, de manera que todos los ejemplos se observan una vez.

Pasos por época. Es la cantidad de iteraciones que se darán en cada época, por lo que el cálculo se hace al dividir el conjunto de datos sobre el tamaño del lote.

Tamaño del lote. Es el escalar que identifica cada cuantos ejemplos se hará la actualización de los pesos en el modelo.

Pasos de validación. Es el escalar que identifica cada cuantos ejemplos se hará la actualización de pesos y reducir el coste computacional a trabajar con mini lotes.

Función de activación. Función que incorpora la suma ponderada de todas las entradas de la capa anterior y genera un valor de resultado (generalmente no lineal) que pasa a la siguiente capa.

Función de pérdida. Es aquella función del modelo que minimiza el error en el conjunto de entrenamiento.

## **Keras**

En la etapa de modelado hacemos uso del Framework Keras el cual provee una API para trabajar con redes neuronales de alto nivel. Keras funciona como una capa que

simplifica el uso de Frameworks (los cuales keras denomina Backends) como TensorFlow , CNTK o Theano, lo cual nos permite entre otras cosas tener la capacidad de experimentar configuraciones de una forma más rápida. Otra ventaja que tiene Keras es que permite trabajar tanto con CPU como con GPU.

Las Aplicaciones en Keras. Cuando en Keras se habla de Aplicaciones (applications) se hace referencia a estructuras de redes neuronales convolucionales preconstruidas, las cuales pueden ser usadas de forma libre. Estas aplicaciones están debidamente documentadas en estudios científicos.

En el presente proyecto se realiza la comparación de algunas de estos modelos debido a que al estar respaldados por la comunidad científica son buen punto de partida para el equipo de trabajo, debido a que no se poseen conocimientos profundos del tema.

Los modelos que se tendrán en cuenta son los modelos que reciban por defecto imágenes de 224px, debido a que es el tamaño de entrada más común en este grupo de modelos y se espera la comparación a realizar sea lo más nivelada posible.

En la siguiente tabla se encuentra el desempeño que tienen cada una de las aplicaciones a la hora de clasificar imágenes del conjunto de datos ImageNet (Stanford Vision Lab, s.f.).

*Tabla 1.* Desempeño de Aplicaciones Seleccionadas al Clasificar Imágenes de Imagenet.

<i>Modelo</i>	<i>Tamaño</i>	<i>Precisión en el Top-1</i>	<i>Precisión en el Top-5</i>	<i>Parámetros</i>	<i>Profundidad</i>
VGG16	528 MB	0.713	0.901	138,357,544	23
VGG19	549 MB	0.713	0.900	143,667,240	26
ResNet50	98 MB	0.749	0.921	25,636,712	-

ResNet101	171 MB	0.764	0.928	44,707,176	-
ResNet152	232 MB	0.766	0.931	60,419,944	-
ResNet50V2	98 MB	0.760	0.930	25,613,800	-
ResNet101V2	171 MB	0.772	0.938	44,675,560	-
ResNet152V2	232 MB	0.780	0.942	60,380,648	-
MobileNet	16 MB	0.704	0.895	4,253,864	88
MobileNetV2	14 MB	0.713	0.901	3,538,984	88
DenseNet121	33 MB	0.750	0.923	8,062,504	121
DenseNet169	57 MB	0.762	0.932	14,307,880	169
DenseNet201	80 MB	0.773	0.936	20,242,984	201
NASNetMobile	23 MB	0.744	0.919	5,326,716	-

---

La precisión top-1 y top-5 se refiere al rendimiento del modelo en el conjunto de datos de validación de ImageNet. En donde top-1 hace referencia a la precisión que tiene la red a la hora de acertar con su predicción, por otro lado, el top-5 hace referencia a la precisión que tiene la red de tener la etiqueta esperada dentro de las 5 primeras opciones de predicción. La profundidad se refiere a la profundidad topológica de la red. Esto incluye capas de activación, capas de normalización por lotes, etc.

Las características generales de las arquitecturas que se utilizan durante el proyecto que hacen parte del framework de Keras son:

**VGG.** Esta arquitectura muestra el efecto de la profundidad de la red sobre la precisión, hace uso de filtros de convolución muy pequeños (3x3), lo que demuestra que se puede lograr una mejora significativa en las configuraciones de la técnica anterior (Redes Neuronales Artificiales tradicionales). Estas redes poseen entre 16 o 109 capas de profundidad (Simonyan & Zisserman, 2014).

**ResNet.** En esta arquitectura se presenta un marco de aprendizaje residual para facilitar el aprendizaje de redes más profundas que sus predecesoras. Se exponen redes residuales con una profundidad de hasta 152 capas, 8 veces más profundas que las redes VGG pero que aún tienen una menor complejidad. (He, Zhang, Ren & Sun, 2015).

**MobileNet.** En esta arquitectura se presenta orientada a la creación de aplicaciones móviles. Se basa en una arquitectura optimizada que utiliza convoluciones separables en profundidad para construir redes neuronales profundas y livianas. Introducen hiper parámetros globales simples que intercambian eficientemente entre latencia y precisión.(Howard et al., 2017).

**DenseNet.** Los creadores de esta red sostienen que: las redes convolucionales pueden ser más profundas, más precisas y eficientes para entrenar si contienen conexiones más cortas entre capas cercanas a la entrada y aquellas cercanas a la salida. El modelo DenseNet conecta cada capa con todas las demás de forma anticipada, teniendo

como ventajas: que reducen el problema del gradiente de fuga, mejoran la propagación de características y reducir el número de parámetros dentro de la red (Huang et al., 2016).

***NASNetMobile***. Está red explora un método para aprender las directamente en el conjunto de datos de interés, en donde proponen buscar un bloque de construcción arquitectónico en un conjunto de datos pequeño y luego transferir el bloque a un conjunto de datos más grande. La contribución clave de este trabajo es el diseño de un nuevo espacio de búsqueda (el "espacio de búsqueda NASNet") que permite la transferibilidad (Zoph, Vasudevan, Shlens & Le, 2017).

### **Transfer Learning**

El aprendizaje de transferencia se utiliza para mejorar o reducir el tiempo de aprendizaje de un modelo de machine learning mediante la transferencia de información de un dominio relacionado. (Weiss, Khoshgoftaar & Wang, 2016).

Para el caso de este proyecto se hará uso del aprendizaje que ha logrado una determinada red neuronal luego de ser entrenada con el conjunto de datos de ImageNet (Stanford Vision Lab, s.f.) con la intención de transferir este conocimiento para identificar las etiquetas de enfermedad del conjunto de datos ChestX-ray14 (Wang et al., 2017).

La forma en la que se transfiere este aprendizaje es a través del uso de los pesos finales obtenidos en el entrenamiento con el conjunto de datos de ImageNet, los cuales se tomarán como pesos iniciales para el entrenamiento con el conjunto de datos ChestX-ray14 (Wang et al., 2017).

## Métricas

Dentro de las métricas que se utilizan en este proyecto se encuentran:

Coeficiente de Kappa. La cual hace referencia a una prueba estadística para establecer la confiabilidad entre evaluadores. La importancia de la confiabilidad del evaluador radica en el hecho de que representa la medida en que los datos recopilados en el estudio son representaciones correctas de las variables medidas (McHugh, 2012). Esta métrica se referencia en el presente trabajo con la intención de mostrar que la precisión de un diagnóstico puede verse afectado cuando se lleva a consenso, especialmente cuando existen profesionales con diferentes niveles de experiencia.

AUC-ROC. Es aquella que proporciona una medida agregada del rendimiento de todos los umbrales de clasificación, El AUC oscila en valor del 0 al 1. Un modelo cuyas predicciones son un 100% incorrectas tiene un AUC de 0.0; otro cuyas predicciones son un 100% correctas tiene un AUC de 1.0, lo que se entiende que entre más se acerca la gráfica a la coordenada (0,1) es mejor (Google, s.f.)

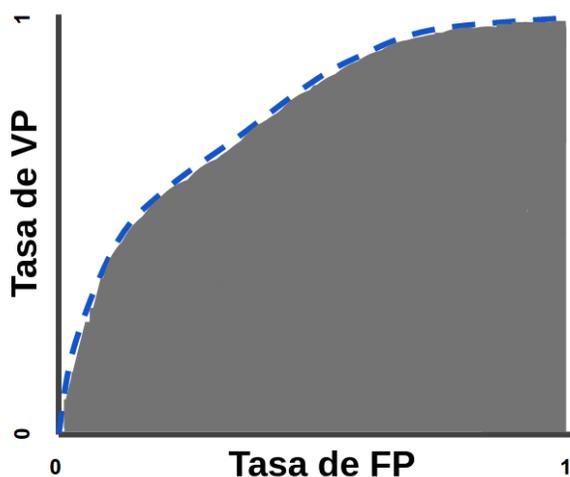


Figura 8. Gráfica de AUC-ROC.

Perdida (Loss). La medida de pérdida corresponde al resultado de la función de pérdida, en el que mientras más se aproxime a (0) cero significa que ha estado más cerca del resultado correcto en términos generales.

En la figura # se puede interpretar la distancia entre la predicción y el valor real(etiqueta) lo que da como resultado la pérdida (la ponderación de las líneas rojas) y la línea azul como el patrón de predicción, en consecuencia la gráfica de la izquierda está poco ajustada y cuenta con una pérdida alta comparada con la gráfica de la derecha.

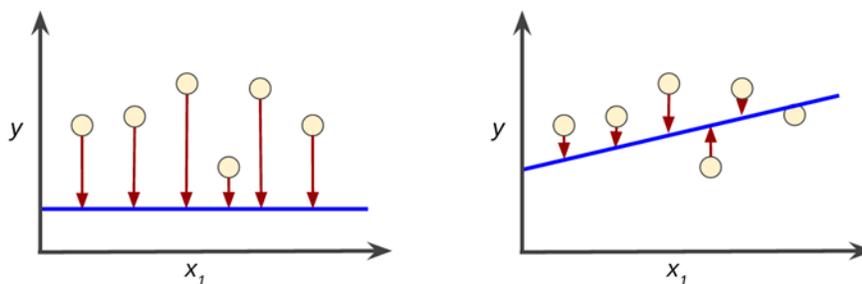


Figura 9. Representación de una pérdida alta y una baja.

Esta medida permite percatarse de problemas típicos dentro del campo de la inteligencia artificial como son el sobreajuste conocido en inglés como overfitting y el subajuste conocido en inglés como underfitting del modelo.

El overfitting es aquel problema en donde el modelo clasifica demasiado bien los ejemplos de entrenamiento, tanto así que aprende y memoriza ruido en dichos ejemplos, en consecuencia baja en gran medida el rendimiento de la red al ingresar nuevos ejemplos al modelo que por lo general no posean estos ruidos. Esto por lo regular ocurre cuando el modelo es muy complejo para los datos que procesa. Esto se puede mitigar al utilizar

estrategias de regularización como los son en las redes neuronales convolucionales las capas de dropout (Google Developers, s.f.).

La contraparte del problema anterior en los modelos es el underfitting en donde el modelo es tan sencillo que no clasifica de buena manera los ejemplos de entrenamiento, ni los nuevos datos que se ingresen en la red, por lo general también es significativa la cantidad de ejemplos que se tengan, ya que si se poseen pocos el modelo no representa de manera idónea la realidad.

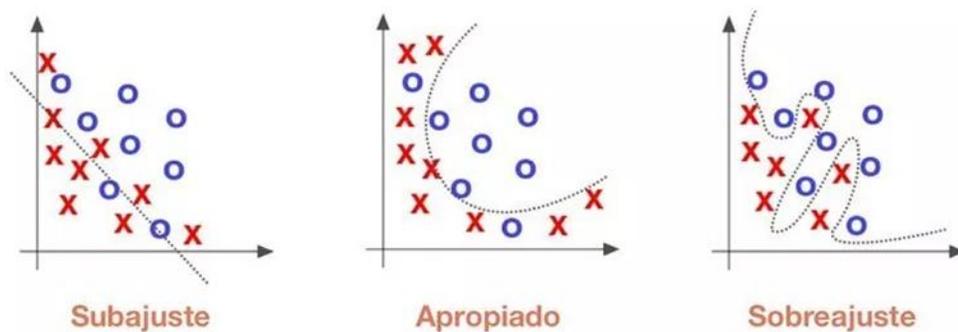


Figura 10. Representación de sobreajuste, subajuste y ajuste apropiado.

## Marco Metodológico

Aparte de la metodología de trabajo seleccionada para el desarrollo técnico de la presente tesis, se hizo uso de un tablero en Trello para llevar un Tablero Kanban, básico, el cual permitiera llevar un control de las tareas necesarias para la culminación del proyecto.

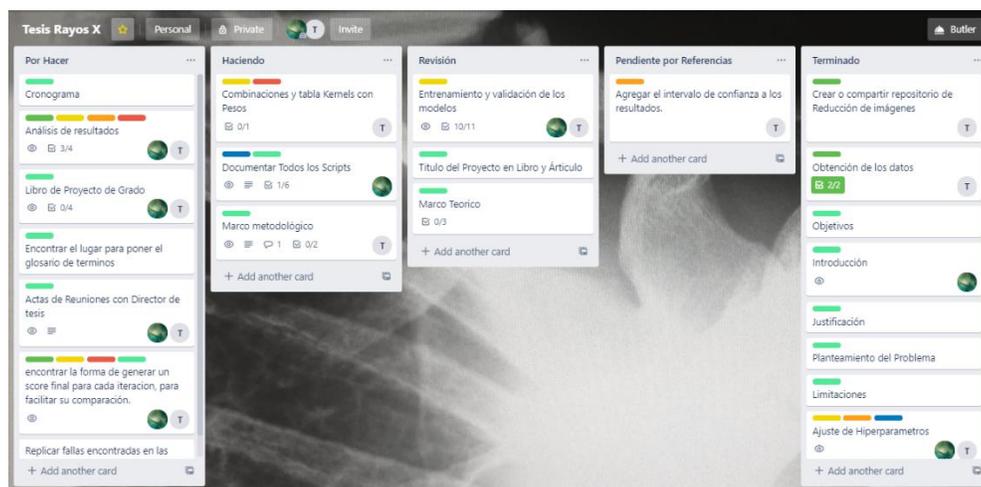


Figura 11. Gestión a través de Trello.

En base a la metodología que se ha implementado de IBM Metodología Fundamental para la Ciencia de Datos en este proyecto, se llevan a cabo las etapas allí propuestas en las que se entra a ahondar a continuación.

### **Etapas 1: Comprensión del negocio.**

El campo de la medicina es uno de los más beneficiados con el surgimiento del Machine Learning, con proyectos que buscan detectar diferentes padecimientos difíciles de diagnosticar o de manera temprana, con lo cual se busca mejorar la eficiencia y

precisión de los médicos a la hora de dictaminar si un paciente posee o no una enfermedad, en algunos casos actuar de manera proactiva frente a la posible aquerencia de la enfermedad y no de forma reactiva al ya poseerla.

El caso de estudio elegido en este proyecto busca diagnosticar las posibles enfermedades particulares que puedan presentar el sujeto a través del análisis de una radiografía de alta resolución del tórax, excluyendo la etapa y/o avance en el que se encuentra dichas enfermedades. Por lo que se hace vital encontrar dentro de la solución un sistema que apalanque con precisión los diagnósticos del especialista y que permita generar un diagnóstico con la mayor premura de manera fiable.

## **Etapa 2: Enfoque analítico.**

Desde la perspectiva analítica al tener un proyecto que intenta predecir si posee o no una enfermedad cierto paciente, se halla la necesidad de utilizar un método de clasificación el cual permita arrojar las probabilidades de poseer alguna enfermedad; Por otro lado al tener como entrada imágenes de alta resolución como características por las cuales se define si el paciente es afectado por la enfermedad, se encuentra que lo más conveniente es optar por un modelo de red neuronal que detecte objetos dentro de las imágenes, como lo son las redes neuronales convolucionales.

Como el actual proyecto procura que sea de fácil implementación con el fin de que un público con un conocimiento no tan avanzado dentro del campo pueda replicarlo, se escogen modelos pre-entrenados y redes neuronales sencillas hechas desde cero como posibles experimentos para dar solución a la problemática que se plantea.

### **Etapa 3: Requisitos de datos.**

Dado que los datos que se buscan son aquellos que representen poblaciones con ciertas afecciones y otros que no las poseen es necesario encontrar la debida muestra que sea significativa o la mayor cantidad de ejemplos que se pueda que representen la realidad, ya que entre más ejemplos se le proporcione a la red neuronal más fácil podrá extraer características en busca de los patrones que ayuden a dar la clasificación de manera correcta y que permiten representar de mejor manera estos eventos raros o inusuales que parten de los datos; Por otra parte para que estas características referentes a las afecciones sean reconocidas por la red neuronal es necesario que las imágenes se encuentren en un tamaño lo suficientemente grande para que sean aptas para trabajar.

### **Etapa 4: Recopilación de datos.**

Ante la recolección de datos es prudente buscar múltiples fuentes que permitan valorar la cantidad, calidad y variedad en los datos, aquellas que estén más completas sirven como mejores opciones, incluso en algunos casos se pueden optar por combinar diferente conjunto de datos, en este proyecto se contemplan los siguientes conjuntos de datos.

*Tabla 2.* Conjuntos de datos y sus características.

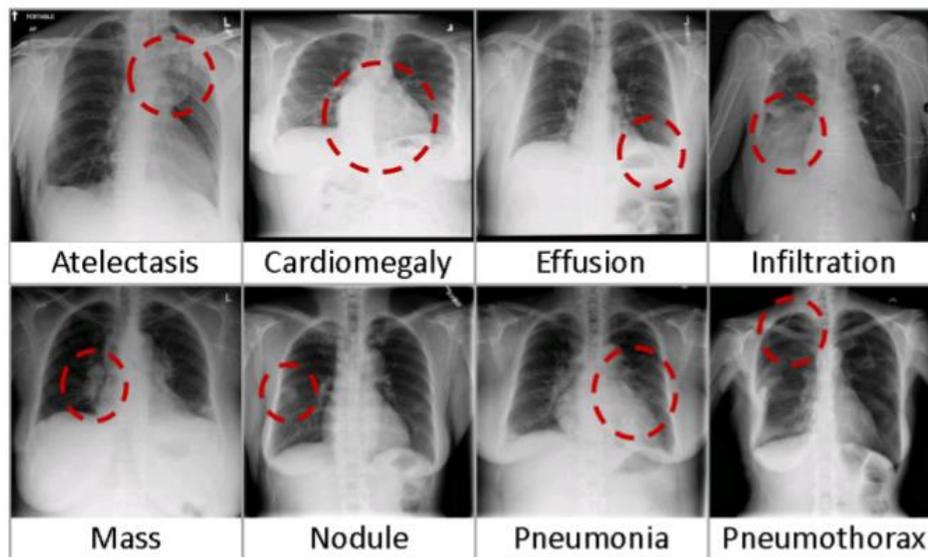
<b>Nombre</b>	<b>Número de ejemplos</b>	<b>Alto (Píxeles)</b>	<b>Ancho (Píxeles)</b>	<b>Pacientes</b>	<b>Etiquetas</b>
ChestX-ray14	112,120	1,024	1,024	30,805	14
CheXpert	224,316	320	320	65,240	14
MIMIC-CXR	371,920	509	509	224,548	14

El conjunto de datos MIMIC-CXR proporcionado por el MIT (Alistair et al., 2019) cuenta con radiografías en posición frontal y lateral, también posee algunas imágenes mal orientadas lo que vuelve engorroso el tratamiento de las imágenes para establecerlas en su orientación correcta de forma manual.

CheXpert publicado por Stanford ML Group (Jeremy et al., 2019) toma como ejemplos imágenes de radiografías en posiciones frontales y laterales lo que no permite tener un estándar sencillo y controlado de las imágenes al poseer diversas posiciones.

ChestX-ray14 difundido por National Institutes of Health (Wang et al., 2017) posee radiografías en posición frontal únicamente lo que permite tener un mayor control frente a la entrada del modelo desde el primer instante, también cuenta con las imágenes de mayor resolución comparadas con los otros conjuntos de datos lo que a grandes rasgos permite que la red neuronal encuentre más características útiles para predecir correctamente, por estas razones es elegido este conjunto de datos para el proyecto.

Este último conjunto de datos contiene diversos archivos que explican a fondo de que se compone. En su documento guía se explica que se etiqueta por medio NPL con una precisión de alrededor del (90%) noventa por ciento, también cuenta con datos de las regiones donde se encuentran las enfermedades de algunas imágenes (Wang et al., 2017). Por lo cual es el conjunto de datos seleccionado.



*Figura 12.* Algunas enfermedades encontradas dentro del conjunto de imágenes.

Para las siguientes etapas Se hace uso de la Plataforma Kaggle (Kaggle, 2019).

Kaggle es una plataforma que dadas sus capacidades nos permite alojar conjuntos de datos y generar soluciones en fase inicial de proyectos relacionados con ciencia de datos e inteligencia artificial. Alrededor de ella se gesta una comunidad de entusiastas y científicos de datos quienes son alentados a exponer sus conocimientos en competencias de machine learning pagadas y organizadas por terceros, en donde Kaggle provee una página con las estadísticas de la competencia, el espacio de almacenamiento y la plataforma de trabajo.

Estas competencias que son ofrecidas por terceros son una buena oportunidad para que las personas afines a estas temáticas logren reforzar sus conocimientos y eventualmente ganar premios. Además de ello, Kaggle ofrece la oportunidad a las empresas de publicar vacantes laborales que puedan interesarle a la comunidad.

Nos enfocaremos en todo lo que Kaggle ofrece para desarrollar proyectos usando el Lenguaje de programación Python (Kuhlman, 2011). Tanto los Notebooks como los Scripts pueden ser públicos o privados, sin restricciones.

Dataset. Con el tiempo, kaggle se ha establecido como uno de los portales con mayor cantidad de conjuntos de datos listos para usar y descargar, actualmente posee más de 23.000 conjuntos de datos, con temáticas muy variadas.

Kaggle permite también publicar conjuntos de datos propios, para ello nos sugiere usar formatos accesibles y no propietarios. Debido a que se admiten mejor en la plataforma y son más fáciles de trabajar para más personas, independientemente de sus herramientas.

Dentro de los formatos sugeridos se encuentran: CSV, JSON, SQLite, Archivos comprimidos en formato 7z y ZIP que contengan archivos soportados por la plataforma, Conexiones con BigQuery. Los cuales se encuentran limitados para cada usuario de la siguiente manera:

- 20GB de almacenamiento por dataset.
- 20GB de almacenamiento máximo por usuario para datasets privados.
- Una estructura de archivos con una profundidad menor a 50 directorios

Notebook. El último tipo son los notebooks, los cuales son en Notebooks de la aplicación web Jupyter la cual permite crear y compartir documentos que contienen ejecuciones de código, ecuaciones, visualizaciones y texto narrativo. Los usos incluyen: limpieza y transformación de datos, simulación numérica, modelado estadístico, visualización de datos, aprendizaje automático y entre otros (Jupyter Team, s.f.). Los cuadernos Jupyter consisten en una secuencia de celdas, donde cada celda está formateada en Markdown

(para escribir texto) o en un lenguaje de programación de su elección (para escribir código). Estos Notebooks poseen acceso a internet, GPU y conexiones a los Dataset alojados en la misma plataforma. Lo cual permite tener una velocidad de ejecución mucho mayor a la que se obtendría ejecutando el proyecto en una CPU tradicional.

De esta manera, consumiremos el conjunto de datos (Wang et al., 2017) alojado en la plataforma de Kaggle y lo procesaremos sobre los Jupyter notebooks.

### **Etapa 5: Compresión de datos.**

Esta parte de la metodología implica una exhaustiva exploración de los datos recolectados en busca de tendencias, modas, y anomalías perceptibles; la información que se visualice permite entender y empaparse del comportamiento habitual de los datos y asegurar que estos no sufren sesgos en sus características que no representen la realidad.

Esto tienden a dar una mayor claridad de los grupos poblacionales en los datos, que permite actuar de manera proactiva frente a un grupo poblacional con baja cantidad de ejemplos al conseguir más ejemplos, permite mitigar un sesgo que no represente la realidad, por otro lado, permite extraer y eliminar o transformar anomalías en los datos como lo son picos inusuales, por tal razón se obtiene los siguientes análisis.

En la Figura 13 se evidencia que gran cantidad de ejemplos dentro del conjunto de datos pertenecen a la etiqueta 'No Finding', sin embargo, esto no influye de manera significativa en el modelo ya que estos datos están representando de manera idónea la realidad.

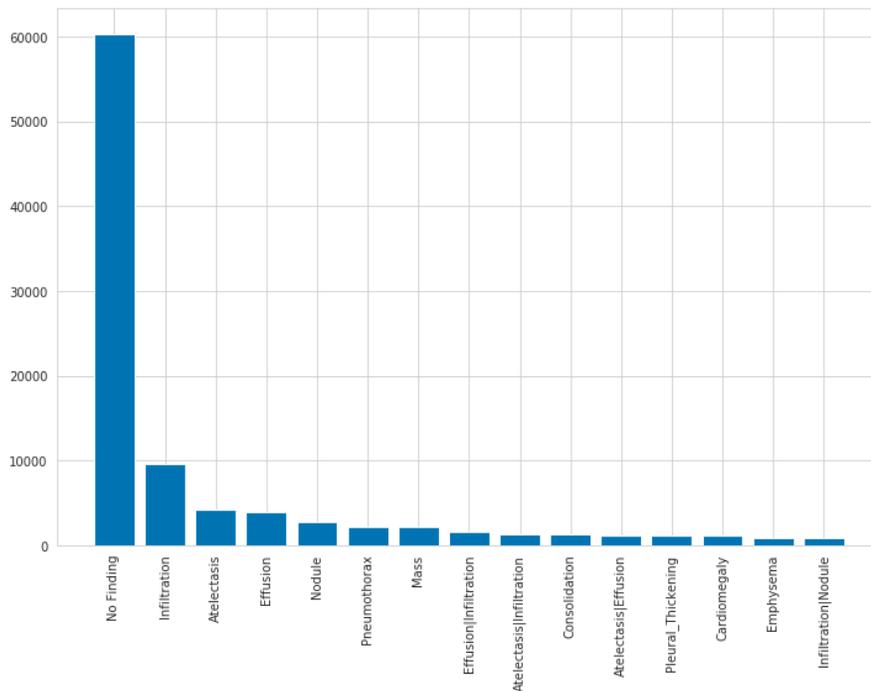


Figura 13. Gráfica de Barras Etiquetas por Cantidad.

La Figura 14 muestra cómo ambos géneros tienden a tener la misma distribución, también evidencian que la edad en donde más se han recolectado ejemplos son alrededor de los (60) sesenta años.

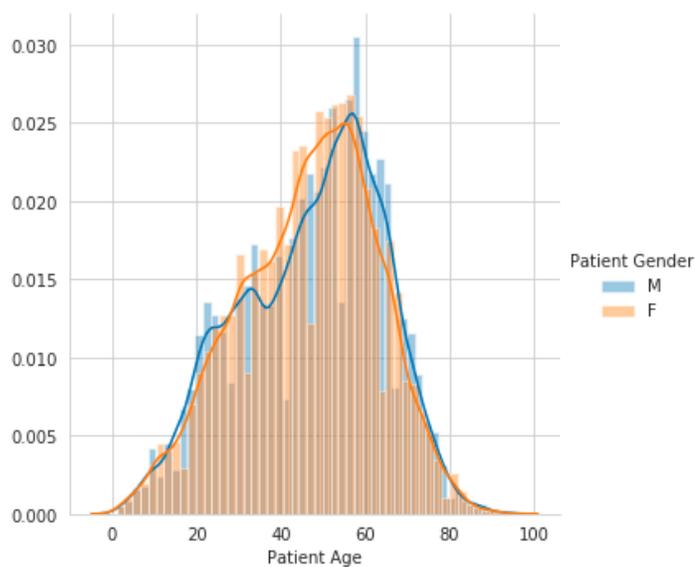


Figura 14. Gráfica de Distribución de Edad Contra Género

La enfermedad que más ejemplos posee dentro del conjunto de datos es infiltración, en donde los hombres representan la mayoría de dicha enfermedad, como se puede apreciar en la Figura 15:

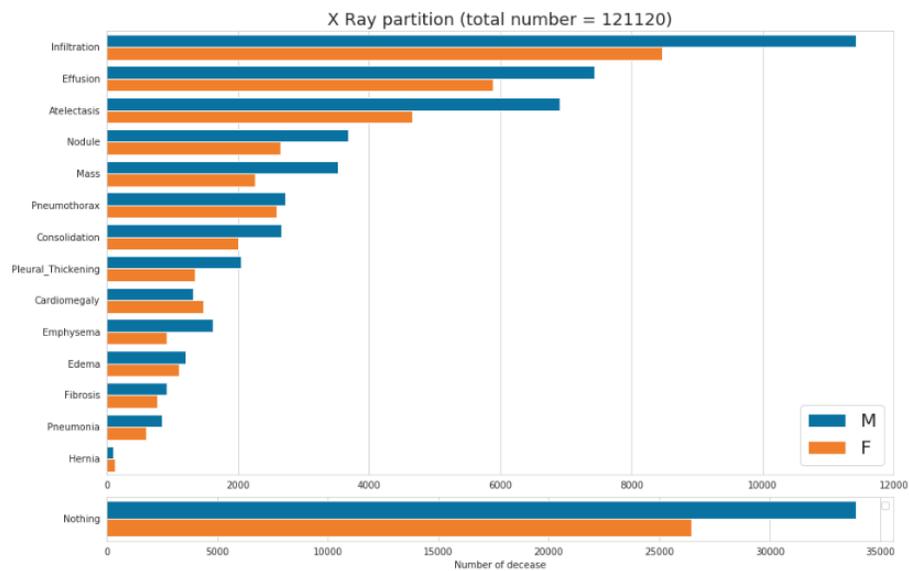


Figura 15. Gráfica de Barras Enfermedad contra Cantidad dependiendo del Género.

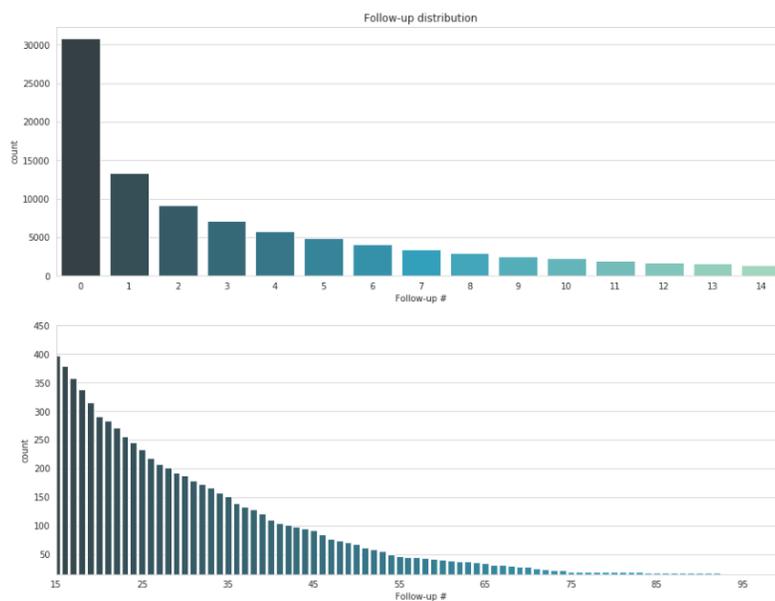


Figura 16. Gráfica de Barras Cantidad de Seguimientos con Pacientes.

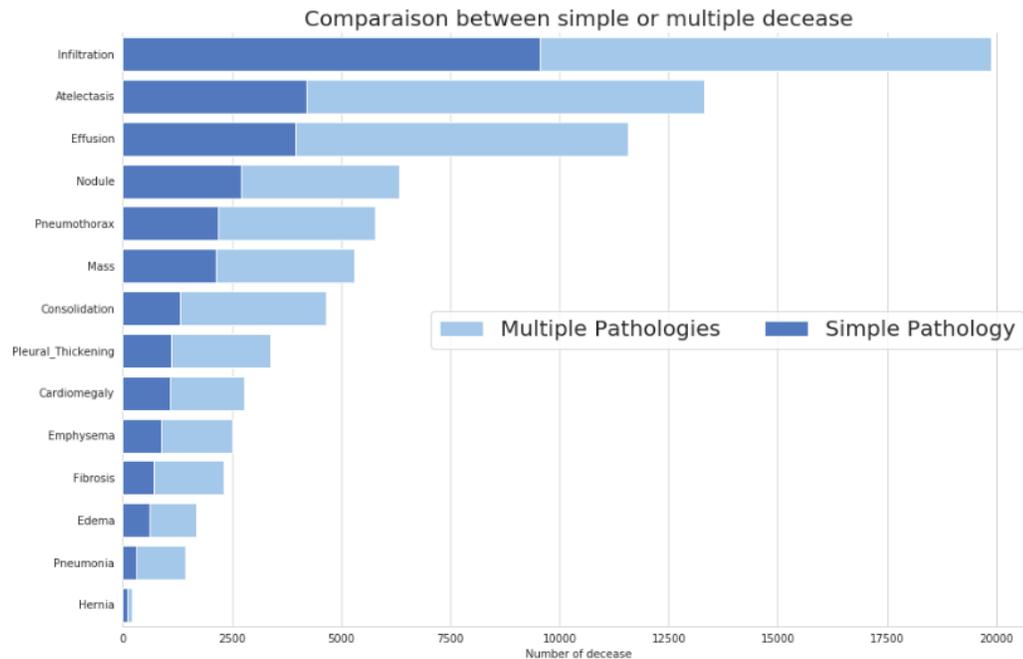


Figura 17. Gráfico de Barras Comparación entre Única y Múltiple Etiqueta

En la figura 17 se comprueba que el conjunto de datos posee referencias a todas las enfermedades no solo una etiqueta, si no mayormente múltiples por cada imagen.

### **Etapas 6: Preparación de datos**

Dado que se ha concluido con la etapa de la comprensión de los datos, se pasa a transformar los datos para volverlos aptos y óptimos para el consumo del modelo.

Lo que se busca en esta etapa es transformar y limpiar la información que existe en el dataset y que con ello genere mayor valor al ingresar a los modelos de inteligencia artificial.

Redimensión. La primera estrategia es la redimensión de las imágenes de tamaño original (1024px por 1024px) a 224px por 224px ya que esto permite un preprocesamiento más ágil al tener elementos más livianos y un procesamiento más rápido, además estas dimensiones se encuentran configuradas por defecto dentro de las arquitecturas a tratar

posteriormente, esta redimensión es realizada a través de un script de utilidad creado en Python y presente en los anexos.

Segmentación del Conjunto de Datos. Continuando con el preprocesamiento se pasa a dividir el dataset con el fin de tener 3 grupos de datos que permiten entrenar, validar y probar respectivamente. Los dataset representan un 70% para el conjunto de entrenamiento y un 30% para los conjuntos de validación y pruebas. A continuación, se repite este proceso con el conjunto de entrenamiento extrayendo de allí el 30% de los datos que ahora pertenecen al conjunto de validación, en todas las divisiones para crear los subconjuntos de datos se mantiene el mismo estado de aleatoriedad lo que permite que, aunque la división se haga en múltiples experimentos se trabaje siempre con la misma data de los subconjuntos.



*Figura 18.* Representación de porcentajes del conjunto de datos

Etiquetado. En el transcurso del proyecto se lleva a cabo el enfoque de tomar todas las imágenes y sus respectivas etiquetas con múltiples patologías transformadas a números de forma binaria y almacenadas en un array, todo esto se conoce como un proceso de one

hot encoding (Brownlee, 2019) debido a que luego de la etapa de comprensión de los datos se determina que muchas de las patologías son causa o consecuencia de otras.

Creación del Flujo de Entrenamiento. Al dejar preparada la información para ser consumida se hace mediante una estructura de flujo programática que consta de imagen y etiqueta conjuntamente y que permite enviar estos por lotes(mini batch) el cual se definido a 32 ejemplos por lote ya que es el estándar, lo que evita gran procesamiento computacional, en esta etapa se puede añadir la imagen con diferentes transformaciones como giros y normalizaciones lo que permite ampliar la diversidad de ejemplos, por otra parte se opta por reescalar la imagen de un rango de 0 a 255 valores por pixel a un rango de 0.0 a 1.0 ya que esto permite que la red calcule con mayor agilidad los datos procesados.

### **Etapa 7: Modelado.**

A partir de este punto se entra en la etapa de experimentación y el ciclo iterativo de entrenar y modificar hiperparámetros en los modelos en busca de mejoras en sus resultados, de acuerdo con esto se realizan dos fases internas, la primera aplica la estandarización de todos los hiperparámetros para las diferentes arquitecturas, la segunda es la configuración del modelo que mejor resultados haya obtenido.

Todos los modelos que se entrenan poseen pesos inicializados con modelos pre-entrenados con Imagenet (Deng et al., 2009).

Primera fase estandarización de los hiperparámetros. Ya que los experimentos deben tener un estándar de hiperparámetros para que sigan una línea comparativa independiente

de la arquitectura, se aplican los hiperparámetros y funciones de monitoreo que se encuentran en el estado del arte, y que dentro del ciclo de entrenamiento son capaces de auto ajustarse con el fin de brindar mejores resultados.

*Tabla 3.* Hiperparámetros y sus valores para todas las arquitecturas

Estado Aleatorio	Optimizador	Taza de aprendizaje	Épocas	Pasos por época	Tamaño de lote	Pasos de validación
2018	Adam	0.001	20	1690	32	724

Cabe aclarar que la función de pérdida también es un hiper parámetro el cual se le ha configurado a todos los experimentos con el valor ‘binary\_crossentropy’ ya que es el más adecuado para la resolución de este problema.

*Tabla 4.* Arquitecturas entrenadas, cuentas e hipervínculos.

Arquitectura	Cuenta	Url
Dense121	willarevalo	<a href="https://www.kaggle.com/willarevalo/xrays-multi-densenet121">https://www.kaggle.com/willarevalo/xrays-multi-densenet121</a>
Mobilenet	jbeltranleon	<a href="https://www.kaggle.com/jbeltranleon/xrays-multi-mobilenet">https://www.kaggle.com/jbeltranleon/xrays-multi-mobilenet</a>
MobilenetV2	jbeltranleon	<a href="https://www.kaggle.com/jbeltranleon/xrays-multi-mobilenetv2">https://www.kaggle.com/jbeltranleon/xrays-multi-mobilenetv2</a>
Resnet50	jbeltranleon	<a href="https://www.kaggle.com/jbeltranleon/xrays-multi-resnet50">https://www.kaggle.com/jbeltranleon/xrays-multi-resnet50</a>
Resnet50V2	jbeltranleon	<a href="https://www.kaggle.com/jbeltranleon/xrays-multi-resnet50v2">https://www.kaggle.com/jbeltranleon/xrays-multi-resnet50v2</a>
VGG16	jbletranleon	<a href="https://www.kaggle.com/jbeltranleon/xrays-multi-vgg16">https://www.kaggle.com/jbeltranleon/xrays-multi-vgg16</a>

Finalmente, de las arquitecturas iniciales de la Tabla 1 encontramos seis arquitecturas que permiten un entrenamiento estable en la plataforma de Kaggle, han sido ejecutadas durante aproximadamente 8 horas cada una, desde cuentas pertenecientes a los integrantes del proyecto, como se puede apreciar en la Tabla 4.

Segunda fase experimentación del modelo con mejores resultados. Al obtener el mejor resultado en un modelo se busca llevarlo a su forma óptima bajo los siguientes valores estándar de experimentación, valores por debajo del estándar en la etapa anterior y superiores a ellos, que permiten determinar si el modelo se encontraba con los hiperparámetros óptimos o es necesario utilizar variaciones de ellos.

*Tabla 5.* Hiperparámetros y sus valores para la arquitectura con mejores resultados.

<b>Estado Aleatorio</b>	<b>Optimizador</b>	<b>Taza de aprendizaje</b>	<b>Épocas</b>	<b>Pasos por época</b>	<b>Tamaño de lote</b>	<b>Pasos de validación</b>
2018	Adam	0.01	20	1690	32	724
2018	Adam	0.001	20	1690	32	724
2018	Adam	0.0001	20	1690	32	724

### **Etapa 8: Evaluación**

Posterior al entrenamiento es indispensable obtener métricas que determinen el rendimiento y poder de clasificación de nuevos datos, por lo tanto se predice el subconjunto de datos de test el cual jamás ha sido intervenido de ningún modo por el modelo, por lo que se entiende que son datos completamente nuevos para dicho modelo y a partir de ello se aplican ciertas funciones que permiten entender el nivel en el que ha

aprendido a clasificar el modelo, como son las medidas de perdida y el área bajo la curva de roc.

*Tabla 6.* Puntajes roc para cada enfermedad, promedio, y perdida para cada arquitectura

	<b>Densenet121</b>	<b>Mobilenet</b>	<b>MobilenetV2</b>	<b>Resnet50</b>	<b>Resnet50V2</b>	<b>VGG16</b>
Perdida en Validacion	0.21298	0.21814	0.20684	0.24329	0.23004	0.2171
Atelectasia	0.78	0.77	0.78	0.78	0.74	0.76
Consolidación	0.79	0.78	0.78	0.78	0.75	0.77
Infiltración	0.71	0.68	0.69	0.70	0.67	0.68
Neumotórax	0.86	0.85	0.85	0.84	0.79	0.81
Edema	0.88	0.88	0.87	0.87	0.83	0.87
Enfisema	0.88	0.86	0.88	0.86	0.76	0.80
Fibrosis	0.79	0.78	0.77	0.77	0.70	0.75
Efusión	0.87	0.87	0.87	0.87	0.84	0.85
Neumonía	0.74	0.71	0.70	0.73	0.66	0.68
Engrosamiento pleural	0.77	0.75	0.75	0.75	0.70	0.72
Cardiomegalia	0.90	0.87	0.85	0.89	0.86	0.87
Nodulo	0.73	0.70	0.73	0.72	0.67	0.66
Masa	0.82	0.77	0.80	0.80	0.74	0.71
Hernia	0.82	0.76	0.74	0.81	0.79	0.81
Promedio	0.811041	0.787629	0.790227	0.796878	0.751079	0.766268

La evaluación de la primera fase en donde se encontraban estándar los parámetros arroja que el modelo con mayor rendimiento es la arquitectura pre-entrenada Densenet121 ya que su puntaje promedio del área bajo la curva para las enfermedades rebasa a las otras arquitecturas, mientras que su valor de pérdida se mantiene bajo lo que indica que hay balance conveniente entre su predicción y su error.

Esto permite pasar a la siguiente etapa en la cual se experimenta con modelo más óptimo que es Densenet121, por lo que se hacen dos experimentos posteriores modificando los hiperparámetros como se menciona en la etapa de modelado.

*Tabla 7.* Puntajes roc para cada enfermedad, promedio, y pérdida para la arquitectura óptima

	<b>Densenet121 Taza de aprendizaje: original (0.001)</b>	<b>Densenet121 Taza de aprendizaje: superior(0.01)</b>	<b>Densenet121 Taza de aprendizaje: inferior(0.0001)</b>
Perdida en Validacion	0.21298	0.2270	0.2369
Atelectasia	0.78	0.76	0.76
Consolidación	0.79	0.78	0.77
Infiltración	0.71	0.68	0.69
Neumotórax	0.86	0.81	0.83
Edema	0.88	0.87	0.87
Enfisema	0.88	0.75	0.85
Fibrosis	0.79	0.75	0.72
Efusión	0.87	0.84	0.86
Neumonía	0.74	0.69	0.69

Engrosamiento pleural	0.77	0.72	0.71
Cardiomegalia	0.90	0.87	0.87
Nodulo	0.73	0.65	0.68
Masa	0.82	0.72	0.75
Hernia	0.82	0.80	0.73
Promedio	0.811041	0.765314	0.770181

---

Dados los resultados obtenidos se puede afirmar que la variación con mejor rendimiento para Densenet121 es aquella que venía con los hiperparámetros que se habían estandarizado a través de todas las otras arquitecturas, en otras palabras los hiperparámetros originalmente configurados a la hora de entrenar el modelo por primera vez.

### **Etapa 9: Implementación**

En este punto ya con el modelo escogido, la red entrenada y evaluada, podemos lanzar predicciones más digeribles para el público al colocar las imágenes que se quieren predecir con su respectiva etiqueta real y los porcentajes que arroja la predicción del modelo.

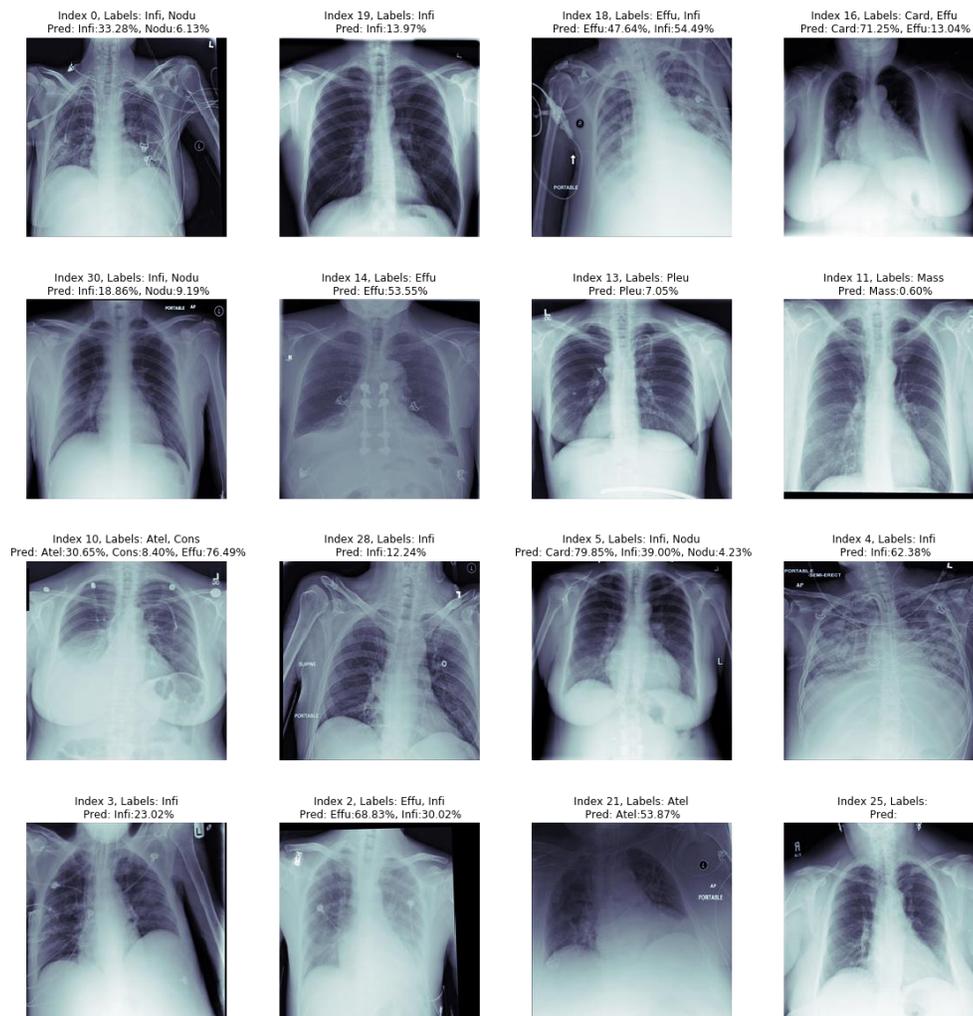


Figura 19. Imágenes aleatorias con su respectiva etiqueta y predicción.

## **Etapa 10: Retroalimentación**

En esta etapa se busca la retroalimentación de los profesionales con el conocimiento del tema, o al poder comparar con otros archivos científicos similares.

## Resultados

Al comparar los resultados obtenidos por el modelo optimo contra arquitecturas de otras investigaciones desarrolladas por equipos de investigación de avanzada como Universidad de Stanford y su grupo de Machine Learning (Pranav Rajpurkar, 2017) se percibe que ellos se encuentran en el estado del arte con un promedio de valores de roc en 0.841, sin embargo el modelo entrenado en este proyecto aun contando con las condiciones de ser de tan rápido alcance y sencillo de replicar no se se aleja mucho de este estado del arte; También podemos encontrar que comparado contra otras investigaciones se supera el estándar como es el caso de la Universidad tecnológica de Hamburgo en Alemania y su instituto de imagen biomédica (Ivo Baltruschat, 2018) que obtiene un promedio roc de 0.806.

*Tabla 8.* Puntajes roc de la investigación contra otras investigaciones

	<b>Densenet121 (Nuestra)</b>	<b>Rajpurkar et al, (2017)</b>	<b>Wang et al. (2017)</b>	<b>Yao et al. (2017)</b>	<b>Baltruschat1 et al. (2019)</b>
Atelectasia	0.78	0.80	0.70	0.73	0.76
Consolidación	0.79	0.79	0.70	0.71	0.74
Infiltración	0.71	0.73	0.66	0.67	0.69
Neumotórax	0.86	0.88	0.79	0.80	0.84
Edema	0.88	0.88	0.80	0.80	0.84
Enfisema	0.88	0.93	0.83	0.84	0.89
Fibrosis	0.79	0.80	0.78	0.74	0.81
Efusión	0.87	0.86	0.75	0.80	0.82
Neumonía	0.74	0.76	0.65	0.68	0.71
Engrosamiento pleural	0.77	0.80	0.68	0.72	0.76

Cardiomegalia	0.90	0.92	0.81	0.85	0.87
Nodulo	0.73	0.78	0.66	0.72	0.74
Masa	0.82	0.86	0.69	0.77	0.82
Hernia	0.82	0.91	0.87	0.77	0.93
Promedio	0.811	0.841	0.745	0.761	0.806

---

## **Discusión**

Podemos afirmar que comparando nuestros resultados con el estado del arte se encuentran muy cerca de este hito, y referentes a los anteriores estados del arte gratamente se sobrepasan. A través del proyecto se desempeñaron múltiples experimentos aquí expuestos dando como resultado un satisfactorio puntaje con una sencilla técnica como lo es Transfer Learning.

Este proyecto se ha llevado por una serie de etapas que permiten organizar el flujo de trabajo y marcar un guía, sin embargo en muchas de las investigaciones en las que nos apoyamos no se siguen esos lineamientos, dado que esta ciencia es nueva y está sujeta a cambios, en donde se experimenta todos los días no solo con la construcción de modelos, sino también la de marcos de trabajos y metodologías que vayan a fin con la problemática a resolver, por lo que no estamos en disposición de decir que pueda servir para resolver problemas en un tiempo posterior si las tecnologías y/o flujos de trabajo han cambiado.

Debido al reciente auge del campo están saliendo nuevas arquitecturas cada cierto tiempo, por lo que, aunque los resultados son prometedores con las arquitecturas actuales, es probable que se obtengan mejores resultados con arquitecturas que estén prontas a incorporasen a los marcos de trabajo.

### **Recomendaciones para la Definición de un Proyecto de ML**

Al trabajar en un proyecto de este tipo es prudente dar ciertos consejos para los lectores que desean entrar de forma inmersa en estos temas. En la realización del proyecto se encontraron múltiples dificultades referentes a los datos adquiridos y el entrenamiento que se abordan a continuación.

Validar los datos. A la hora de explorar qué conjunto de datos elegir para resolver el problema, existen diversos factores que pueden llegar a ser vitales en etapas posteriores y resultados más precisos, como lo son el origen de dichos datos y la precisión del etiquetado dentro del conjunto, por ende, se recomienda un minucioso análisis e investigación de la procedencia de los datos y la fiabilidad de los mismos.

Definir cuidadosamente alcance y objetivos. En muchos proyectos de este tipo se tiende a esperarse resultados bastante entusiastas sin definir adecuadamente el alcance del proyecto, los objetivos a trabajar, sin conocer el estado del arte en este campo, en problemas similares o iguales al que se busca tratar y con altas expectativas sin base argumental, o investigativa, por ello recomendamos ahondar en estos temas antes de ir de lleno a la experimentación, ya que sin conocimiento alguno de cuál es el rango de precisión actual o una métrica a la cual apuntar no se tendrá nada con qué medir y/o comparar si el proyecto realmente se encuentra mejorando o si por el contrario comienza a empeorar. Así mismo puede darse la situación de que al no definir correctamente los alcances el proyecto tome mucho más del tiempo esperado.

Que temas estudiar antes de iniciar. Dado que el Machine Learning y Ciencia de Datos es tan amplio, extenso y crece cada momento, recomendamos, estudiar metodologías de ciencia de datos que los ayuden a definir las etapas por las cuales debe pasar su proyecto, es muy importante poseer conocimientos al menos básicos de Machine Learning y si es necesario un poco de Deep Learning. Ahondar en el tema que se quiere resolver de forma detallada al estudiar el comportamiento de los datos dentro de su ambiente.

Estas pautas permitirán que un proyecto posterior posea objetivos alcanzables y realistas, además de tener un flujo de acción trazado.

## Conclusiones

Presentamos una evaluación sistemática con diferentes enfoques que permiten la clasificación de 14 enfermedades en rayos X del conjunto de datos ChestX-ray14 basado en arquitecturas de redes neuronales convolucionales, en el transcurso se obtienen resultados satisfactorios con redes optimizadas bajo el conjunto de datos ImageNet, nuestros mejores resultados logran competir contra los resultados que se encuentran en el estado del arte y poseen una estructura sencilla y fácil de replicar. Si bien los resultados obtenidos sugieren que el entrenamiento de redes neuronales profundas en el dominio del médico es una opción bastante viable y también cada vez existen más conjuntos de datos del tema. Para el caso en particular del conjunto de datos ChestX-ray14 el ruido en las etiquetas al ser bastante alto del 10%, hace que una evaluación verdadera acerca del rendimiento de la red sea difícil, por lo que la calidad de la etiqueta de los datos se convierte en una limitación.

## **Trabajo Futuro**

En trabajos futuros se deberían abarcar temas relacionados con la investigación de otras arquitecturas modelo, nuevas arquitecturas para aprovechar las dependencias de etiquetas e incorporando información de segmentación como es la edad, el sexo entre otros. Así mismo puede ser posible conseguir mejores resultados aplicando un aumento a la data existente.

### **Anexo 1**

Se anexa el código fuente del modelo óptimo, así como todos los demás modelos ejecutados sobre la plataforma de Kaggle, así mismo se anexa un documento de texto plano en donde se referencian las url públicas a todas las ejecuciones.

## Anexo 2

Acta de Inicio:

	ADOr010-V6
	Página 1 de 3

---

21.1

**ACTA No. 001**

**CLASE DE REUNIÓN:** Acta de Inicio proyecto de grado “Selección de Modelo de Red Neuronal Profunda (Deep Learning) óptimo para el reconocimiento de enfermedades usando imágenes de Rayos X”.

**CIUDAD Y FECHA:** Fusagasugá, 2018 - 08 10

**HORA:** 09: 00 a.m.

**LUGAR:** UNIVERSIDAD DE CUNDINAMARCA,  
SALA BLOQUE A.

**ASISTENTES:** Ingeniero(a) ANGELA PATRICIA ARENAS AMADO.  
Director de Proyecto

WILLIAM FABIAN AREVALO RODRIGUEZ.  
Estudiante.

JHON FREDY BELTRAN LEON.  
Estudiante.

**AUSENTES CON EXCUSA:**

NO APLICA

**INVITADOS:** NO APLICA

**ORDEN DEL DÍA:**

1. LLAMADO A LISTA Y VERIFICACIÓN DEL QUÓRUM.
2. LECTURA Y APROBACIÓN DEL ORDEN DEL DÍA.
3. INICIO OFICIAL DEL PROYECTO

**DESARROLLO DE LA SESIÓN:**

---

Diagonal 18 No. 20-29 Fusagasugá – Cundinamarca  
 Teléfono (091) 8281483 Línea Gratuita 018000180414  
[www.ucundinamarca.edu.co](http://www.ucundinamarca.edu.co) E-mail: [info@ucundinamarca.edu.co](mailto:info@ucundinamarca.edu.co)  
 NIT: 890.680.062-2

*Documento controlado por el Sistema de Gestión de la Calidad  
 Asegúrese que corresponde a la última versión consultando el Portal Institucional*



ADOr010-V6

Página 2 de 3

21.1

**ACTA No. 001**

1. Se hace llamado a lista, se verifica Quórum y se confirma que se puede realizar la reunión de acta de inicio del proyecto
2. Se hace la lectura del orden del día y se aprueba.
3. Mediante la presente acta de reunión y en acuerdo de la partes se da inicio oficial al proyecto aprobado "Selección de Modelo de Red Neuronal Profunda (Deep Learning) óptimo para el reconocimiento de enfermedades usando imágenes de Rayos X", de acuerdo a Acta No. 05 del Comité de Trabajos de Grado programa Ingeniería de Sistemas Facultad de Ingeniería, realizado el día 09 del mes de Agosto de 2018.  
Se acuerda que el seguimiento del proyecto se realizará mediante el anteproyecto (modalidad Trabajo Monográfico) aprobado y sus respectivos anexos.

**COMPROMISOS Y RESPONSABLES:**

1. Los estudiantes se comprometen a cumplir los parámetros establecidos institucionalmente y mediante la documentación soporte del anteproyecto aprobado.

**ANEXOS**

FECHA	CORREO ELECTRÓNICO	REMITENTE
AAAA-MM-DD		

Nota: Relación de comunicaciones recibidas y/o enviadas.

**ACTOS ADMINISTRATIVOS  
RESOLUCIONES**

FECHA	NOMBRE	DECISIÓN

Diagonal 18 No. 20-29 Fusagasugá – Cundinamarca  
Teléfono (091) 8281483 Línea Gratuita 018000180414  
[www.ucundinamarca.edu.co](http://www.ucundinamarca.edu.co) E-mail: [info@ucundinamarca.edu.co](mailto:info@ucundinamarca.edu.co)  
NIT: 890.680.062-2

Documento controlado por el Sistema de Gestión de la Calidad  
Asegúrese que corresponde a la última versión consultando el Portal Institucional



**UDEEC**  
UNIVERSIDAD DE  
CUNDINAMARCA

ADO010-V6

Página 3 de 3

21.1

## ACTA No. 001

AAAA-MM-DD	XXXXXXXXXXXXXXXXXXXX	<b>POR APROBAR APROBADA etc.</b>
------------	----------------------	--------------------------------------

No siendo más el orden del día se da por terminada la reunión a las 10: 00 a. m.

*Angela Arenas Amado*  
**Ing. ANGÉLA PATRICIA ARENAS AMADO**  
Director de Proyecto  
Facultad de Ingeniería  
UNIVERSIDAD DE CUNDINAMARCA

*William Fabian Arevalo Rodriguez*  
**WILLIAM FABIAN AREVALO RODRIGUEZ**  
Estudiante Ingeniería de Sistemas

*Jhon Fredy Beltran Leon*  
**JHON FREDY BELTRAN LEON**  
Estudiante Ingeniería de Sistemas

Copia: Archivo

Anexos: Anteproyecto aprobado.

Elaboró: William Arévalo, Ángela Arenas, Jhon Beltrán.

21.1-2.37

## Acta Final:



**UDEC**  
UNIVERSIDAD DE  
CUNDINAMARCA

ADOr010-V6

Página 1 de 4

21.1

**ACTA No. 006**

**CLASE DE REUNIÓN:** ENTREGA FINAL DEL PROYECTO 'Selección de Modelo de Red Neuronal Profunda (Deep Learning) óptimo para el reconocimiento de enfermedades usando imágenes de Rayos X'

**CIUDAD Y FECHA:** Fusagasuga, 2018 - 11 12

**HORA:** 09: 00 a.m.

**LUGAR:** UNIVERSIDAD DE CUNDINAMARCA,  
SALA BLOQUE A.

**ASISTENTES:** Ingeniero(a) ANGELA PATRICIA ARENAS AMADO.  
Director de Proyecto

Ingeniero(a) ALEXANDER CAICEDO DORADO.  
Asesor Externo

WILLIAM FABIAN AREVALO RODRIGUEZ.  
Estudiante.

JHON FREDY BELTRAN LEON.  
Estudiante.

**AUSENTES CON EXCUSA:**

NO APLICA

**INVITADOS:** NO APLICA

**ORDEN DEL DIA:**

1. LLAMADO A LISTA Y VERIFICACIÓN DEL QUÓRUM.
2. LECTURA Y APROBACIÓN DEL ORDEN DEL DÍA.
3. ENTREGA FINAL DE PROYECTO.

Diagonal 18 No. 20-29 Fusagasugá – Cundinamarca  
Teléfono (091) 8281483 Línea Gratuita 018000180414  
[www.ucundinamarca.edu.co](http://www.ucundinamarca.edu.co) E-mail: [info@ucundinamarca.edu.co](mailto:info@ucundinamarca.edu.co)  
NIT: 890.680.062-2

Documento controlado por el Sistema de Gestión de la Calidad  
Asegúrese que corresponde a la última versión consultando el Portal Institucional



21.1

**ACTA No. 006****DESARROLLO DE LA SESIÓN:**

1. Se hace llamado a lista, se verifica Quórum y se confirma que se puede realizar la reunión de acta de inicio del proyecto
2. Se hace la lectura del orden del día y se aprueba.
3. Los estudiantes hacen entrega del Proyecto de acuerdo a los productos comprometidos mediante Anteproyecto aprobado en Comité de Trabajos de Grado del día 09 del mes de Agosto de 2018.

En su orden se hace entrega de

- Modelo óptimo de red neuronal convolucional para la clasificación de enfermedades del pecho a través de imágenes de rayos X
- Libro del proyecto
- Artículo 'Consideraciones Sobre Kaggle Como Plataforma Gratuita Para Desarrollar Proyectos De Machine Learning Para La Clasificación de Imágenes Con Python'
- Documento de texto plano en donde se referencian las url públicas a todas las ejecuciones de los modelos y sus variaciones.

**COMPROMISOS Y RESPONSABLES:**

1. Ninguno.

**ANEXOS**

FECHA	CORREO ELECTRÓNICO	REMITENTE
AAAA-MM-DD		

Nota: Relación de comunicaciones recibidas y/o enviadas.



ADOr010-V6

Página 3 de 4

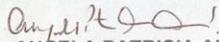
21.1

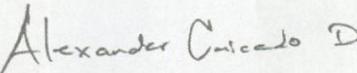
ACTA No. 006

**ACTOS ADMINISTRATIVOS  
RESOLUCIONES**

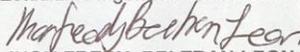
FECHA	NOMBRE	DECISIÓN
AAAA-MM-DD	XXXXXXXXXXXXXXXXXXXXX	POR APROBAR APROBADA etc.

No siendo más el orden del día se da por terminada la reunión a las 10: 00 a. m.

  
Ing. ANGELA PATRICIA ARENAS AMADO  
Director de Proyecto  
Facultad de Ingeniería  
UNIVERSIDAD DE CUNDINAMARCA

  
Ing. Alexander Caicedo Dorado  
Asesor Externo  
UNIVERSIDAD DEL ROSARIO

  
WILLIAM FABIAN AREVALO RODRIGUEZ  
Estudiante Ingeniería de Sistemas

  
JHON FREDY BELTRAN LEON  
Estudiante Ingeniería de Sistemas

Diagonal 18 No. 20-29 Fusagasugá – Cundinamarca  
Teléfono (091) 8281483 Línea Gratuita 018000180414  
[www.ucundinamarca.edu.co](http://www.ucundinamarca.edu.co) E-mail: [info@ucundinamarca.edu.co](mailto:info@ucundinamarca.edu.co)  
NIT: 890.680.062-2

Documento controlado por el Sistema de Gestión de la Calidad  
Asegúrese que corresponde a la última versión consultando el Portal Institucional



**UDEEC**  
UNIVERSIDAD DE  
CUNDINAMARCA

ADOr010-V6

Página 4 de 4

21.1

**ACTA No. 006**

Copia: Archivo

Anexos: Anteproyecto aprobado.

Elaboró: William Arevalo, Angela Arenas, Jhon Beltran y Alexander Caicedo.

21.1-2.37

## No autorización de publicación artículo científico

Fusagasugá, Noviembre 12 de 2019

Señores  
**UNIVERSIDAD DE CUNDINAMARCA**  
Facultad de Ingeniería  
Ingeniería de Sistemas  
Fusagasugá

**Asunto:** Publicación Artículo Científico en revistas de la Universidad de Cundinamarca.

Respetados Señores:

Por medio de la presente nos permitimos comunicar que no autorizamos la publicación de nuestro Artículo Científico titulado "SELECCIÓN DE MODELO DE RED NEURONAL PROFUNDA (DEEP LEARNING) ÓPTIMO PARA EL RECONOCIMIENTO DE ENFERMEDADES USANDO IMÁGENES DE RAYOS X", debido a que será postulado con fines académicos en eventos y/o medios externos, y para tal efecto se gestionará el apoyo respectivo de la Universidad de Cundinamarca cuando así sea requerido.

Sin otro particular nos suscribimos agradeciendo de antemano su atención.

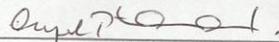
Atentamente,



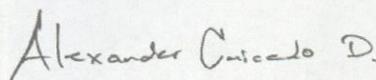
**Estudiante:** Jhon Fredy Beltrán León  
C.C. No. 1069758190



**Estudiante:** William Fabián Arévalo Rodríguez  
C.C. 1069750950



**Director:** Ángela Patricia Arenas Amado  
C.C. No. 52.208.301



**Asesor externo:** Alexander Caicedo Dorado  
C.C. No. 14.139.512

## Referencias

- Alves, G. (2018, 08 octubre). Entendiendo Redes Convolucionais (CNNs). Recuperado 4 octubre, 2019, de <https://medium.com/neuronio-br/entendiendo-redes-convolucionais-cnns-d10359f21184>
- Alves, G. (2018, 08 octubre). Entrada de 28x28 dimensões com receptive field de área 5x5. [Figura]. Recuperado 2 octubre, 2019, de <https://medium.com/neuronio-br/entendiendo-redes-convolucionais-cnns-d10359f21184>
- Alves, G. (2018, 08 octubre). Maxpooling com 2x2 de área. [Figura]. Recuperado 2 octubre, 2019, de <https://medium.com/neuronio-br/entendiendo-redes-convolucionais-cnns-d10359f21184>
- Baltruschat, M. Ivo. (2018, 6 marzo). Comparison of Deep Learning Approaches for Multi-Label Chest X-Ray Classification. Recuperado 10 septiembre, 2019, de <https://arxiv.org/abs/1803.02315>
- Bazán, P., Fernandez, A., Del Rio, N., Molinari, L., Pérez, J., & Banchoff, M. (2017). *Aplicaciones, servicios y procesos distribuidos Una visión para la construcción de software* (Ed. rev.). Buenos Aires, Argentina: Editorial Universidad de La Plata.

Bosagh, R. &, Ramsundar, B (2019). A fully connected layer in a deep network. [Figura].

Recuperado 2 octubre, 2019, de <https://www.oreilly.com/library/view/tensorflow-for-deep/9781491980446/ch04.html>

Brownlee, J. B. (2019, 19 mayo). Why One-Hot Encode Data in Machine Learning?

Recuperado 5 octubre, 2019, de <https://machinelearningmastery.com/why-one-hot-encode-data-in-machine-learning/>

CDC. (2019). Deaths: Final Data for 2017. *National Vital Statistics Reports*, 68(9), 1-2.

[https://www.cdc.gov/nchs/data/nvsr/nvsr68/nvsr68\\_09-508.pdf](https://www.cdc.gov/nchs/data/nvsr/nvsr68/nvsr68_09-508.pdf)

Cerda, P., Varoquaux, G., & Kégl, B. (2018). Similarity encoding for learning with dirty categorical variables. *Machine Learning*, 107(8-10), 1477–1494.

<https://doi.org/10.1007/s10994-018-5724-2>

Deng, J., Dong, W., Socher, R., Li, L., Kai Li, & Li Fei-Fei, (2009). ImageNet: A large-scale hierarchical image database. *2009 IEEE Conference on Computer Vision and Pattern Recognition*, .

<https://doi.org/10.1109/cvpr.2009.5206848>

Dong, Y., Pan, Y., Zhang, J., & Xu, W. (2017). Learning to Read Chest X-Ray Images from 16000+ Examples Using CNN. *2017 IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE)*, <https://doi.org/10.1109/chase.2017.59>

- Fernández, A. (2014, 19 septiembre). El renacimiento de la Inteligencia Artificial.  
Recuperado 31 octubre, 2019, de <https://www.sintetia.com/el-renacimiento-de-la-inteligencia-artificial/>
- Franquet, I. (2001). Imaging of pneumonia: trends and algorithms. *European Respiratory Journal*, 18(1), 196-208
- Google Developers. (s.f.). Machine Learning Glossary | Google Developers. Recuperado 11 octubre, 2019, de <https://developers.google.com/machine-learning/glossary>
- Google Inc. (s.f.). Descending into ML: Training and Loss | Machine Learning Crash Course. Recuperado 9 septiembre, 2019, de <https://developers.google.com/machine-learning/crash-course/descending-into-ml/training-and-loss>
- Google Inc. (s.f.-b). Clasificación: ROC y AUC | Curso intensivo de aprendizaje automático. Recuperado 11 septiembre, 2019, de <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc?hl=es-419>
- Google. (s.f.). Clasificación: ROC y AUC | Curso intensivo de aprendizaje automático. Recuperado 11 octubre, 2019, de <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc?hl=es-419>
- Google. (s.f.). Cloud Computing Services | Google Cloud. Recuperado 1 octubre, 2019, de <https://cloud.google.com/>

- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., . . . Che, T. (2015, 22 diciembre). Recent Advances in Convolutional Neural Networks. Recuperado 4 octubre, 2019, de <https://arxiv.org/abs/1512.07108>
- He, K., Zhang, X., Ren, S., & Sun, J. (2015, 10 diciembre). Deep Residual Learning for Image Recognition. Recuperado 4 octubre, 2019, de <https://arxiv.org/abs/1512.03385>
- Howard, A., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., . . . Adam, H. (2017, 17 abril). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. Recuperado 4 noviembre, 2019, de <https://arxiv.org/abs/1704.04861>
- Huang, G., Liu, Z., Van der Maaten, L., & Weinberger, K. (2016, 25 agosto). Densely Connected Convolutional Networks. Recuperado 4 octubre, 2019, de <https://arxiv.org/abs/1608.06993>
- Hurwitz, J., & Kirsch, D. (2018). *Machine Learning For Dummies, IBM Limited Edition*. Hoboken, Estados Unidos: John Wiley & Sons, Inc.
- Introducción a Sobreajuste y Subajuste para Machine Learning - Ligdi González. (2019, 2 julio). Recuperado 9 septiembre, 2019, de <http://ligdigonzalez.com/sobreajuste-y-subajuste-en-machine-learning/>

Irvin, J. I. Jeremy. (2019, 21 enero). CheXpert: A Large Chest Radiograph Dataset with Uncertainty Labels and Expert Comparison. Recuperado 4 octubre, 2019, de

<https://arxiv.org/abs/1901.07031>

Jannesari, M., Habibzadeh, M., Aboulkheyr, H., Khosravi, P., Elemento, O., Totonchi, M., & Hajirasouliha, I. (2018). Breast Cancer Histopathological Image Classification: A Deep Learning Approach. *2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*.

<https://doi.org/10.1109/bibm.2018.8621307>

Johnson, E. W. Alistair. (2019, 21 enero). MIMIC-CXR: A large publicly available database of labeled chest radiographs. Recuperado 3 noviembre, 2019, de

<https://arxiv.org/abs/1901.07042>

Jupyter Team. (s.f.). Project Jupyter. Recuperado 4 octubre, 2019, de <https://jupyter.org/>

Kaggle. (s.f.). Notebooks Documentation | Kaggle. Recuperado 1 octubre, 2019, de

<https://www.kaggle.com/docs/kernels>

Keras. (s.f.-a). Home - Keras Documentation. Recuperado 31 octubre, 2019, de

<https://keras.io>

Keras. (s.f.-b). Applications - Keras Documentation. Recuperado 1 octubre, 2019, de

<https://keras.io/applications/>

- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90.  
<https://doi.org/10.1145/3065386>
- Kruskal, W. H., & Wallis, W. A. (1952). Use of Ranks in One-Criterion Variance Analysis. *Journal of the American Statistical Association*, 47(260), 583–621.  
<https://doi.org/10.1080/01621459.1952.10483441>
- Kuhlman, D. (2011). *A Python Book: Beginning Python, Advanced Python, and Python Exercises*. Washington, Estados Unidos: John Wiley & Sons, Inc.
- Liu, T., Fang, S., Zhao, Y., Wang, P., & Zhang, J. (2015, 04 Junio). Implementation of Training Convolutional Neural Networks. Recuperado 2 octubre, 2019, de <https://arxiv.org/abs/1506.01195>
- Lombana, A. (2018). La evolución de las brechas digitales y el auge de la Inteligencia Artificial (IA). *Revista Mexicana de Bachillerato a Distancia*, 10(20).  
<https://doi.org/10.22201/cuaed.20074751e.2018.20.65884>
- McHugh, M. L. (2012). Interrater reliability: the kappa statistic. *Biochemia Medica*, , 276–282. <https://doi.org/10.11613/bm.2012.031>
- NIH. (2018, 21 febrero). NIH Chest X-rays. Recuperado 2 octubre, 2019, de <https://www.kaggle.com/nih-chest-xrays/data/version/3>

- Paul, S., GARG, M. K., KALE, S. K., Kaur, D. T., Muniraju, D. M., Sagar, D. S., . . . Bangalore, A. in. (2018). Inter-radiologist concordance in pulmonary tuberculosis vs. normal chest x-ray classification to arrive at expected performance level of automated classification. *European Society of Radiology*, ECR 2018(C-2197), 4. <https://doi.org/10.1594/ecr2018/C-2197>
- Python. (s.f.). pickle — Python object serialization — Python 3.8.0 documentation. Recuperado 5 octubre, 2019, de <https://docs.python.org/3/library/pickle.html>
- Rajpurkar (2017, 14 noviembre). CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning. Recuperado 11 septiembre, 2019, de <https://arxiv.org/abs/1711.05225>
- Rajpurkar, P., Irvin, J., Ball, R. L., Zhu, K., Yang, B., Mehta, H., . . . Lungren, M. P. (2018). Deep learning for chest radiograph diagnosis: A retrospective comparison of the CheXNeXt algorithm to practicing radiologists. *PLOS Medicine*, 15(11). <https://doi.org/10.1371/journal.pmed.1002686>
- Rollins, J. (2015). Foundational methodology for data science. [Figura]. Recuperado 2 octubre, 2019, de <https://www.ibmbigdatahub.com/blog/why-we-need-methodology-data-science>
- Rollins, J. (2015). Why we need a methodology for data science. Recuperado 2 octubre, 2019, de <https://www.ibmbigdatahub.com/blog/why-we-need-methodology-data-science>

Russell, S. J., Norvig, P., & Davis, E. (2010). A simple mathematical model for a neuron.

[Figura] Recuperado de *Artificial Intelligence: A Modern Approach* (3ª ed.).

Upper Saddle River, Estados Unidos: Prentice Hall.

Russell, S. J., Norvig, P., & Davis, E. (2010). *Artificial Intelligence: A Modern Approach*

(3ª ed.). Upper Saddle River, Estados Unidos: Prentice Hall.

Saha, S. (2018). 4x4x3 RGB Image. [Figura]. Recuperado 2 octubre, 2019, de

<https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>

Scikit-learn. (s.f.). scikit-learn: machine learning in Python — scikit-learn 0.21.3

documentation. Recuperado 11 noviembre, 2019, de <https://scikit-learn.org/stable/>

Sharma, S., Chang, V., Tim, U. Sunday, Wong, J., & Gadia, S. (2016). Cloud-based

emerging services systems. *International Journal of Information Management*,

390585. Recuperado de <https://eprints.soton.ac.uk/390585/>

Stanford Vision Lab. (s.f.). ImageNet. Recuperado 4 octubre, 2019, de

<http://www.image-net.org/>

TensorFlow. (s.f.). TensorFlow. Recuperado 1 octubre, 2019, de

<https://www.tensorflow.org/>

Wang, X., Peng, Y., Lu, L., Lu, Z., Bagheri, M., & Summers, R. M. (2017). ChestX-

Ray8: Hospital-Scale Chest X-Ray Database and Benchmarks on Weakly-

- Supervised Classification and Localization of Common Thorax Diseases. 2017  
*IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, .  
<https://doi.org/10.1109/cvpr.2017.369>
- Weiss, K., Khoshgoftaar, T. M., & Wang, D. (2016). A survey of transfer learning.  
*Journal of Big Data*, 3(1). <https://doi.org/10.1186/s40537-016-0043-6>
- Wikipedia. (2019, 19 octubre). internet platform for data science competitions.  
Recuperado 4 octubre, 2019, de <https://en.wikipedia.org/wiki/Kaggle>
- Yao, Prosky, Poblenz, Covington, & Lyman, (2018, 21 marzo). Weakly Supervised  
Medical Diagnosis and Localization from Multiple Resolutions. Recuperado 12  
septiembre, 2019, de <https://arxiv.org/abs/1803.07703>
- Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. (2017, 21 julio). Learning Transferable  
Architectures for Scalable Image Recognition. Recuperado 4 octubre, 2019, de  
<https://arxiv.org/abs/1707.07012>