



UNIVERSIDAD JOSÉ ANTONIO PÁEZ

**DESARROLLO DE UN MODELO DE DEEP  
LEARNING PARA LA AUTOMATIZACIÓN  
DE LOS PROCESOS DE DETECCIÓN DE  
TUMORES CEREBRALES**

*Autor:*

Torres Toro Jorge Rafael

C.I.: 28.232.437

Urb. Yuma II, calle N° 3. Municipio San Diego  
Teléfono: (0241) 8714240 (master) – Fax: (0241) 8712394



**REPÚBLICA BOLIVARIANA DE VENEZUELA**  
**UNIVERSIDAD JOSÉ ANTONIO PÁEZ**  
**FACULTAD DE INGENIERÍA**  
**ESCUELA DE INGENIERÍA EN COMPUTACIÓN**

**DESARROLLO DE UN MODELO DE DEEP LEARNING PARA LA  
AUTOMATIZACIÓN DE LOS PROCESOS DE DETECCIÓN DE  
TUMORES CEREBRALES**

Proyecto del Trabajo de Grado para optar al título de  
**INGENIERO EN COMPUTACIÓN**

Autor:

Torres Toro Jorge Rafael

C.I.: 28.232.437

Tutor(a):

Prof. Mayerlin Maldonado

San Diego, mayo de 2022



UNIVERSIDAD JOSÉ ANTONIO PÁEZ  
COORDINACIÓN DE PASANTÍA Y TRABAJO DE GRADO

**ACTA DE APROBACIÓN**

INFORME FINAL DE PASANTÍA

TRABAJO DE GRADO

El jurado designado por la Facultad de Ingeniería para la evaluación del Informe Final de Pasantía o Trabajo de Grado titulado:

Desarrollo de un Modelo Deep Learning para la Automatización de los Procesos de Detección de Tumores Cerebrales.

Realizado por el (la) Br. Jorge Rafael Torres Toro

C.I. N° 28.232.437 cursante de la carrera de Computación

hace constar después de analizar su contenido y oída la exposición oral,

considera que el Informe Final o Trabajo de Grado ha obtenido la calificación de:

APROBADO

NO APROBADO

El Jurado

[Signature]

Tutor Académico (Coordinador)

Nombre:

C.I.:

[Signature]  
[Signature]  
11810356

[Signature]

Jurado

Nombre:

C.I.:

Juan Alexander Perez  
11520441

Jurado

Nombre:

C.I.:

[Signature]  
Milbet Rodríguez  
7996228

Fecha 10/10/2022.

[Signature]



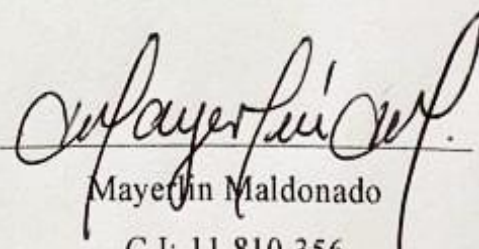


REPÚBLICA BOLIVARIANA DE VENEZUELA  
UNIVERSIDAD JOSÉ ANTONIO PÁEZ  
FACULTAD DE INGENIERÍA  
ESCUELA DE COMPUTACIÓN

**CONSTANCIA DE APROBACIÓN PARA LA PRESENTACIÓN  
PÚBLICA DEL TRABAJO DE GRADO**

Quien suscribe, **MAYERLIN MALDONADO**, portador de la cédula de identidad N° **11.810.356**, en mi carácter de tutor del trabajo de grado presentado por el ciudadano **TORRES TORO JORGE RAFAEL**, portador de la cédula de identidad N° **28.232.437**, titulado **DESARROLLO DE UN MODELO DE DEEP LEARNING PARA LA AUTOMATIZACIÓN DE LOS PROCESOS DE DETECCIÓN DE TUMORES CEREBRALES**, presentado como requisito parcial para optar al título de **INGENIERO DE COMPUTACIÓN**, considero que dicho trabajo reúne los requisitos y méritos suficientes para ser sometido a la presentación pública y evaluación por parte del jurado examinador que se designe.

En San Diego, a los 15 días del mes de Septiembre del año dos mil veintidós.

  
Mayerlin Maldonado  
C.I: 11.810.356

UNIVERSIDAD JOSÉ ANTONIO PÁEZ  
FACULTAD DE INGENIERÍA  
DECANATO DE INGENIERÍA



FI C 002 2022-2CR TG

Valencia, 10 de junio de 2022

Ciudadano:  
TORRES TORO, JORGE RAFAEL  
28.232.437  
Presente -

Cumplo con informarle que la comisión de Trabajo de Grado y Pasantías de la Facultad de Ingeniería en su reunión N° 7-2022 de fecha 13/05/2022 aprobó el proyecto de grado titulado:

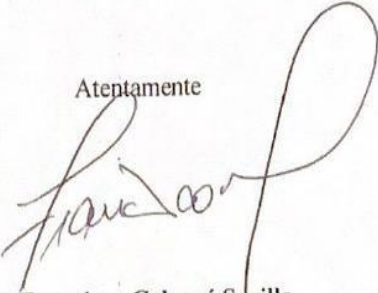
**Desarrollo de un modelo Deep Learning para la automatización de los procesos de detección de Tumores Cerebrales**

Presentado por usted como requisito para optar al título de Ingeniero en Computación.

Se ratifica la designación del Tutor Académico que lo asesorará en el desarrollo de este proyecto a:  
Ing. Mayerlin del Carmen Maldonado Velásquez, titular de la cédula de identidad V-11.810.356



Atentamente

  
**Dr. Francisco Gelanzé Sevilla.**  
Decano de Ingeniería

c.c. Coordinación de Pasantías y Trabajo de Grado

## ÍNDICE GENERAL

<b>CONTENIDO</b>	<b>pp.</b>
LISTA DE CUADROS.....	ix
LISTA DE FIGURAS.....	x
LISTA DE GRÁFICOS.....	xi
LISTA DE TABLAS.....	xii
RESUMEN INFORMATIVO.....	xiii
INTRODUCCIÓN.....	1
<b>CAPÍTULO</b>	
<b>I EL PROBLEMA</b>	
1.1 Planteamiento del Problema.....	3
1.2 Formulación del Problema.....	8
1.3 Objetivos de la Investigación.....	8
1.3.1 Objetivo General.....	8
1.3.2 Objetivos Específicos.....	8
1.4 Justificación.....	8
1.5 Alcance y Limitaciones.....	10
<b>II MARCO TEÓRICO</b>	
2.1 Antecedentes.....	11
2.2 Bases Teóricas.....	14
2.2.1. Deep Learning.....	14
2.2.2. Redes Neuronales Convolucionales.....	15
2.2.3. RESNET (Red Residual).....	17
2.2.4. Aprendizaje por Transferencia.....	18
2.2.5. Segmentación de Imágenes.....	19
2.2.6. RESUNET.....	20
2.2.7. Mascaras.....	21

2.3 Bases Legales.....	22
2.3.1. Artículo 108 y 110 de la Constitución de la República Bolivariana de Venezuela.....	22
2.3.2. Artículos 1° de la Ley de Telecomunicaciones y 5° de la Ley Orgánica de la Administración Central.....	23
2.3.3. Decreto con Fuerza de Ley Orgánica de Ciencia, Tecnología e Innovación.....	23
2.4 Definición de Términos.....	24
2.5 Cuadro de Operacionalización de Variables.....	26
<b>III MARCO METODOLÓGICO</b>	
3.1 Tipo de Investigación.....	28
3.2 Diseño de la Investigación.....	29
3.3 Nivel de la investigación.....	30
3.4. Población y muestra.....	30
3.5. Técnicas e instrumentos de recolección de datos.....	32
3.5.1. Técnicas de recolección de datos.....	32
3.5.2. Instrumentos de recolección de datos.....	33
3.6. Validez del Instrumento.....	34
3.7. Confiabilidad del Instrumento.....	34
3.8. Fases Metodológicas.....	35
<b>IV RECURSOS</b>	
4.1 Recursos Humanos.....	39
4.2 Recursos Institucionales.....	39
4.3 Recursos Materiales.....	39
REFERENCIAS.....	41

## LISTA DE CUADROS

CUADRO	DESCRIPCIÓN	pp.
1	Pasos para transferir estrategias No. 1 de entrenamiento de aprendizaje.....	19
2	Pasos para transferir estrategias No. 2 de entrenamiento de aprendizaje.....	19
3	Cuadro de Operacionalización de Variables.....	26
4	Cronograma de actividades 2022.....	40

## LISTA DE FIGURAS

FIGURA	DESCRIPCIÓN	pp.
1	Estimación de los tumores más frecuentemente diagnosticados en el mundo. Estimación para el año 2018, ambos sexos.....	4
2	Representación de una RNC.....	16
3	Ejemplo de cómo, de una subregión, la función max-pooling obtiene el valor máximo.....	22

## LISTA DE GRAFICOS

GRAFICO	DESCRIPCIÓN	pp.
1	Incidencia a nivel mundial del cáncer cerebral en la población masculina.....	5
2	Incidencia a nivel mundial del cáncer cerebral en la población femenina.....	5
3	Uso de la IA en el sector de Salud.....	37

## LISTA DE TABLAS

### DESCRIPCIÓN

TABLA		pp.
1	Contribución estimada de la IA al mundo en 2030.....	9
2	Clasificación de los métodos de segmentación de imágenes médicas.....	20



**REPÚBLICA BOLIVARIANA DE VENEZUELA  
UNIVERSIDAD JOSÉ ANTONIO PÁEZ  
FACULTAD DE INGENIERÍA  
ESCUELA DE INGENIERÍA EN COMPUTACIÓN**

## **DESARROLLO DE UN MODELO DE DEEP LEARNING PARA LA AUTOMATIZACIÓN DE LOS PROCESOS DE DETECCIÓN DE TUMORES CEREBRALES**

Autor: Torres Toro Jorge Rafael.

C.I.: 28.232.437

Tutor (a): Prof. Mayerlin Maldonado

**Fecha:** Mayo 2022

### **RESUMEN INFORMATIVO**

La presente investigación plantea el desarrollo de un modelo de deep learning para la automatización de los procesos de detección de tumores cerebrales, se empleará un enfoque predominantemente cuantitativo que será contrastado con el enfoque cualitativo provisto por el médico especialista. Para el desarrollo del trabajo teórico se utilizarán fuentes bibliográficas como artículos científicos, libros y tratados médicos sobre temas relacionados y que representen un aporte para la investigación. La investigación a efectuar también será de campo ya que para el desarrollo del sistema se requiere interacción con profesionales en el área que provean las imágenes, doten del criterio médico pertinente y de parámetros significativos reales que permitan ir corrigiendo errores en los resultados del diagnóstico previo mediante la manipulación de datos que mejore la precisión del sistema. Se realizará una investigación descriptiva, porque se observa y se describe el fenómeno. El cuestionario estará estructurado en tres partes, la primera engloba el impacto sobre el usuario acerca del desarrollo de un modelo de deep learning para la automatización y optimización de los procesos de detección de tumores cerebrales en un hospital; la segunda corresponde a el impacto sobre el entorno y; la tercera se refiere a el impacto sobre el manejo de la información.

**Descriptor:** Deep Learning, Red Neuronal, Aprendizaje por Transferencia.

## INTRODUCCIÓN

La inteligencia artificial está revolucionando las ciencias de la salud y la medicina en áreas como la detección temprana de enfermedades, las imágenes médicas, la cirugía con robots o maximizar la eficacia dentro de un hospital. Las ciencias de la salud o la medicina en general son un mercado que se espera que alcance los 45.000 millones de dólares en 2026 ya que, actualmente está valuado en más de 4.000 millones de dólares, es decir, multiplicar por 10 su valor actual en apenas 6 años. El mundo del Deep Learning está demostrando ser superior en la detección de enfermedades a partir de rayos-X y resonancias magnéticas, lo cual significa que pueden diagnosticarse enfermedades rápidamente y de forma más precisa que como lo haría un doctor.

El presente trabajo de investigación se enfoca en buscar, acelerar y mejorar la velocidad y la precisión con la que se detectan y localizan tumores malignos a través de resonancias magnéticas del cerebro y ayudar en la detección temprana de tumores, lo cual haría que la calidad de vida de las personas mejorara significativamente. Para ello, se realizarán encuestas en clínicas y hospitales para lograr recolectar información detallada que ayude con la elaboración y ejecución del proyecto investigativo. Seguidamente, se entrenarán 2 tipos de modelos, uno será capaz de detectar si el tumor existe o no existe, por lo tanto, servirá de primer filtro a partir de las resonancias magnéticas.

En el caso de que salten las alarmas en la primera red neuronal, la imagen será suministrada a una segunda red, la cual estará basada en un modelo con arquitectura RESUNET para localizar exactamente y segmentar la imagen con la región a la que corresponde la presencia de ese tumor. A su vez, se procederá a construir y crear un modelo de segmentación, anteriormente mencionado RESUNET que sea capaz de encontrar exactamente el tumor en las imágenes. Por consiguiente, se podrán aplicar técnicas y acelerar rápidamente el proceso de entrenamiento, ya que, se evaluará en particular la eficacia de nuestro clasificador de resonancias magnéticas y la red neuronal RESUNET para saber qué tan bien lo hace.

Finalmente, se aplicarán a su vez, técnicas de Deep Convolutional Neural Network, por lo tanto, se utilizarán la API de Keras y de Tensor Flow. La investigación consta de 4 capítulos, cuyo contenido se presentan a continuación. Capítulo I: El problema, formulación del problema, objetivos de la investigación, objetivo general y específicos, justificación y alcances. Capítulo II: comprende los antecedentes de la investigación, las bases teóricas, las bases legales y la definición de términos básicos. Capítulo III: es el marco metodológico, el cual está formado por; el tipo de investigación, diseño de investigación, nivel de investigación, población y muestra, técnicas e instrumentos de recolección de datos, fases del estudio y análisis de datos. Capítulo IV: corresponde a los recursos: Humanos, Materiales, Económicos y Financieros, además del Cronograma de Actividades.

# **CAPÍTULO I**


## **EL PROBLEMA**

### **1.1 Planteamiento del Problema.**

El cáncer, según la Organización Mundial de la Salud (OMS), es un proceso incontrolado de crecimiento y de diseminación de células. Esta alteración tiene la capacidad de aparecer prácticamente en cualquier lugar del cuerpo e invadir el tejido circundante o los vasos linfáticos y/o hemáticos provocando el crecimiento de un tumor en puntos distantes del organismo, lo que se conoce como metástasis. Hoy en día se registran más de 200 tipos de cáncer donde se diferencian en 23 grupos según su localización. Cada uno de ellos tiene unas propiedades distintas que los categoriza como enfermedades independientes.

Existen dos tipos de factores de riesgo que han demostrado estar asociados con un mayor crecimiento tumoral. Por un lado, están aquellos que se controlan como los malos hábitos para la salud. Y, por otro lado, están los factores inevitables como son los artefactos del ADN, es decir, las mutaciones hereditarias. Evitar la exposición a estos factores de riesgo, en la medida de lo posible, podría conducir a una disminución de la incidencia y, por consiguiente, de la mortalidad. Es cierto que, una vez desarrollado el cáncer, si se detecta en fases tempranas, éste podría eliminarse empleando los tratamientos más comunes como la quimioterapia, la radioterapia y la cirugía.

Sin embargo, si el diagnóstico del cáncer tiene lugar en una fase avanzada, su tratamiento se complica. Este tipo de casos se asocia a un aumento de la morbilidad y de la mortalidad, además de a una menor esperanza de vida. Para determinar en qué fase se encuentra y poder hallar un tratamiento personalizado, es necesario llevar a cabo un análisis detallado a nivel tisular. Según las estadísticas recogidas por la Agencia Internacional para la Investigación del Cáncer (IARC), se prevé que dicha enfermedad aumente a nivel mundial más de un 60%, en términos de incidencia y mortalidad en los próximos 20 años (ver figura 1).

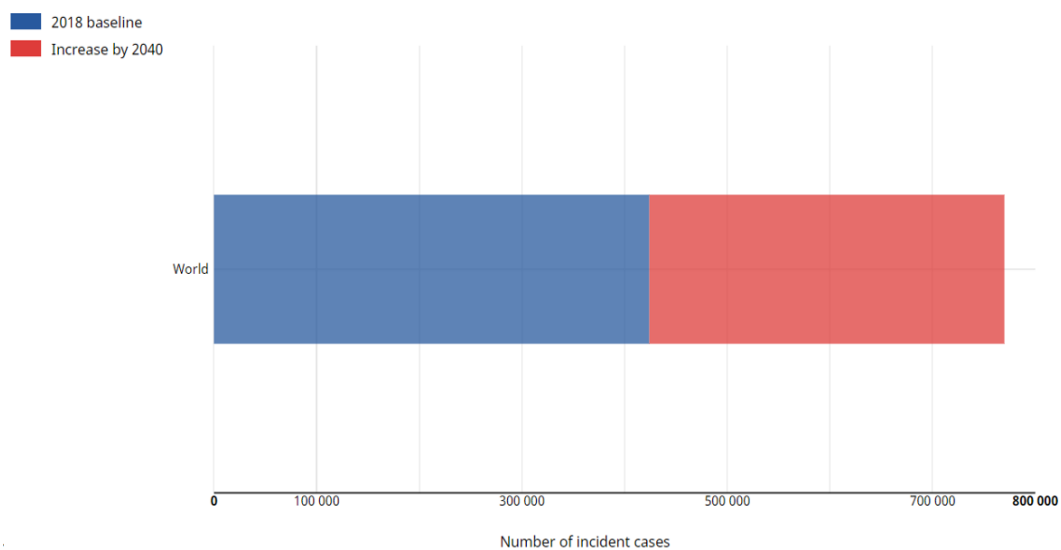


**Figura 1.** Estimación de los tumores más frecuentemente diagnosticados en el mundo. Estimación para el año 2018, ambos sexos.

Fuente: Sociedad Española de Oncología Médica (SEOM, 2020).

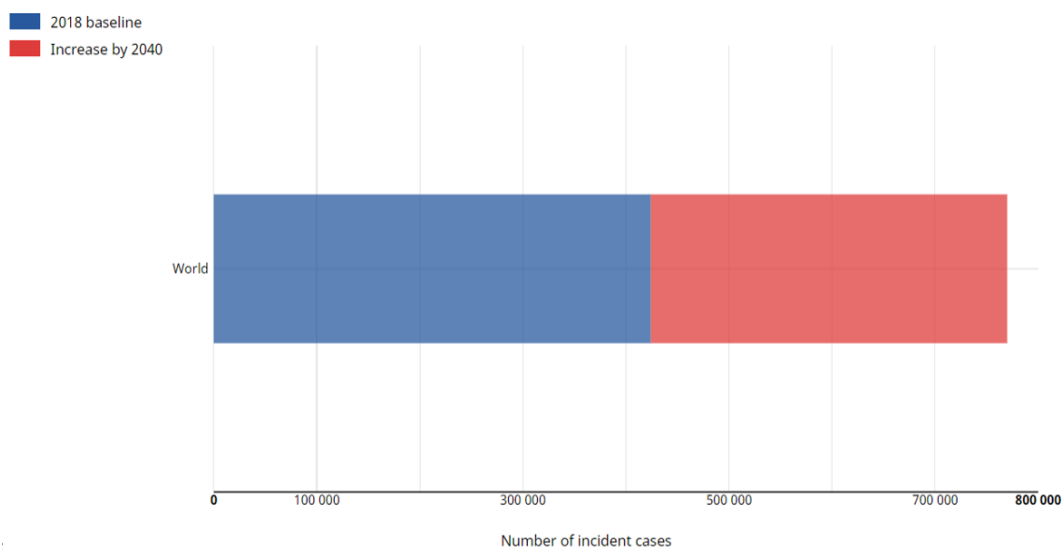
Los tumores cerebrales están directamente relacionados con el entorno laboral, como pueden ser las exposiciones ocupacionales (agentes químicos, pinturas, cuero y caucho), y también al hábito de fumar o el factor genético. Es por eso que hay una diferencia considerable entre los países desarrollados y subdesarrollados. Hasta hace unos años, se podría decir que había una gran diferencia en la incidencia entre hombres y mujeres. Sin embargo, desde que la población femenina consiguió incorporarse dentro del mundo laboral, se pudo observar que, debido a este desarrollo social, se prevé que el cáncer cerebral aumente considerablemente.

Existen factores de riesgo como la exposición a la radiación que pueden llegar a tener un efecto grave. Las personas que estuvieron expuestas a un tipo de radiación llamadas radiaciones ionizantes corren un mayor riesgo de padecer un tumor cerebral. Algunos ejemplos de radiación ionizante son la radioterapia usada para tratar el cáncer y la radiación causada por las bombas atómicas. También, existen antecedentes familiares de tumores cerebrales. Una pequeña cantidad de este tipo de tumores se presenta en personas con antecedentes familiares o con otros antecedentes de síndromes genéticos que aumentan el riesgo de padecer tumores cerebrales (ver gráficos 1 y 2).



**Gráfica 1.** Incidencia a nivel mundial del cáncer cerebral en la población masculina.

Fuente: Global Cancer Observatory (GCO). Inf. téc. International Agency for Research on Cancer (2018).



**Gráfica 2.** Incidencia a nivel mundial del cáncer cerebral en la población femenina.

Fuente: Global Cancer Observatory (GCO). Inf. téc. International Agency for Research on Cancer (2018).

Esta es la razón por la que es necesaria la investigación y el desarrollo de sistemas de ayuda al diagnóstico para identificar el cáncer en sus fases iniciales, permitiendo así un diagnóstico precoz y, por ende, un tratamiento temprano que permita una disminución de la mortalidad. Por otra parte, uno de los principales problemas a nivel global es la falta de acceso a la atención médica. El Banco Mundial y la Organización Mundial de la Salud (OMS) publicaron un informe en 2017 en el cual afirman que el 50% de la población mundial no tiene acceso a los servicios de salud, adicionalmente crece el envejecimiento de la población y aumentan las enfermedades crónicas.

La población de América Latina y el Caribe (ALC) está envejeciendo a un ritmo acelerado. Según estimaciones de las Naciones Unidas, se proyecta que la población mayor de 60 años en la región pase de un nivel actual del 11% al 25% en un lapso de 35 años. Así mismo, señalaron que, en Venezuela, casi 45% de las personas tienen al menos una enfermedad crónica y se estima que este número sigue creciendo, por lo tanto, los pacientes con estas enfermedades y de edad avanzada requerirán cada vez más atención médica y seguimiento. Según los últimos datos de la OMS, el 75% de las muertes en América son atribuibles a enfermedades crónicas, un aumento de casi 20 puntos porcentuales con respecto a los datos de 1990.

También la OMS estipula que, el 80% de las decisiones médicas en el mundo desarrollado se toman con el apoyo de estudios de imágenes (Madrid, 2013). Por otro lado, en 2015, solamente en Estados Unidos, se han realizado 800 millones de exámenes de imágenes (IBM, 2018). Dichos exámenes generaron aproximadamente 60 billones de imágenes médicas. Estas serían cantidades imposibles de procesar en tiempo y forma, teniendo en cuenta que la cantidad de médicos especialistas en DPI es de 31.000. Si se quisieran analizar todas las imágenes, cada médico debería ver una cada dos segundos de trabajo, durante todas sus jornadas laborales (IBM, 2016).

Es por este motivo que se requiere implementar soluciones que garanticen al sistema de salud su sustentabilidad. Si bien la IA presenta muchos beneficios para el análisis de imágenes médicas, hay aspectos importantes a tener en cuenta.

El Dr. Daniel Luna considera que la IA no es algo que se va a dar de un momento para otro, sino que será un proceso que llevará un largo tiempo. El mismo no dependerá exclusivamente de los avances tecnológicos. “Todo el camino de transición en el uso de la IA se va a dar como un proceso de transformación. Y esa transformación no es tecnológica. Es la medicina la que tiene que transformar” El Dr. Daniel Luna agrega, además, que para que la IA en salud comience un camino de crecimiento sostenido, para así alcanzar el uso masivo, deberá pasar por una etapa más de enfriamiento (D. Luna, 2019).

Lamentablemente, esto no ayuda cuando hay pacientes que, sin saberlo, están “contra el reloj” y, siendo concretos, un diagnóstico preliminar oportuno podría marcar la diferencia entre un tratamiento pertinente o un desenlace fatal. El uso de la IA, ayuda con la planificación, el diagnóstico y el pronóstico de los pacientes, logrando que la atención médica sea más eficiente, ya que también permite el análisis remoto de resultados. Considerando este contexto, el presente trabajo muestra una solución informática para la automatización del reconocimiento de las patologías en las imágenes clínicas.

Si bien no sería un diagnóstico definitivo al no ser firmado por un médico, permitiría mitigar los tiempos asociados al proceso. Para lograr lo anterior, hemos visto en el Deep Learning, al igual que otros autores, una herramienta eficaz para la predicción y detección de diversas condiciones en los humanos. Por ejemplo, Ari e Hanbay (2018) exploraron la clasificación de imágenes cerebrales para la identificación de tumores cancerígenos utilizando ELM-LRF y, en un ámbito relacionado, Cao et al. (2017) trabajaron en la detección de tumores mamarios en imágenes de ultrasonido mediante aprendizaje profundo.

Sin perjuicio de lo anterior, el trabajo en esta materia es aún incipiente por lo que esta investigación es novedosa al incorporar simultáneamente dos patologías asociadas a problemas cerebrales. Además, en lo referente a la especialidad, las aplicaciones prácticas del Deep Learning son un foco interesante para desarrollo de soluciones bioinformáticas enfocadas en agilizar los procesos y a la contribución para salvar vidas. Es por ello que, en el trabajo de investigación surge la siguiente pregunta:

## **1.2 Formulación del Problema.**

Se ha demostrado que el aprendizaje profundo es superior en la detección de enfermedades a partir de rayos X, resonancias magnéticas y tomografías computarizadas, lo que podría mejorar significativamente la velocidad y precisión del diagnóstico, sin embargo, en concordancia con esto, nos surgió la siguiente interrogante:

- ¿De qué manera es posible mejorar la precisión de los resultados a la par de reducir los tiempos en diagnóstico por imágenes en el proceso de detección de tumores cerebrales?

## **1.3 Objetivos de la Investigación.**

### **1.3.1 Objetivo General.**

- Desarrollar un modelo de Deep Learning para la automatización de los procesos de detección de tumores cerebrales.

### **1.3.2 Objetivos Específicos.**

- Identificar los actores de los sistemas de salud, el impacto que supone la implementación de IA y de qué formas puede ser implementada.
- Determinar los requerimientos funcionales y no funcionales para desplegar el modelo de IA.
- Diseñar el modelo de Deep Learning, el diagnóstico por imágenes y los sistemas para la detección de enfermedades.
- Entrenar el modelo de clasificación para detectar tumores cerebrales.
- Evaluar la eficacia del modelo de clasificación entrenado.

## **1.4 Justificación.**

El uso de las capacidades de la IA ayuda a reducir la carga en el personal clínico, lo que tiene un alto impacto en una mayor dedicación al cuidado de los pacientes. Uno de los aspectos críticos para el éxito en la digitalización de la atención médica utilizando la IA y la telemedicina es contar con una infraestructura adecuada, para lo cual son esenciales las inversiones iniciales que deben establecerse, preferiblemente, en combinación con socios especialistas que permitan garantizar la compatibilidad en todos los sistemas. Una infraestructura de datos común podría ayudar a facilitar la capacitación y la implementación.

Además, para que la telemedicina y la IA tengan éxito en la práctica clínica, las regulaciones deben permitir el uso óptimo de un modelo que considere la cobertura de este tipo de atención, así como las licencias y responsabilidad médicas. Hay dos factores claves relacionados con la financiación que son importantes para asegurar un enfoque sostenible. El primero está relacionado con el proveedor médico, para quien debe haber un incentivo financiero para implementar la IA. El segundo tiene que ver con los pacientes, para quienes la telemedicina debe ser financieramente atractiva, y tener unos costos similares a la atención habitual.

La educación debe ser la base de cualquier enfoque de implementación de la telemedicina y la IA, tanto para el personal sanitario como para los pacientes. Se recomienda que todo el personal médico reciba formación sobre cómo utilizar las herramientas y el software de IA, además de capacitarse en la comunicación con los pacientes a través de un medio electrónico. De otro lado, la formación de los pacientes es necesaria para superar las barreras generacionales, culturales y educativas, especialmente para los mayores y hacer un uso más eficiente de estas herramientas. Finalmente, la protección de datos es esencial para la atención sanitaria en general y se vuelve más importante con los crecientes riesgos asociados a la atención digital (ver tabla 1).

**Tabla 1.** Contribución estimada de la IA al mundo en 2030.

<b>Región</b>	<b>Impacto de la IA al mundo</b>
China	44,6%
América del Norte	23,6%
Europa del Norte	11,5%
Asia Desarrollada	5,7%
Europa del Sur	4,5%
América Latina	3,2%
Resto del Mundo	7,6%
<b>Total</b>	<b>100%</b>

Fuente: The macroeconomic impact of the artificial intelligence (PWC, 2018).

Un enfoque estandarizado para evaluar los riesgos de las plataformas mejora el uso y la confianza en estos sistemas. Para eso, las regulaciones deben orientarse a minimizar los riesgos, y los gobiernos deben promover la transparencia de los datos para evitar sesgos discriminatorios al utilizar algoritmos de IA. Por consiguiente, estos factores desempeñarán un papel fundamental en la atención sanitaria, dado que la pandemia de Covid-19 ha acelerado la implementación de la telemedicina, una tendencia que se espera crezca continuamente en los próximos años.

### **1.5 Alcance y Limitaciones.**

Uno de los temas que se podrán alcanzar en el presente trabajo investigativo es el aprendizaje por transferencia, el cual es una técnica de aprendizaje automático en la que una red que ha sido entrenada para realizar una tarea específica se reutiliza como punto de partida para otra tarea similar.

El aprendizaje por transferencia se usa ampliamente ya que partir de modelos previamente entrenados puede reducir drásticamente el tiempo de cálculo requerido si el entrenamiento se realiza desde cero. Algunas ventajas de este es que proporciona un progreso de entrenamiento rápido, no tiene que empezar desde cero utilizando pesos inicializados aleatoriamente, también se puede utilizar un pequeño conjunto de datos de entrenamiento para lograr resultados increíbles.

Otro de los temas que se podrán observar es la segmentación de imágenes, cuyo objetivo es comprender y extraer información de las imágenes a nivel de píxel, la segmentación de imágenes se puede utilizar para el reconocimiento y la localización de objetos, lo que ofrece un valor tremendo en muchas aplicaciones, como imágenes médicas y automóviles autónomos, etc. Lo que se quiere lograr con la segmentación de imágenes es entrenar una red neuronal para producir una máscara de píxeles de la imagen. Las técnicas modernas de segmentación de imágenes se basan en un enfoque de aprendizaje profundo que hace uso de arquitecturas comunes como RNC, RCT (redes de convolución total) y codificadores-decodificadores profundos.

## CAPÍTULO II

### MARCO TEÓRICO

En esta etapa de la investigación se busca un sistema coordinado y coherente de conceptos y proposiciones que permitan abordar el problema en su contexto teórico a fin de situarlo dentro de un conjunto de conocimientos, orientado a la búsqueda y ofrezca una conceptualización adecuada de los términos que se utilizaran en el trabajo. Constituye un aspecto de mucha importancia dentro de la investigación. En términos generales, representa la “explicación” teórica para comprender la naturaleza del hecho investigado. Por otra parte, se analizan y exponen teorías, investigaciones, leyes y antecedentes consideradas válidas y confiables, en dónde se organiza y conceptualiza el estudio. En apoyo a estos argumentos, Sabino (2002) señala que:

“El Marco Teórico, tiene un propósito: dar a la investigación un sistema coordinado y coherente de conceptos y proposiciones que permitan abordar el problema, es decir, se trata de integrar el problema dentro de un ámbito donde éste cobre sentido, incorporando los conocimientos previos referentes al mismo y ordenándolos de modo tal que resulten útiles en nuestra tarea (p. 47).”

#### **2.1 Antecedentes.**

Los antecedentes de la investigación son indagaciones previas que sustentan el estudio sobre el mismo problema o se relacionan con otros, sirviendo de guía al investigador. En la búsqueda y recolección de información sobre investigaciones que hayan sido realizadas con anterioridad y relacionados con el tema de estudio, se ubicaron algunos que serán detalladas a continuación, que sirven de apoyo para el desarrollo de la investigación. Así mismo, Plata (2006), señala que los antecedentes de una investigación:

“Se refieren a los estudios previos y tesis de grado relacionadas con el problema planteado, es decir, investigaciones realizadas anteriormente y que guardan alguna vinculación con el problema en estudio. En este punto se deben señalar, además de los autores y el año en que se realizaron los estudios, los objetivos y principales hallazgos de los mismos (p. 43).”

Barrientos, Ortiz, Vera y Escalona (2021), en su trabajo titulado “**Deep Learning aplicado para la detección de hemorragias y tumores cerebrales**” realizado en la Universidad Finis Terrae, Providencia, Chile, para optar al título de Ingeniero en Sistema tuvo como objetivo construir un modelo de deep learning para la predicción de imágenes cerebrales que permitía obtener un diagnóstico previo, pero no definitivo, en virtud de disminuir el tiempo del proceso. Con el modelo definitivo, los resultados superaron el 80% de precisión en las predicciones y descubrieron que separar patologías (hemorragias y tumores) fue crucial para el resultado. El aporte más significativo de este trabajo consistió en que ofrece una fundamentación teórica y metodológica sobre herramientas y formas de la investigación de datos dentro del Deep Learning.

Por otra parte, Leivi (2019), en su trabajo titulado “**Análisis de la implementación de Machine Learning en el diagnóstico por imágenes**” realizado en la Universidad de San Andres, Argentina, para optar al título de Maestría en Gestión de Servicios Tecnológicos y de Telecomunicaciones tuvo por objetivo realizar un análisis de los principales beneficios asociados a la implementación de Machine Learning en el Diagnóstico por Imágenes. El aporte más significativo con la presente investigación son las fuentes entre la que se destaca abundante bibliografía, una serie de entrevistas realizadas a expertos, la observación del trabajo del profesional y la concurrencia a eventos.

Seguidamente, Sáenz, Hoyos y Arias (2018), en su trabajo titulado “**Detección de tumores cerebrales, a partir de neuroimágenes, utilizando una técnica computacional híbrida**” realizado en la Universidad Simón Bolívar, Venezuela, para optar al título de Ingeniero en Sistemas se desarrolló una interface gráfica de usuario (GUI) que puede ser útil en la detección automática de tumores cerebrales considerando imágenes tridimensionales de tomografía computarizada. El aporte más significativo con la investigación es el proceso de diseño, implementación, entonación y validación de algoritmos computacionales que permitirán abordar los problemas de ruido, artefactos y bajo contraste que exhiben las imágenes.

Así mismo, Oliveros (2018), en su trabajo titulado “**Procesamiento de Imágenes Diagnósticas para la Detección de Anomalías Mamarias**” realizado en la Universidad Rafael Beloso Chacín, Venezuela, para optar al grado de Magister Scientiarum en Ingeniería de Control y Automatización de Proceso cuyo objetivo fue proponer un sistema procesamiento de imágenes diagnósticas para la detección de anomalías mamarias, se reforzó el planteamiento de la investigación con las teorías de los autores: Benloch, Narváez, Merello, Bordils, Chavarría, Camargo, Morales Graffigna y otros (2012). El tipo de investigación fue definida como descriptiva, y el diseño de la misma se determinó de tipo no experimental.

La unidad de análisis del presente estudio se basó en el sistema de procesamiento de imágenes diagnósticas mamográficas. Los resultados obtenidos de la investigación permitieron concluir que en las clínicas privadas más allá de una simple relación entre los sistemas inteligentes existe una vinculación entre estos dos elementos que generan desafíos permanentes en los retos que deben enfrentar mencionadas organizaciones. Su aporte a mi investigación es la metodología empleada en el proceso de realización de dicho sistema en donde buscan la participación de todos los médicos ecografistas y de los pacientes atendidos.

Finalmente, Guerra & Rivas (2018), en su trabajo titulado “**Detección de microcalcificaciones en imágenes mamográficas usando redes neuronales**” realizado en la Universidad de Carabobo, Venezuela, para optar al título de Ingeniería de Computación describió el desarrollo de un software que tuvo como objetivo principal constituir el proceso de detección de microcalcificaciones, a través del estudio de imágenes mamográficas. El software trabaja a partir de una mamografía digitalizada, la cual es procesada para ingresarla como dato de entrada a una Red Neuronal Artificial (RNA) del tipo perceptrón multicapas; ésta se encarga de detectar si la imagen presenta microcalcificaciones.

La efectividad alcanzada en la evaluación del software fue de 94.4% de aciertos en su predicción, mostrando así el potencial de la aplicación de ambas técnicas para el abordaje del problema planteado. La aportación para importante para mi investigación es el sistema automatizado que utilizaron al momento de detección de dichas enfermedades.

## **2.2 Bases Teóricas.**

Las bases teóricas son el punto importante de la investigación, mediante su elaboración se realiza un análisis de todos los puntos que afectan el estudio, es decir, los aspectos generales del tema, comprendiendo un conjunto de conceptos y proposiciones que constituyen un punto de vista o enfoque determinado, dirigido a explicar el fenómeno o problema planteado y a su vez sustentan la investigación con los aportes de distintos autores para una sustentación a nivel científico. Una buena base teórica formará la plataforma sobre la cual se construye el análisis de los resultados obtenidos en el trabajo, sin ella no se puede analizar los resultados.

En toda investigación es necesario una fundamentación teórica o documental, es por ello que se llega a este punto de la estructura metodológica para darle credibilidad a dicho estudio, de allí pues que Tamayo y Tamayo, M (2004), describe las bases teóricas como “la parte de la investigación que amplía la descripción del problema, integrada la teoría con la investigación y sus relaciones mutuas “. (p.96). Cuando se hace énfasis en un tema determinado es necesario tener una base que sustente dicho tema, Según Arias, F (2004), las bases teóricas son: “Un conjunto de conceptos y proposiciones que constituyen un punto de vista o enfoque determinado, dirigido a explicar el fenómeno o problema planteado.” (p.41).

### **2.2.1 Deep Learning.**

Deep learning es un subcampo del aprendizaje automático (machine learning), el cual se concentra en el aprendizaje mediante capas sucesivas de representación. El concepto de profundidad (depth), no hace referencia a la profundidad del entendimiento obtenido, sino a la cantidad de capas o niveles de representación que contribuyen a la red (Chollet, 2017). Adicionalmente, el deep learning está basado en el algoritmo de las redes neuronales, las cuales, bajo distintas arquitecturas, han demostrado tener un buen rendimiento en campos como visión por computadora, reconocimiento de voz, procesamiento de lenguaje natural, entre otros.

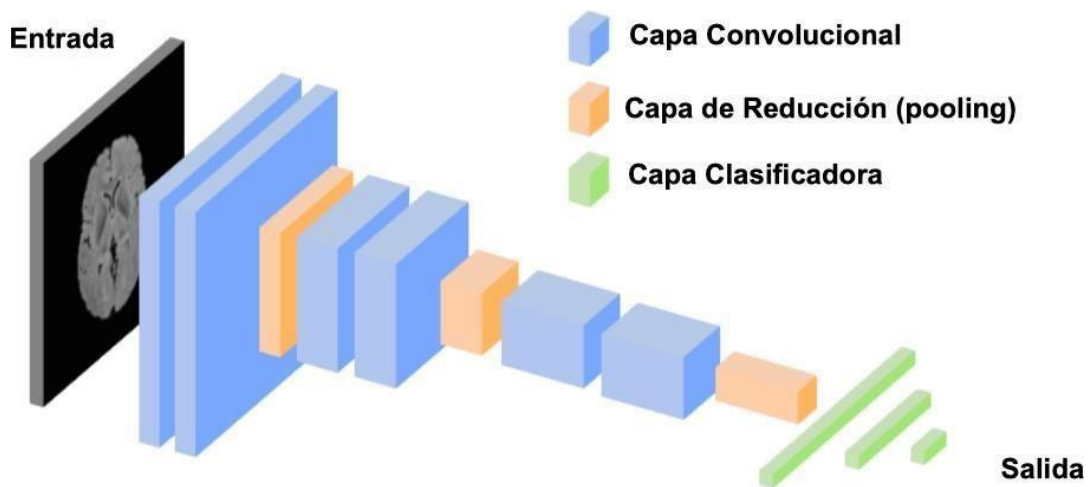
Una definición formal fue introducida por McCulloch e Pitts (1943) aunque utilizaremos la definición más moderna mostrada por Petersen & Voigtlaender (2018). En consecuencia, y aunque se utiliza una función arbitraria (conocida como función de activación), popularmente se utilizan las funciones adoptadas del escrito de Petersen, Raslan, e Voigtlaender (2020) como son ReLU, parametric ReLU y Sigmoid, entre otras. En pocas palabras, el adjetivo “deep” en deep learning se refiere al uso de múltiples capas, esto es cuando el número  $L$  en la representación anterior es grande, donde cada una de estas extrae una representación de alto nivel de las características intrínsecas en la data.

Para hacer esto, la transformación implementada por una capa es parametrizada por sus pesos donde entendemos como aprendizaje el hecho de obtener un conjunto de pesos para todas las capas de la red, de tal manera que dicha red podrá mapear ejemplos (entradas) a sus “targets” asociados. Para poder realizar esta tarea, se debe medir la diferencia entre las salidas obtenidas y las esperadas, dicha diferencia se alcanza mediante la función de pérdida o “loss function” en inglés. La función de pérdida toma las predicciones de la red y los targets esperados y calcula un valor de distancia entre éstos. Finalmente, este valor es utilizado para ajustar los pesos de las capas con el fin de disminuir el valor conseguido por la función de pérdida.

### **2.2.2 Redes Neuronales Convolucionales.**

Las Redes neuronales convolucionales son un tipo de redes neuronales artificiales donde las neuronas corresponden a campos receptivos de una manera muy similar a las neuronas en la corteza visual primaria de un cerebro biológico. Este tipo de red es una variación de un perceptrón multicapa, sin embargo, debido a que su aplicación es realizada en matrices bidimensionales, son muy efectivas para tareas de visión artificial, como en la clasificación y segmentación de imágenes. Aunque no es la única arquitectura, la Red Neuronal Convolutiva (en adelante, RNC) es la arquitectura más utilizada dentro de DL.

La misma, si bien hereda las propiedades de las RN, posee sus características específicas (López Briega, 2016). Las RNC poseen una estructura que consta de tres tipos de capas: convolucional, de reducción (también conocida como pooling) y clasificadora. El trabajo realizado por Hubel y Wiesel en 1959 jugó un papel importante en la comprensión sobre cómo funciona la corteza visual, particularmente las células responsables de la selectividad de orientación y detección de bordes en los estímulos visuales dentro de la corteza visual primaria. Dos tipos de células se identificaron debido a que tenían campos receptivos alargados, con lo cual tienen una mejor respuesta a los estímulos visuales alargados como las líneas y los bordes (ver figura 2).



**Figura 2.** Representación de una RNC.

Fuente: Elaboración propia a partir de Mazurowksi (2018).

La capa convolucional es la capa que le da nombre a la arquitectura. La operación de convolución recibe, como entrada, la imagen a clasificar. Luego aplica sobre ella un filtro (también conocido como kernel), la cual devuelve como salida un mapa de características de la imagen original. De esta manera, se logra reducir el tamaño de los parámetros (López Briega, 2016). Por lo tanto, la convolución es tomar una pequeña forma de onda (el kernel) e ir pasándola por una imagen, secuencialmente. Es decir, ir realizando un barrido, e ir observando cuánto tiene la imagen analizada de la forma del kernel, en cada una de sus posiciones.

La capa de Reducción (pooling) es la capa que se ubica a continuación de la capa convolucional. Su objetivo es la reducción de dimensiones espaciales (ancho y alto) del volumen de entrada. El primero es que la reducción de tamaño genera una menor sobrecarga para realizar cálculos en las subsiguientes capas de la red. Por otro lado, también colabora para que no se genere una sobre adaptación de la red. La operación que suele utilizarse para esto es la de Max-pooling, la cual divide a la imagen de entrada en un conjunto de rectángulos. (López Briega, 2016). Finalmente, la capa Clasificadora, según Carlos Selmo:

“luego de que se itere una N cantidad de veces sobre la Capa Convolucional y la Capa de Reducción, se utiliza una capa completamente conectada. Generalmente se trata de un Perceptrón Multicapa, en la que cada pixel es considerado como una neurona separada, tal cual las RN convencionales. El objetivo de esta capa es realizar la clasificación de las extracciones que se han realizado en las capas convolucionales y de reducción” (C. Selmo, comunicación personal, 17 de junio de 2019).

### **2.2.3 RESNET (Red Residual).**

Una red neuronal residual conocida como “ResNet” es una renombrada red neuronal artificial. Se ensambla en construcciones obtenidas de las células de la pirámide de la corteza cerebral. Las redes neuronales residuales logran esto usando atajos o “conexiones de salto” para moverse sobre varias capas. Los expertos implementan modelos tradicionales de redes neuronales residuales con saltos de dos o tres capas que contienen normalización por lotes y no linealidad entre ellas. Los científicos de los datos también aprovechan una matriz de peso extra para aprender los pesos de los saltos en algunos casos.

El término utilizado para describir este fenómeno es “Redes de autopistas”. Una razón de peso para saltar capas es evitar los gradientes que se desvanecen y cuestiones similares. Como el gradiente se retropropaga a las capas anteriores, este proceso repetido puede hacer que el gradiente sea extremadamente pequeño. La mayoría de los individuos hacen esto utilizando las activaciones de las capas precedentes hasta que el adyacente aprende en pesos particulares. Estos pesos se ajustan a las capas anteriores y amplían la capa salteada anteriormente.

Los pesos utilizados para conectar las capas adyacentes entran en juego. Sin embargo, esto sólo funciona eficazmente cuando todas las capas intermedias son lineales o se superponen sobre la capa no lineal. Si no es así, la utilización de una matriz de pesos diferente sería útil para las conexiones salteadas. El salto elimina las complicaciones de la red, haciéndola más simple, usando muy pocas capas durante la etapa de entrenamiento inicial. Acelera el aprendizaje por diez veces, minimizando el efecto de la desaparición de los gradientes.

Después de esto, la red eventualmente vuelve a poner las capas hábiles mientras aprende el espacio de las características. A medida que el entrenamiento se acerca a su fin y cada capa se expande, se acercan al múltiple y aprenden cosas más rápidamente. Una red neuronal que no tiene partes residuales tiene más libertad para explorar el espacio de características, haciéndolo altamente peligroso para las perturbaciones, causando que salga del colector, y haciéndolo esencial para que los datos de entrenamiento extra se recuperen.

#### **2.2.4 Aprendizaje por Transferencia.**

El aprendizaje por transferencia es el proceso de entrenar un modelo en un conjunto de datos a gran escala y luego usar ese modelo previamente entrenado para llevar a cabo el aprendizaje para otra tarea posterior. Nos hemos vuelto muy buenos para predecir un resultado muy preciso con muy buenos modelos de entrenamiento. Pero debemos considerar que la mayoría de las tareas que realizamos con estos modelos no son nada generalistas, sino al contrario, son específicas de un solo objetivo o dominio. El mundo real no está encerrado en el conjunto de datos que entrenamos, sino que es algo mucho más extenso y desordenado, por lo tanto, ese modelo que hemos entrenado anteriormente si lo usamos para un objetivo más general con toda seguridad su eficacia descenderá notablemente. (ver cuadros 1 y 2) Aplicar el conocimiento de un modelo podría ayudar a reducir el tiempo de capacitación y los problemas de aprendizaje profundo al tomar los parámetros existentes para resolver problemas de datos “pequeños” (Calvo, 2020).

**Cuadro 1.** Pasos para transferir estrategias No. 1 de entrenamiento de aprendizaje.

<b>Estrategia No. 1:</b>	<b>Ventajas:</b>
Congelar los pesos de la red RNC entrenada de las primeras capas.	Proporciona un progreso de entrenamiento rápido, no tiene que empezar desde cero utilizando pesos inicializados aleatoriamente.
Entrenar solo las capas densas recién agregadas (con pesos inicializados aleatoriamente).	

Fuente: Torres (2022).

**Cuadro 2.** Pasos para transferir estrategias No. 2 de entrenamiento de aprendizaje.

<b>Estrategia No. 2:</b>	<b>Ventajas:</b>
Inicializar la red de RNC con los pesos previamente entrenados.	Se puede utilizar un pequeño conjunto de datos de entrenamiento para lograr resultados increíbles.
Volvemos a entrenar a toda la RNC mientras establece la tasa de aprendizaje para que sea muy pequeña, esto es fundamental para garantizar que no cambie agresivamente los pesos entrenados.	

Fuente: Torres (2022).

### **2.2.5 Segmentación de Imágenes.**

La segmentación de imágenes es una técnica de procesamiento que se refiere a la extracción de información útil de una escena para facilitar su observación y análisis, ya que el resto del contenido de una imagen puede estar contaminado o no ser útil para el propósito buscado. La segmentación de imágenes médicas enfrenta tres problemas principales vinculados a las imágenes: las imágenes contienen gran cantidad de ruido, lo cual dificulta la clasificación de píxeles por intensidad, la intensidad en los tejidos y órganos, no es uniforme, la segmentación se logra con diferentes métodos y combinación de los mismos.

Tomando como base, se distinguen tres generaciones en los métodos de segmentación para imágenes médicas. La primera generación está integrada por técnicas de bajo nivel, donde poco o nada de información a priori se incluye. La segunda generación, incorpora modelos de imagen, modelos de incertidumbre y métodos de optimización, a los algoritmos. Sin embargo, los resultados de la segmentación continúan siendo dependientes de los datos. La tercera generación, incluye conocimiento de más alto nivel en el algoritmo, durante el proceso de segmentación (ver tabla 2).

**Tabla 2.** Clasificación de los métodos de segmentación de imágenes médicas.

Generation	Category			
	Region-based	Boundary Following	Pixel Classification	
1st	Region Growing	Edge tracing	Threshold	
2nd	Deformable Models	Minimal Path	Statistical Pattern Recognition	
	Graph Search	Target Tracking	C-means Clustering	
		Graph Search	Neural Networks	Neural Networks
		Neural Networks	Multiresolution	Multiresolution
		Multiresolution		
3rd	Shape Models		Atlas-based	
	Appearance Models		Rule-based	
	Rule-based			
	Coupled Surfaces			

Fuente: Torres (2022).

### 2.2.6 RESUNET.


La arquitectura ResUNet combina la arquitectura de la red troncal UNet con bloques residuales para superar los problemas de desvanecimiento de gradientes en las arquitecturas profundas. La arquitectura de UNet se basa en redes totalmente convolucionales y se modifica de manera que funcione bien en las tareas de segmentación. Resunet consta de tres partes: codificador o ruta de contracción, cuello de botella y decodificador o ruta expansiva. La ruta de contracción (encoder) consta de varios bloques de contracción, cada bloque toma una entrada que pasa a través de resblocks seguido de una agrupación máxima de 2x2.

Los mapas de características después de cada bloque se duplican, lo que ayuda al modelo a aprender características complejas de manera efectiva. La ruta expansiva tiene una ventaja significativa de esta arquitectura, y es que radica en la sección de expansión o decodificador. Cada bloque toma la entrada muestreada de la capa anterior y se concatena con las características de salida correspondientes de los bloques res en la ruta de contracción. Esto luego se pasa nuevamente a través del bloque res seguido por capas de convolución de muestreo ascendente  $2 \times 2$ .

Esto ayuda a garantizar que las características aprendidas durante la contracción se utilicen al reconstruir la imagen. Finalmente, en la última capa de la ruta de expansión, la salida del bloque res pasa a través de la capa de convolución  $1 \times 1$  para producir la salida deseada con el mismo tamaño que la entrada. En conclusión, El bloque de cuello de botella sirve como conexión entre la ruta de contracción y la ruta de expansión. El bloque toma la entrada y luego pasa a través de un bloque res seguido de un muestreo de capas de convolución  $2 \times 2$ .

### **2.2.7 Mascaras.**

Según Briega, 2016. El objetivo de la segmentación de imágenes es comprender la imagen a nivel de píxel. Asocia cada píxel con una determinada clase. La salida producida por el modelo de segmentación de imágenes se denomina "máscara" de la imagen. Las máscaras se pueden representar asociando valores de píxeles con sus coordenadas. Por ejemplo, si tenemos una imagen negra de forma  $(2,2)$ , esta se puede representar como:  $[[0, 0], [0, 0]]$  Si nuestra máscara de salida es como sigue:  $[[255, 0], [0, 255]]$  Para representar esta máscara, primero debemos aplanar la imagen en una matriz 1-D. Esto resultaría en una máscara temporal similar a  $[255, 0, 0, 255]$ . Luego, podemos usar el índice para crear la máscara. Finalmente tendríamos algo como  $[1, 0, 0, 1]$  como nuestra máscara (ver figura 3).



**Figura 3.** Ejemplo de cómo, de una subregión, la función max-pooling obtiene el valor máximo.

Fuente: Briega (2016).

### 2.3 Bases Legales.

Palella y Stracruzzi (2017) indican que las bases legales "son las normativas jurídicas que sustenta el estudio desde la carta magna, las leyes orgánicas, las resoluciones decretos entre otros" (p.55). Es importante que se especifique el número de articulado correspondiente, así como una breve paráfrasis de su contenido a fin de relacionarlo con la investigación a desarrollar. Por otra parte, las bases legales son todas aquellas leyes las cuales deben guardar una relación con la investigación de estudio, los artículos deben ser copiados tal como son.

#### 2.3.1 Artículo 108 y 110 de la Constitución de la República Bolivariana de Venezuela.

Las bases legales de esta investigación se encuentran representadas, en primer lugar, en la Constitución de la República Bolivariana de Venezuela (1999), de donde se destaca el Artículo 108 y 110, capítulo IV cuando establece que: El conjunto de normas, así como los principios fundamentales por los que se debe regir el pueblo de la República Bolivariana de Venezuela.

**Artículo 108.** Los medios de comunicación social, públicos y privados, deben contribuir a la formación ciudadana: El Estado garantizará servicios públicos de radio, televisión y redes de bibliotecas y de informática, con el fin de permitir el acceso universal a la información. Los centros educativos deben incorporar el conocimiento y aplicación de las nuevas tecnologías, de sus innovaciones, según los requisitos que establezca la ley.

**Artículo 110.** El Estado reconocerá el interés público de la ciencia, la tecnología, el conocimiento, la innovación y sus aplicaciones y los servicios de información necesarios por ser instrumentos fundamentales para el desarrollo económico, social y político del país, así como para la seguridad y soberanía nacional. Lo anterior confirma la responsabilidad del estado de brindar los instrumentos necesarios para el desarrollo tecnológico de su nación.

### **2.3.2 Artículos 1º de la Ley de Telecomunicaciones y 5º de la Ley Orgánica de la Administración Central, en Consejo de Ministros.**

Asimismo, de conformidad con lo previsto en el artículo 110, en concordancia con lo dispuesto en los artículos 1º de la Ley de Telecomunicaciones y 5º de la Ley Orgánica de la Administración Central, en Consejo de Ministros. (mayo, 2000).

**Artículo 1º.** Se declara el acceso y el uso de internet como política prioritaria para el desarrollo cultural, económico, social y político de la República Bolivariana de Venezuela.

**Artículo 5º.** El ministerio de Educación, cultura y Deportes dictara las directrices tendentes a instruir sobre el uso de Internet, el comercio electrónico, la interrelación y la sociedad del conocimiento. Para la correcta implementación de lo indicado, deberán incluirse estos temas en los planes e mejoramiento profesional del magisterio. De allí, se declara el acceso y el uso de internet como política prioritaria para el desarrollo cultural, económico, social, y político de la República Bolivariana de Venezuela.

### **2.3.3 Decreto con Fuerza de Ley Orgánica de Ciencia, Tecnología e Innovación.**

Otro de los basamentos legales está representado en el Decreto con Fuerza de Ley Orgánica de Ciencia, Tecnología e Innovación (agosto 2005) nos refiere:

**Artículo 29º.** El Ministerio de Ciencia y Tecnología creará mecanismos de apoyo, promoción y difusión de invenciones e innovaciones populares, propiciando su transformación en procesos, sistemas o productos que generen beneficios a la población o logren un impacto económico o social.

**Artículo 56°.** El Ejecutivo Nacional estimulará la formación del talento humano especializado, a través del financiamiento total o parcial de sus estudios e investigaciones y de incentivos, tales como, premios, becas, subvenciones, o cualquier otro reconocimiento que sirva para impulsar la producción científica, tecnológica y de innovación.

**Artículo 57°.** El Ministerio de Ciencia y Tecnología impulsará la Carrera Nacional del Investigador, para lo cual se promoverán los instrumentos legales necesarios para su aplicación. En atención a lo establecido en los artículos, los lineamientos para impulsar el desarrollo del capital humano y de sus capacidades de creación, absorción y difusión de conocimientos y tecnologías, constituyendo el eje fundamental de los grandes procesos de cambios.

#### **2.4 Definición de Términos.**

La definición de términos básicos consiste en dar el significado preciso y según el contexto a los conceptos principales, expresiones o variables involucradas en el problema formulado. Según Tamayo (1993), la definición de términos básicos "es la aclaración del sentido en que se utilizan las palabras o conceptos empleados en la identificación y formulación del problema." (p. 78).

**Aprendizaje automático.** Se define como la capacidad de las computadoras de aprender y actuar como los humanos. Esto incluye el desarrollo de su aprendizaje en forma autónoma a lo largo del tiempo, proporcionándoles datos como interacciones del mundo real y otro tipo de observaciones.

**Aprendizaje profundo.** Es el resultado del trabajo de una red neuronal. A medida que las capas procesan los datos, más allá de entender qué es algo, la IA comienza a aprender el por qué. Hay diferentes ejemplos de aprendizaje profundo: la visión artificial es una aplicación de aprendizaje profundo que puede "entender" imágenes digitales.

**Aprendizaje reforzado.** Implica dar a la IA un objetivo que no está definido con una métrica específica, sino que se requiere encontrar una solución o mejorar la eficiencia. En lugar de encontrar una respuesta específica, la IA ejecutará varias hipótesis e informará los resultados para evaluar y ajustar las siguientes suposiciones.

**Aprendizaje supervisado.** En el modelo de IA se proporciona la respuesta correcta con anticipación: la IA conoce tanto la pregunta como la respuesta. Este método de preparación es el más común, porque define los modelos de pregunta y respuesta ofreciendo la mayor cantidad de datos.

**Aprendizaje sin supervisión.** Los modelos de IA pueden aprender por sí mismos, sin tener que alimentarles estructuras predefinidas. Utilizan capas y capas de información no estructurada, procesan los datos, establecen las relaciones existentes entre ellos y encuentran un patrón en los mismos.

**Red neuronal.** Con un diseño similar al sistema nervioso y al cerebro humanos, una red neuronal organiza las etapas de aprendizaje para dar a la IA la capacidad de resolver problemas complejos dividiéndolos en niveles de datos. Las redes neuronales aplican la táctica de la división en conjuntos de datos más pequeños para ir superando cada capa de su aprendizaje.

**Transferencia de aprendizaje.** Este término se refiere a cómo la IA puede almacenar el conocimiento adquirido al resolver un problema y utilizarlo luego para solucionar otra situación, distinta pero relacionada con el primer caso. Por ejemplo, si un modelo de IA aprende a reconocer automóviles, ese conocimiento le facilitará posteriormente el reconocimiento de otro tipo de vehículos, como pueden ser los camiones.

## 2.5 Cuadro de Operacionalización de Variables.

Objetivo de la Investigación:	Desarrollar un modelo de Deep Learning para la automatización de los procesos de detección de tumores cerebrales.			
Variables	Dimensiones	Indicadores / Criterios	Instrumento	Ítems
Variable Independiente:	Inferencia de contexto.	Impacto sobre el usuario.	Cuestionario	¿Padece usted alguna enfermedad cerebro-vascular?
		Impacto sobre el entorno.		¿Con frecuencia se realiza consultas, exámenes médicos e incluso el estudio de resonancias magnéticas?
Inferencia de contexto por predicción basado en la técnica de inteligencia artificial	Impacto sobre el manejo de la información.			¿Invierte mucho tiempo a la hora de la realización dichas consultas, exámenes médicos o resonancias magnéticas?
		¿Estaría dispuesto a esperar el tiempo necesario para obtener los resultados de dichos exámenes? ¿Sea de vida o muerte?		
		¿Se siente usted cómodo a la hora de ir a una clínica, hospital u otro instituto médico?		
		¿Cree usted conveniente la ejecución de este proyecto de investigación?		
		¿Considera que llevando a cabo dicho proyecto le ahorraría tiempo a la hora de la detección de este tipo de enfermedades?		
		¿Estaría usted seguro de los resultados obtenidos por dicho proyecto de investigación?		

Objetivo de la Investigación:	Desarrollar un modelo de Deep Learning para la automatización de los procesos de detección de tumores cerebrales.			
Variables	Dimensiones	Indicadores / Criterios	Instrumento	Ítems
Variable Independiente:  Sistema para reconocimiento de patrones de imágenes médicas.	Patrones de imágenes.	Modelos básicos para diferentes casos.	Revisión de fuentes bibliográficas técnicas y médicas.  Aplicación de software libre.	¿Qué patrones de imágenes se van a emplear?
	Segmentación de imágenes.	División del cerebro por partes.		¿Cómo se seccionarán por software las partes del cerebro para su análisis?
	Extracción de características.	Identificación de características relevantes para análisis.		¿Qué características facilitarán el diagnóstico previo?
	Clasificación y reconocimiento de tumores cerebrales.	Reconocimiento de trastornos cerebrales.		¿Qué parámetros se expondrán como parte del diagnóstico previo?
Variable Dependiente:  Diagnóstico previo en trastornos cerebrales.	Patologías Cerebrales.	Tumores Cerebrales.	Entrevista con un experto del área para adquirir un mejor criterio.	¿Es posible detectar a simple vista un tumor cerebral?
				¿Cuáles son las causas asociadas a los tumores cerebrales?
				¿Realmente se puede ayudar al sector sanitario con herramientas de este estilo sin sacrificar por supuesto la eficacia y sin poner la vida de las personas en juego?

**Cuadro 3.** Cuadro de Operacionalización de Variables Independientes.

Fuente: Torres (2022).

## CAPÍTULO III

### MARCO METODOLÓGICO

Balestrini (2006) define el marco metodológico como: La instancia referida a los métodos con los cuales una teoría y su método calculan las magnitudes de lo real. De allí que se deberán plantear el conjunto de operaciones y técnicas que se incorporan en el despliegue de la investigación en el proceso de la obtención de los datos. El fin esencial del marco metodológico es el de situar en el lenguaje de investigación los métodos e instrumentos que se emplearan en el trabajo planteado, hasta la codificación, análisis y presentación de los datos.

De esta manera se proporcionará al lector una información detallada sobre cómo se realizará la investigación (pp. 114). En el marco metodológico de la presente investigación, se especifica el procedimiento de cómo se solucionará el problema propuesto; de principio a fin. De esta forma se describe la metodología, el procedimiento y los tipos de muestras empleados para recaudar y disponer los datos indispensables para la culminación del trabajo de grado. Describirá el diseño de estudio en detalle, se determinará el ¿cómo? y ¿con qué? se realizará la actividad investigativa.

#### **3.1 Tipo de Investigación.**

Según la definición del Manual UPEL (2010) las investigaciones tecnicistas o proyectivas: Son investigaciones aplicadas que se encuentran dirigidas a encontrar soluciones a problemas prácticos o necesidades sentidas por un grupo, una institución u organización de orden social, educativo, económico, cultural u otra, a través de la elaboración de un plan, estrategia, programa, diseño o tecnología producto original o adaptado por el investigador. Cumplen con el ciclo planificación-producción-función. La presente investigación es un proyecto especial, que, según la definición son trabajos que conllevan a la creación de objetos tangibles, para ser usados como solución a problemas, intereses o necesidades demostradas.

### **3.2 Diseño de la Investigación.**

La investigación documental es, como su nombre indica, aquella que se realiza a partir de la información hallada en documentos de cualquier especie, como fuentes bibliográficas, hemerográficas o archivísticas. Por otra parte, cabe destacar que lo que se pretende con esta aproximación es, en palabras de Páez (2006), “asegurar condiciones para obtener la información para desarrollar las acciones que permitirán la búsqueda del conocimiento” (p. 255). Es un hecho que la investigación es parte fundamental en la construcción del conocimiento, de modo tal que deberá ser un proceso cuidadoso, ya que ordena las ideas y las centra en objetivos específicos.

Para el desarrollo del trabajo teórico se utilizarán fuentes bibliográficas como artículos científicos, libros y tratados médicos sobre temas relacionados y que representen un aporte para la investigación, también para efectuar el trabajo práctico relacionado con el procesamiento de las imágenes se emplearán libros y manuales sobre el software y librerías a utilizar, ya que a pesar de que la visión artificial se encuentra extendida en muchas áreas se requiere un estudio minucioso ya que es muy limitado en el tema seleccionado y se espera que los errores en el proyecto sean imperceptibles.

La investigación a efectuar también será de campo ya que para el desarrollo del sistema se requiere interacción con profesionales en el área que provean las imágenes, doten del criterio médico pertinente y de parámetros significativos reales que permitan ir corrigiendo errores en los resultados del diagnóstico previo mediante la manipulación de datos que mejore la precisión del sistema. Se empleará un enfoque predominantemente cuantitativo que será contrastado con el enfoque cualitativo provisto por el médico especialista; ya que mediante la recolección y análisis de datos empíricos de diversas fuentes sobre el tema a tratar y el desarrollo del sistema propuesto se podrá dar respuesta a cada una de las preguntas de investigación y comprobar la hipótesis planteada en base a los resultados obtenidos sin afectar de ninguna forma al fenómeno de estudio.

Por otra parte, Arias (2006), define la investigación de campo como aquella que consiste en la recolección de todos directamente de los sujetos investigados, o de la realidad donde ocurren los hechos (datos primarios), sin manipular o controlar variables alguna, es decir, el investigador obtiene la información, pero no altera las condiciones existentes. Claro está, en una investigación de campo también se emplea datos secundarios, sobre todo los provenientes de fuentes bibliográficas, a partir de los cuales se elabora el marco teórico. No obstante, son los datos primarios obtenidos a través del diseño de campo, lo esenciales para el logro de los objetivos y la solución del problema planteado.

### **3.3 Nivel de la Investigación.**

El presente trabajo se enmarca dentro de una metodología de investigación de tipo descriptivo, Arias (2006) afirma que “consiste en la caracterización de un hecho, fenómeno, individuo o grupo, con el fin de establecer su estructura o comportamiento”. Conociendo el nivel de investigación bajo el cual se rige este trabajo, se realizará una investigación descriptiva, porque se observa y se describe el fenómeno, que en este caso son la presencia de tumores cerebrales, con cada una de sus características basada en fundamentos cuantitativos efectuando control sobre el diagnóstico previo.

### **3.4 Población y Muestra.**

Según Arias (2006) se entiende por población “Un conjunto finito o infinito de elementos con características comunes para los cuales serán extensivas las conclusiones de la investigación. Esta queda delimitada por el problema y por los objetivos del estudio.” (p. 81). Por otra parte, Castro (2003) define la población infinita cuando el número de elementos que la forman es infinito, o tan grande que pudiesen considerarse infinitos. Como por ejemplo si se realizase un estudio sobre los productos que hay en el mercado. Hay tantos y de tantas calidades que esta población podría considerarse infinita. (p.75). A su vez, Arias (2006) define la muestra como un "subconjunto representativo de un universo o población. La muestra, "es una parte del todo que llamamos universo y que sirve para representarlo".

Para la presente investigación, la población estará definida por los métodos para reducir el tiempo, tanto de la creación de la red neuronal como del entrenamiento. Se utilizará el “Transfer Learning” para trasladar el conocimiento adquirido por una RN en un dataset a otro dataset, compuesto por información completamente diferente. Las RN entrenadas de esta manera pueden comportarse tan bien como si hubieran sido entrenadas en forma convencional. Otro método para reducir el tiempo es la técnica conocida como “data augmentation”. A través de la misma se puede agrandar el tamaño del dataset.

Esto se realiza aplicando transformaciones aleatorias a las imágenes, siempre manteniendo la lógica con el etiquetado ya hecho. Ejemplos de transformaciones que pueden ser realizadas son: rotar, agrandar y deformar. De esta forma se logra aumentar el tamaño del dataset del entrenamiento. El Dr. Enzo Ferrante considera que la técnica de data augmentation puede ser útil pero su alcance es limitado. “...es útil pero no supe la variabilidad real de los datos. Su alcance es limitado. Permite realizar cambios simples, como estirar la imagen, rotarla. Pero tiene un límite. Te pueden dar un 10% más de precisión. Pero nunca van a ser que un problema que no podías resolver lo vayas a poder resolver perfecto” (E Ferrante, 2019).

Para la muestra del proyecto investigativo se obtendrá la recolección de una gran cantidad de resonancias magnéticas del cerebro para el desarrollo de dicho modelo investigativo que pueda localizar dichos tumores. Se recolectará mediante un dataset, el cual servirá como base de datos, junto con la ubicación exacta de en qué parte del cerebro se halla el tumor en particular, que luego será contrastado con un médico especialista que corrobore dicha información para luego compararla con el presente proyecto y así obtener la mayor precisión.

Las imágenes se obtendrán desde “Kaggle: Brain MRI Images for Brain Tumor Detection” y desde el repositorio de imágenes médicas del “Cancer Imaging Archive: Brain-Tumor-Progression”. Procesamiento vía Data augmentation: Generar imágenes a partir de las conseguidas para tener un dataset mayor, mediante las técnicas de rotación, inversión, desplazamiento, corte y ampliación.

### **3.5 Técnicas e instrumentos de recolección de datos.**

Las técnicas de recolección de datos son definidas por Arias (2006 p. 146) como las distintas formas o maneras de obtener información. Para lograr los objetivos de la investigación se debe elegir la técnica y el instrumento de recolección de datos. Conscientes de esto, para efecto de esta investigación, las técnicas de recolección de datos utilizadas serán: La Observación directa, Revisión documental, y Revisión Bibliográfica.

#### **3.5.1 Técnicas de recolección de datos.**

**Revisión Documental.** La revisión documental permite identificar las investigaciones elaboradas con anterioridad, las autorías y sus discusiones. Según Hurtado (2008, p 427) La Revisión Documental Es una técnica en la cual se recurre a información escrita, ya sea bajo la toma de datos que pueden haber sido producto de mediciones hechas por otros o como texto que en sí mismo constituyen los eventos de estudio. Para esta investigación se aplicó la técnica de revisión documental, consultando textos asociados a la información, con el fin de obtener una base de conocimiento.

**Revisión Bibliográfica.** La revisión bibliográfica se ha definido como "la operación documental de recuperar un conjunto de documentos o referencias bibliográficas que se publican en el mundo sobre un tema, un autor, una publicación o un trabajo específico. Es una actividad de carácter retrospectivo que nos aporta información acotada a un periodo determinado de tiempo. Según GEOCITIES (2008) es un conjunto de técnicas, y estrategias que se emplean para localizar, identificar y acceder a documentos que sirvan para obtener información para la investigación.

**Observación Directa.** los autores Hernández, Fernández y Baptista (2006: 316), expresan que: "la observación directa consiste en el registro sistemático, válido y confiable de comportamientos o conducta manifiesta". A través de esta técnica el investigador puede observar y recoger datos mediante su propia observación. Por otra parte, Según Heinemann (2003) Se tiene un contacto directo con los elementos o caracteres en los cuales se presenta el fenómeno que se pretende investigar, y los resultados obtenidos se consideran datos estadísticos originales.

**Encuesta.** Según nos explica Hernández (2012). La encuesta por muestreo es la técnica más empleada en las investigaciones realizadas en las ciencias sociales. Se utiliza para recolectar información de personas respecto a características (estado civil, edad), opiniones (¿está realizando el actual presidente una buena labor?), creencias (¿hay vida después de la muerte?), expectativas (¿cree Ud. que la situación económica del país mejorará durante este año?), conocimiento (¿sabe Ud. cómo se trasmite el SIDA?), conducta actual (¿va Ud. a misa frecuentemente?) o conducta pasada (¿votó Ud. en la elección pasada?). (pág. 25).

**Entrevista.** Corbetta (2007) opina que es una conversación provocada por un entrevistador con un número considerable de sujetos elegidos según un plan determinado con una finalidad de tipo cognoscitivo. Siempre está guiada por el entrevistador, pero tendrá un esquema flexible no estándar. Para recoger la información que permita desarrollar el proyecto se efectuarán visitas a diferentes instituciones entre casas de salud, laboratorios particulares y empresas, con la finalidad de acceder a 15 imágenes cerebrales, seleccionadas adecuadamente con el apoyo de un especialista para que aporte en el conocimiento médico y se logre omitir errores en el diagnóstico que emita el sistema en cuanto a sus respectivos diagnósticos formales.

### **3.5.2 Instrumentos de recolección de datos.**

De acuerdo a lo expuesto por Tamayo y Tamayo (2007), el instrumento se define como una ayuda o una serie de elementos que el investigador construye con la finalidad de obtener información, facilitando así la medición de los mismos. Para Chávez (2007), “los instrumentos de investigación son los medios que utiliza el investigador para medir el comportamiento o atributo de la variable. Con el propósito de obtener la información necesaria, es muy importante definir con claridad las técnicas e instrumentos de recolección que se utilizaron, ya que estuvieron destinados a conocer las necesidades y así recolectar los datos de la realidad aplicados a la situación a estudiar, para su posterior análisis; con el fin de determinar las necesidades del objeto estudiado.

**Cuestionario.** El autor Tamayo y Tamayo (2008: 124), señala que “el cuestionario contiene los aspectos del fenómeno que se consideran esenciales; permite, además, aislar ciertos problemas que nos interesan principalmente”. El cuestionario estará estructurado en tres partes, la primera engloba el impacto sobre el usuario acerca del desarrollo de un modelo de deep learning para la automatización de los procesos de detección de tumores cerebrales en un hospital; la segunda corresponde a el impacto sobre el entorno y; la tercera se refiere a el impacto sobre el manejo de la información.

### **3.6 Validez del Instrumento.**

Con respecto a la validez del instrumento, Hernández, Fernández y Baptista (2006), señalan que, un instrumento (o técnica) es válido si mide lo que en realidad pretende medir. La validez es una condición de los resultados y no del instrumento en sí (p. 107). Además, la validez puede efectuarse a juicio de expertos; es decir, con personas de gran experiencia en investigación o largo tiempo de servicio y conocedores del área inherente al problema estudiado. Por lo tanto, para conseguir la validez de los instrumentos aplicados en el presente estudio, se consultará la opinión de tres (03) profesionales en el área de Metodología, con amplia experiencia en la elaboración de cuestionarios y entrevistas.

### **3.7 Confiabilidad del Instrumento.**

Los autores Hernández, Fernández y Baptista (2006: 248), afirman que: “existen diversos procedimientos para calcular la confiabilidad de un instrumento de medición. Todos utilizan fórmulas que producen coeficientes de confiabilidad. Estos coeficientes pueden oscilar entre 0 y 1”. Es importante señalar, que el coeficiente de 0 significa nula confiabilidad y 1 representa un máximo de confiabilidad (confiabilidad total). Para la presente investigación la confiabilidad de los instrumentos de medición se determinará mediante el método estadístico Alpha de Combrach, aplicado a los resultados obtenidos luego de la aplicación de los mismos. El alcanzar un resultado confiable y consistente significa que el instrumento de medición puede ser aplicado nuevamente al mismo sujeto y producir iguales resultados.

Para efectuar el análisis se ingresarán imágenes nuevas y de esta forma obtener el diagnóstico previo de las mismas. Una vez efectuada esta operación, se procederá con la confirmación de un médico especialista estableciendo el diagnóstico oficial, con el cual se verificará la funcionalidad del sistema desarrollado, contraponiendo los resultados arrojados por el sistema vs. el criterio del experto y se modificará lo necesario para reducir el error, permitiendo aceptar o rechazar la hipótesis planteada.

### **3.8 Fases metodológicas.**

Para alcanzar el objetivo principal de la investigación planteada, el cual es desarrollar un modelo de Deep Learning para la automatización y optimización de los procesos de detección de tumores cerebrales, para su implementación en hospitales, clínicas u otras empresas dirigidas al sector de la salud, enfocada principalmente a la reducción de costos a la hora de la detección de enfermedades y la reducción en el tiempo de diagnóstico. se deben tomar en cuenta 5 aspectos importantes para llevar a cabo la metodología, que a su vez definen cada fase de la misma y serán descritas a continuación:

#### **Fase I: Identificación de los actores de los sistemas de salud, el impacto que supone la implementación de IA y de qué formas puede ser implementada.**

Para el desarrollo de dicho sistema se observó que, las aplicaciones de IA en los sistemas de salud han sido bastante comunes desde hace un buen tiempo. En particular, los sistemas de aprendizaje automático, que pueden utilizar más información sobre pacientes y ser desarrollados a través del análisis algorítmico de miles de casos similares, tienen un gran potencial para producir recomendaciones de cuidado de la salud mucho más dirigidas y personalizadas. El gráfico detalla casos de uso potencial en diferentes áreas del ecosistema de la salud en los que la IA probablemente tendrá un impacto en el corto y mediano plazo (ver gráfico 3).



**Gráfico 3.** Uso de la IA en el sector de Salud.

Fuente: Torres (2022).

**Fase II: Determinación de los requerimientos funcionales y no funcionales para desplegar el modelo de IA.** Los requerimientos funcionales se determinaron de las declaraciones de los servicios que proveerá el sistema. Los problemas emergen después de un análisis profundo. Una vez que éstos se hayan descubierto en las diferentes revisiones o en las fases posteriores del ciclo de vida, se deben corregir en el documento de requerimientos. En cuanto a los requerimientos no funcionales surgirán de la necesidad del usuario, debido a las restricciones en el presupuesto, a las políticas de la organización, a la necesidad de interoperabilidad con otros sistemas de software o hardware o a factores externos como los reglamentos de seguridad, las políticas de privacidad, entre otros.

**Fase III: Diseño del modelo de Deep Learning, el diagnóstico por imágenes y los sistemas para la detección de enfermedades.** Se creará un modelo capaz de analizar las radiografías introducidas, generando las probabilidades obtenidas por un modelo desarrollado mediante técnicas de Deep Learning, y, mostrando gráficamente las partes de la imagen en las que los médicos deberían prestar especial atención. Una vez realizados estos benchmarks, procederemos a la creación y optimización de un modelo de detección de patologías de tumores cerebrales, empleando la base de datos del National Institute of Health, BrainX-Ray14 [Wang X. et al. 2017].

**Fase IV: Entrenamiento del modelo de clasificación para detectar tumores cerebrales.** Para ello, realizaremos un análisis inicial de los distintos frameworks y librerías de Deep Learning disponibles para entrenar nuestro modelo utilizando el lenguaje Python, seleccionando las opciones más prometedoras. Utilizando las tecnologías seleccionadas, se crearán benchmarks analizando los resultados y tiempos de entrenamiento tanto en CPUs como en GPUs.

**Fase V: Evaluación de la eficacia del modelo de clasificación entrenado.** Finalmente, se realizarán pruebas mediante casos reales, utilizando radiografías obtenidas a lo largo del año. Y se implementará la aplicación de apoyo médico, creando una interfaz sencilla que permita consultar los resultados obtenidos por el modelo y descargar los heatmaps resultantes para su posterior análisis.

## **CAPÍTULO IV**

### **RESULTADOS**

En este capítulo se presentan los resultados de la investigación obtenidos mediante el procesamiento, análisis e interpretación de los datos obtenidos, arrojados de la población en estudio. Dichos resultados fueron recabados mediante la utilización de varios instrumentos de recolección de datos (cuestionarios y entrevistas) los datos recabados por esta entrevista permitieron darle respuestas a los objetivos y a las variables planteadas en esta investigación, permitiendo así evaluar todos los parámetros e indicadores para darle respuesta y solución a los objetivos del proyecto de investigación.

#### **4.1 Fase I: Identificación de los actores de los sistemas de salud, el impacto que supone la implementación de IA y de qué formas puede ser implementada.**

Para arribar a los resultados obtenidos, se utilizó una metodología cuantitativa y cualitativa. Se realizó una triangulación entre las fuentes primarias y secundarias, entre la que se destaca abundante bibliografía, una serie de entrevistas realizadas a expertos, la observación del trabajo del profesional y la concurrencia a eventos. Posteriormente se realizó una investigación de los conceptos de IA, ML y DL, centrándose en sus arquitecturas utilizadas para el análisis de imágenes (RN y RNC). Finalmente, se detalló en qué etapas del proceso sanitario la IA puede aportar valor y cómo puede transferirse el mismo entre los actores del sistema en función de sus inversiones.

Por otra parte, para la realización del cuestionario anteriormente mencionado consistió en analizar y evaluar la pertinencia de cada ítem del instrumento, con el fin de realizar y juzgar los aspectos a su concordancia con los objetivos, las variables, las dimensiones y los indicadores de la investigación, así como la recolección de la misma.

Para la validación de dicho instrumento se utilizó el cálculo de coeficiente del alfa de Cronbach, el cual es un método de cálculo del coeficiente de fiabilidad, que identifica esta como consistencia interna. Se denomina así porque analiza hasta qué punto medidas parciales obtenidas con los diferentes ítems son “consistentes” entre sí y por tanto representativas del universo posible de ítems que podrían medir ese constructo. El coeficiente Alfa de Cronbach oscila entre el 0 y el 1. Cuanto más próximo esté a 1, más consistentes serán los ítems entre sí (y viceversa). Por otro lado, hay que tener en cuenta que, a mayor longitud del test, mayor será alfa ( $\alpha$ ).

**Tabla 3.** Cálculo de Alfa de Cronbach

Sujeto	Item		Item						Total
	1	Item 2	Item 3	4	Item 5	Item 6	Item 7	Item 8	
1	4	5	4	2	1	3	4	5	28
2	3	4	5	4	2	4	4	5	31
3	3	4	5	4	5	5	4	4	34
4	5	1	5	4	5	2	4	5	31
5	2	2	5	4	1	2	2	2	20
6	2	1	4	2	3	2	4	2	20
7	2	4	2	3	1	3	2	2	19
8	1	2	2	1	3	2	4	2	17
Varianza	1,4375	2,109375	1,5	1,25	2,484375	1,109375	0,75	1,984375	

Confiabilidad de Cronbach				Item	1	2	3	4	5
k	8	Vi	12,625	Escala	Muy en desacuerdo	En desacuerdo	Indeciso	De acuerdo	Muy de acuerdo
Vt	39	$\alpha$	0,77289377						

Fuente: Torres (2022).

De acuerdo a los resultados obtenidos en la tabla anterior (ver tabla 3), se pudo analizar y observar que dichos ítems son consistentes y confiables para la presente investigación, eso sí, no sirve por sí sola para conocer de una manera absoluta la calidad del análisis estadístico realizado, ni la de los datos sobre los que se trabaja.

Gracias a esto, se pudieron identificar ciertos actores como: Tecnológico, Normativo, Económico, Demográfico y Cultural. Esto indica que, por más que tengamos una tecnología de vanguardia como la IA, podría no haber una adaptación exitosa si la población no la acepta (factor demográfico y cultural), si no existen las normas adecuadas que pueden proteger al usuario y sus operadores (factor normativo), o si no hay una viabilidad económica que permita la sustentabilidad del modelo (factor económico). Cuando estos actores alcancen una madurez mínima es cuándo podremos considerar que la tecnología tendrá un impacto exitoso en la sociedad.

Por lo que una tecnología novedosa como la IA en la salud requiere de otros actores igual de importantes que funcionan como catalizadores para su implementación. Lo anterior indica la necesidad de la adaptación de una misma tecnología en diferentes tiempos y formas, de acuerdo a la sociedad y/o cultura en la que se realizaron dichas pruebas. Las sociedades desarrolladas tienden a realizar un esfuerzo más coordinado y generalmente de menor magnitud en comparación a una sociedad en desarrollo.

## **4.2 Fase II: Determinación de los requerimientos funcionales y no funcionales para desplegar el modelo de IA.**

### **4.2.1 Requerimientos Funcionales.**

- Registrarse/Iniciar sesión para médicos, pacientes o personal de cualquier instituto médico.
- Escanear imágenes de resonancias magnéticas para obtener resultados de detección y clasificación.
- Lista de institutos médicos de ciudades populares (Caracas, Valencia, Maracay, Barquisimeto) para referencia de pacientes.
- Formulario para completar los detalles del paciente y almacenar los resultados de detección.
- Imprimir resultados.

#### 4.2.2 Requerimientos No Funcionales.

- Debe ser un sistema fácil de usar.
- Obtener un informe instantáneo del diagnóstico.
- Modelos ligeros de aprendizaje automático y aprendizaje profundo.
- Proporcionar un soporte multiplataforma.

#### 4.3 Fase III: Diseño del modelo de Deep Learning, el diagnóstico por imágenes y los sistemas para la detección de enfermedades.

Para la construcción y diseño del modelo de Deep Learning se realizaron entrevistas previas con expertos en el área, para la correcta ejecución de dicho modelo y así evitar riesgos y baja eficacia al momento de desplegar el modelo de detección. Como primera entrevista se realizaron una serie de preguntas a varios expertos en el área computacional para obtener un concepto de segmentación de imágenes enfocado a la detección de tumores cerebrales además del procesamiento digital de imágenes, así como los conceptos básicos involucrados en este proceso. La entrevista se realizó al ingeniero Federico Milano quien es ingeniero en sistemas y especialista en procesamiento de imágenes médicas y cirugías asistidas por computadora.

**Tabla 4.** Entrevista en el área computacional.

<p><b>Pregunta 1:</b> ¿Qué patrones de imágenes se pueden emplear?</p>	<p><b>Respuesta:</b> “Para el caso de este proyecto de investigación se puede procesar digitalmente imágenes de resonancia magnética nuclear de pacientes con tumores cerebrales, con el fin principalmente, de diferenciar el tejido tumoral del resto de los tejidos.”</p>
--	--

<p><b>Pregunta 2:</b> ¿Como se seccionarán por software las partes del cerebro para su análisis?</p>	<p><b>Respuesta:</b> “Para ello se puede combinar la información de diferentes estudios de resonancia magnética: a saber, utilizaremos los resultados de esos estudios para entrenar una red neuronal que asocie a cada pixel de la imagen un determinado tipo de tejido, así podemos colorear cada píxel de la imagen, obteniéndose al final.”</p>
<p><b>Pregunta 3:</b> ¿Qué características facilitarían el diagnóstico previo?</p>	<p><b>Respuesta:</b> “Píxeles de espectroscopia coloreados de acuerdo a su clasificación bioquímica, el color rojo corresponde a tumor, el azul a edema y el verde a tejido sano.”</p>
<p><b>Pregunta 4:</b> ¿Qué parámetros se expondrán como parte del diagnóstico previo?</p>	<p><b>Respuesta:</b> “Básicamente tres parámetros, tejido tumoral, tejido sano y tejido edematizado o necrótico obteniéndose imágenes donde se puede claramente diferenciar la zona donde se encuentra la lesión del resto de los tejidos.”</p>

**Fuente:** Torres (2022)

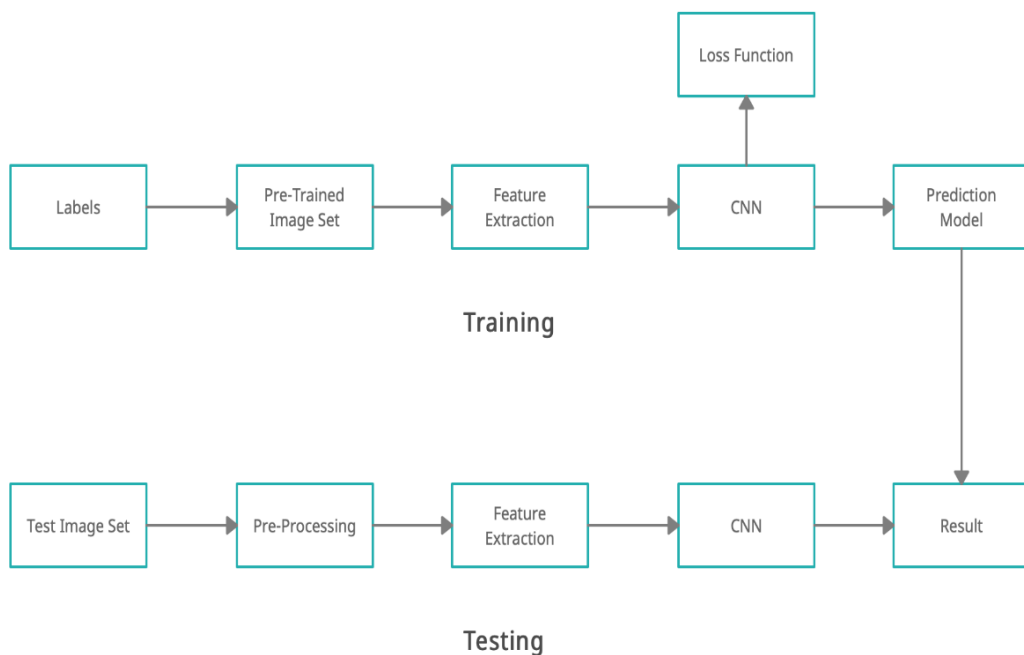
La siguiente entrevista se realiza al doctor Daniel Luna, quien es médico especialista en medicina interna y neurocirugía. Con el fin de obtener información médica, precisa y detallada acerca de los tumores cerebrales, sus características, causas, y el impacto que supone a la población.

**Tabla 5.** Entrevista en el área de la medicina.

<p><b>Pregunta 1:</b> ¿Es posible detectar a simple vista un tumor cerebral?</p>	<p><b>Respuesta 1:</b> “Las imágenes por resonancia magnética (MRI) y las tomografías computarizadas (CT) son utilizadas con más frecuencia para detectar las enfermedades del encéfalo. Si hay un tumor encefálico, estos estudios casi siempre lo mostrarán. También se obtiene una idea sobre el tipo de tumor que podría ser, basándose en cómo luce y dónde está localizado en el encéfalo.”</p>
<p><b>Pregunta 2:</b> ¿Cuáles son las causas asociadas a los tumores cerebrales?</p>	<p><b>Respuesta 2:</b> “Actualmente, no existen causas directas que expliquen la aparición de un tumor cerebral. Existen algunos tumores que pueden originarse de forma hereditaria o por inducción debida a agentes físicos.”</p>
<p><b>Pregunta 3:</b> ¿Realmente se puede ayudar al sector sanitario con herramientas de este estilo, sin sacrificar por supuesto la eficacia y sin poner la vida de las personas en juego?</p>	<p><b>Respuesta 3:</b> “El uso de la IA ayuda con el diagnóstico de los pacientes, esto hace que la atención médica sea más eficiente, pues no solo reduce costos, sino que también permite el análisis remoto de resultados, lo que redundará en una mejor distribución de los servicios de atención médica.”</p>

**Fuente:** Torres (2022)

De acuerdo a las entrevistas realizadas, se recopiló toda la información para el diseño de un diagrama de flujo, el cual detalla el comportamiento que obtendrá dicho modelo de detección. Para conseguir el principal objetivo del presente proyecto, tal y como se aprecia en el diagrama de flujo, el trabajo parte de una base de datos de imágenes que posteriormente se le aplica un preprocesado para la anotación y extracción de la región de interés, la creación de los bloques y el descarte de aquellos que no contienen información relevante. Una vez se tienen los bloques, se crea el groundtruth para cada uno de los bloques. Más adelante, se realiza una partición de datos para el entrenamiento de los modelos. Finalmente, se exponen los resultados y se comparan para evaluar su eficacia.



**Figura 4.** Diagrama de flujo correspondiente al diseño del modelo para la detección de enfermedades.

**Fuente:** Torres (2022)

#### **4.4.1 Obtención del dataset**

La obtención de las imágenes se consiguió desde “Kaggle: Brain MRI Images for Brain Tumor Detection” (<https://www.kaggle.com/navoneel/brain-mri-images-for-brain-tumordetection> recuperado el 12 julio de 2022) y desde el repositorio de imágenes médicas del “Cancer Imaging Archive: Brain-Tumor-Progression”. La estandarización de las imágenes se le aplicaron un redimensionamiento a un valor común de tamaño 320x320. Posteriormente se realizó un procesamiento vía data augmentation, con lo cual se generaron imágenes a partir de las conseguidas para tener un dataset mayor, mediante las técnicas de rotación, inversión, desplazamiento, corte y ampliación.

#### **4.4.2 Implementación de la Red Neuronal**

Se seleccionaron los parámetros iniciales para las pruebas de la red estableciendo una métrica simple determinada por el porcentaje de exactitud en las pruebas, para luego mejorar el modelo a través de uno o más ajustes en la cantidad de capas convolucionales, selección de optimizador y función de activación. Esta implementación fue evolucionando en cada nuevo prototipo en virtud de los resultados obtenidos en las pruebas.

#### **4.4.3 Análisis de Resultados y Ajustes a la Red**

Se analizaron los resultados derivados con la red creada y se definieron los ajustes pertinentes a los parámetros establecidos, con el objetivo de optimizar la red y poder obtener mejores porcentajes de precisión. Esto, en pocas palabras, contempló lo siguiente:

- Análisis de precisión con la muestra de prueba.
- Cambios en las capas de la red, estableciendo una o más opciones entre nuevas capas en la red, cambio de modelo, agregar capas convolucionales y/o capas de pooling o cambio de optimizador.
- Reentrenamiento de la red.

#### **4.4.4 Framework y Herramientas para la implementación de los Modelos**


Considerando el avance que ha tenido el Deep Learning y las herramientas disponibles, se decidió utilizar Tensorflow y la API de Keras para Python 3.10. Los motivos para esta elección se basan en la documentación abundante para las implementaciones y facilita la implementación de modelos y topologías complejas con pocas líneas de código (TensorFlow Core, 2020). Esto nos ayudó a enfocar los esfuerzos en el análisis y diseño por sobre la implementación. En el marco informativo del proyecto de investigación, las herramientas utilizadas para la codificación fueron: Sequential de keras.models, Conv2D, Maxpooling2D, Dense y Flatten de keras.layers, optimizers de keras y VGG16 de keras.applications.vgg16.

Respecto al Hardware utilizado, se trabajó con un equipo ad-hoc que consta de un procesador AMD Ryzen 5 3600X 6-Core con 16GB de Memoria RAM, una Unidad SSD de 480GB, una unidad de HDD para el almacenamiento de las imágenes con una capacidad de 1TB y una GPU NVIDIA GeForce RTX 2060. Lo anterior nos permitió autonomía de herramientas como Google Colab y manejar experimentos en un entorno controlado.

#### **4.4.5 Generalidades del experimento**

Considerando que la identificación de presencia (o ausencia) de hemorragias y tumores en imágenes de resonancias magnéticas de cerebro es “terreno de investigación incipiente”, como declaran Knoll et al. (2020); quienes realizaron un estudio sobre métodos de aprendizaje profundo para la reconstrucción de imágenes de resonancia magnética, se decidió comenzar con un modelo simple que fue mejorando en virtud de los resultados alcanzados. De esta manera, la red convolucional creada inicialmente para probar el funcionamiento con las imágenes obtenidas consistió en una red con 1 capa convolucional utilizando 32 filtros de dimensión (2,2), un stride con dimensión de 1,1 y una entrada con dimensión de 320,320,3.

Para la cual se empleó una función de activación ReLu, una capa flatten y una capa densa con 3 neuronas con función de activación Softmax. Realizar el diseño del modelo de preentrenamiento sirvió para identificar puntos de mejora y verificar la eficiencia del Hardware. Luego, se utilizaron dos capas convolucionales 2D con 32 filtros como un parámetro arbitrario para la identificación de resultados base, optimizador “Adam4” y “categorical crossentropy” como función de pérdida. El diseño general de la red anteriormente descrita se puede apreciar en la Figura 5 (ver figura 5). Sin embargo, después de realizar tres iteraciones se decidió explorar el Transfer Learning en virtud de optimizar el tiempo de entrenamiento para esta investigación.



**Figura 5.** Ilustración del diseño general de la red implementada.

Fuente: Torres (2022).

#### **4.4 Fase IV: Entrenamiento del modelo de clasificación para detectar tumores cerebrales.**

Como se mencionó anteriormente, la configuración inicial de red neuronal convolucional generada consistió en una capa de convolución utilizando 32 filtros de dimensiones 2x2, un stride de (1,1) para leer imágenes de 320,320 píxeles, unida a una capa flatten seguida de una capa densa, obteniendo un 28% de precisión en su validación después de 30 epochs. Decidimos mantener la cantidad de epochs para tener un factor constante en las diferentes experiencias. En total se realizaron nueve modelos donde los tres primeros corresponden a una red ad-hoc y los seis siguientes fueron realizados a partir del Transfer Learning de VGG16.

#### **4.4.1 Configuraciones previas al Transfer Learning**

Las siguientes arquitecturas exploradas fueron combinaciones de diferentes cantidades de capas convolucionales variando el número de filtros y de capas de max pooling, obteniendo que al utilizar 2 capas convolucionales con 32 filtros y 1 capa de pooling se consiguió un 30% de precisión. Dentro de las distintas combinaciones de capas convolucionales con 32 filtros y capas de pooling intercaladas entre las capas convoluciones, el mayor porcentaje de precisión fue de 34%. Posterior a estos resultados, se decidió por recomendaciones realizar pruebas con Transfer Learning.

#### **4.4.2 Configuraciones posteriores al Transfer Learning bajo optimizador Adam**


Con la utilización del transfer Learning empleando VGG16, sin reentrenamiento de sus capas, agregando una capa flatten y una capa densa que, al contar con 3 clases para clasificar imágenes sanas, hemorragias y tumores, se compuso con 3 neuronas, se logró conseguir un resultado de 30% de precisión. El VGG se cortó “justo antes” de la capa de salida de 1000 neuronas. De esta forma, al utilizar VGG16 se obtuvo un resultado del 32%. El notar que el aumento de la precisión fue bajo se pensó que estaría omitiéndose algo importante y, al ver el dataset, se sospechó que el problema podría estar en el optimizador. Esto porque Adam es un método de descenso de gradiente estocástico que se basa en la estimación adaptativa de momentos de primer y segundo orden y, en nuestro caso, las variaciones de magnitud parecían ser amplias.

#### **4.4.3 Configuraciones posteriores. El punto de quiebre: El optimizador**

Como parte del aprendizaje del proyecto se observó que las imágenes cerebrales cuentan con características particulares que harían muy probable la caída en un “punto silla”. Luego, el utilizar Adam como optimizador fue un error (como se indicó anteriormente) y se corrigió utilizando, en primera instancia, SGD para tener un punto de partida y/o comparación y luego cambiando a RMSprop (Keras, 2021).

En concordancia con lo anterior, se optó por el que entregó mayor precisión, el cual fue RMSprop, ya que bajo los mismos parámetros generó mejores resultados. Si bien tanto SGD como RMSprop son optimizadores basados en Gradiente Descendiente, RMSprop equilibra el tamaño del paso, disminuyéndolo para gradientes grandes y aumentando el paso para gradientes pequeños. Lo antes descrito se ajustaba al dataset ya que posee imágenes donde los gradientes pueden variar ampliamente en cuanto a sus magnitudes.

Dicho lo anterior, al utilizar el optimizador SDG se obtuvo un porcentaje de precisión del 70%, mientras que con el optimizador RMSprop fue alcanzado un porcentaje del 78%, bajo las mismas condiciones. Continuando con este optimizador y probando la red para el caso aislado de estudio exclusivo de imágenes de tumores, se consiguió un porcentaje de precisión del 85% y, para el caso del estudio de las imágenes de hemorragias, fue obtenido un porcentaje del 83%. En síntesis, se logró un modelo que clasificó en 4 posibles resultados: Glioma, Meningioma, Pituitario o Ninguno de los anteriores. La Figura 6 muestra los resultados derivados en las diferentes pruebas.




**Figura 6.** Porcentajes de precisión de los diferentes modelos.

**Fuente:** Torres (2022)

**Tabla 6:** Cuadro resumen de resultados.

**Fuente:** Torres (2022)



**Figura 7:** Matriz de confusión en la etapa de predicción.

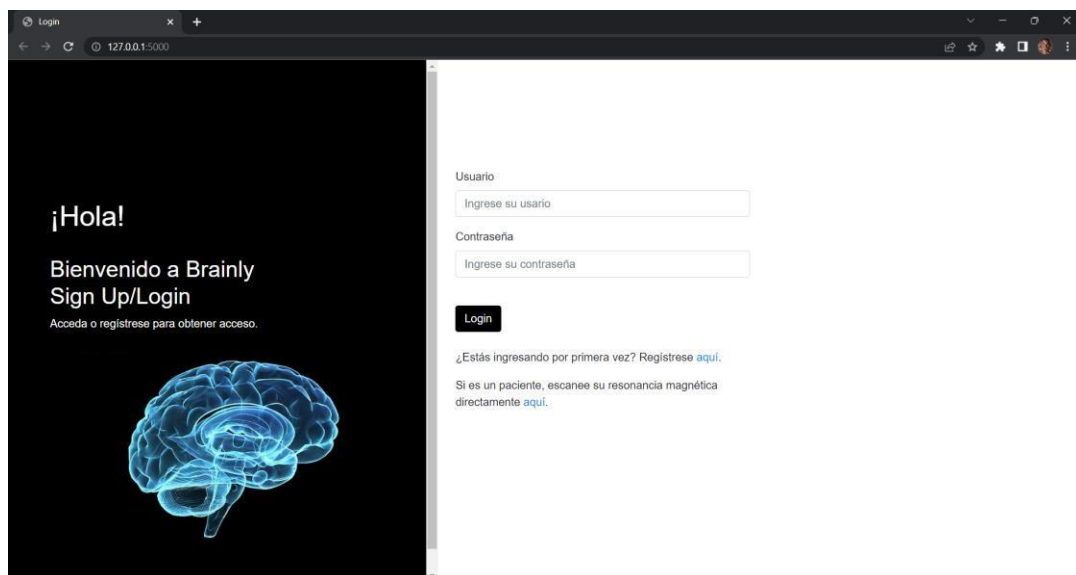
**Fuente:** Torres (2022)

#### 4.5 Fase V: Evaluación de la eficacia del modelo de clasificación entrenado.

Finalmente, en la fase final, se evalúa la eficacia del modelo previamente diseñado y entrenado para observar su comportamiento en pruebas mediante casos reales, utilizando radiografías obtenidas del dataset. Además, se implementó una aplicación de apoyo médico, creando una interfaz sencilla que permita consultar los resultados obtenidos por el modelo y descargar los heatmaps resultantes para su posterior análisis.

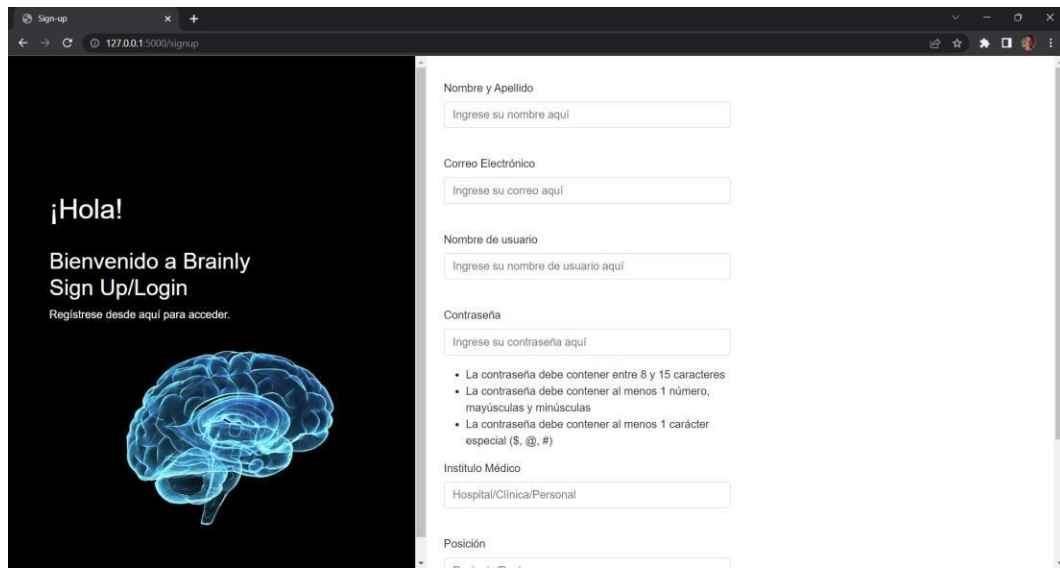
La aplicación web está diseñada bajo el lenguaje de Python (3.10) con el servidor de Flask, combinado con HTML, JavaScript y CSS, también se añaden componentes y librerías como Bootstrap, JQuery y una base de datos local en SQLite3. A través de la app web, se puede automatizar con precisión el proceso de detección de la presencia o no de un tumor cerebral en un paciente, a la vez que lo acompaña una interfaz de usuario fácil de usar (para el médico + paciente).

Si se detecta la presencia de un tumor, se clasifica en 'Glioma', 'Pituitaria' o 'Meningioma'. Esta técnica de detección automatizada conduce a una detección precisa, eficiente y rentable de tumores cerebrales al tiempo que alivia el cuello de botella del tiempo limitado de diagnóstico para los médicos.



**Figura 8:** Página de Inicio de Sesión.

**Fuente:** Torres (2022)



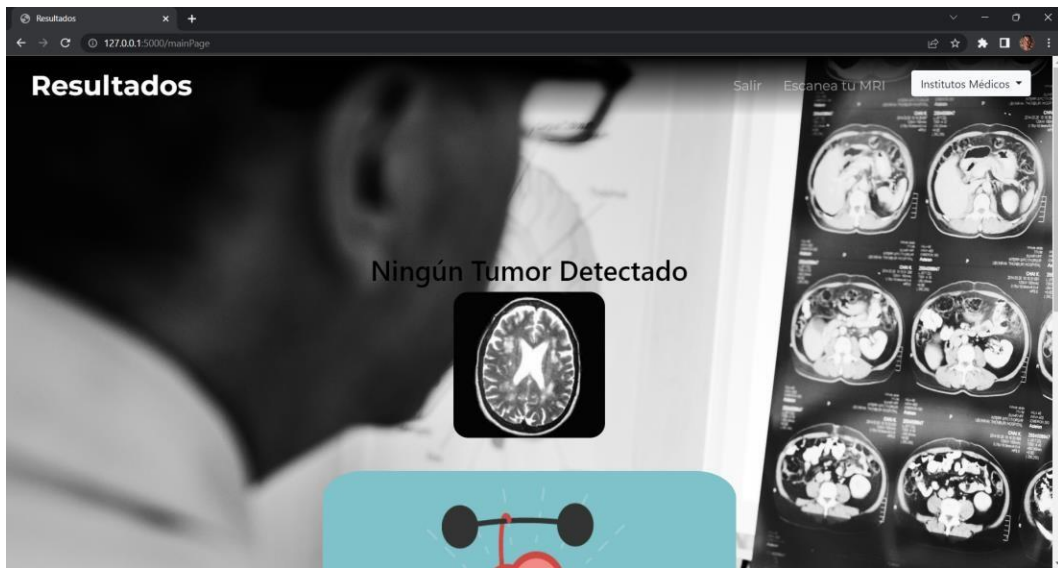
**Figura 9:** Página de Registro.

**Fuente:** Torres (2022)



**Figura 10:** Página de Inicio.

**Fuente:** Torres (2022)



**Figura 11:** Página de Resultados.

**Fuente:** Torres (2022)



**Figura 12:** Página de Institutos Médicos.

**Fuente:** Torres (2022)

The screenshot shows a web browser window with the URL '127.0.0.1:5000/form'. The page title is 'Información del Paciente'. At the top right, there are links for 'Ingresar', 'Escanea tu MRI', and a dropdown menu for 'Institutos Médicos'. The main content area has a teal header with the title 'Información del Paciente'. Below this, there are several input fields and radio buttons:

- Nombre y Apellido:** [Input field]
- Edad:** [Input field]
- Género:**
  - Hombre
  - Mujer
  - No Binario
- Resultados de detección:**
  - Tumor de glioma detectado
  - Tumor de meningioma detectado
  - Tumor pituitario detectado
  - Tumor no detectado
- Cualquier condición médica previa:** [Input field]
- Número Telefónico:** [Input field]
- Grupo Sanguíneo:** [Input field]
- Fecha:** [Input field with format 'dd/mm/aaaa' and a calendar icon]

At the bottom left, there are two buttons: 'Enviar' and 'Reiniciar'.

**Figura 13:** Página de Formulario.

Fuente: Torres (2022)

The screenshot shows a web browser window with the URL '127.0.0.1:5000/displayData'. The page title is 'Reporte'. The content displays the patient's information and the result of the MRI scan:

Nombre y Apellido:	Jorge Torres
Edad:	22
Género:	Hombre
Grupo Sanguíneo:	O+
Historial Médico:	Ninguna
Número de Teléfono:	+584244563270
Fecha:	2022-09-15
Resultado:	<b>Tumor no detectado</b>

Below the text, there is a square image of an axial MRI scan of a brain. Underneath the image is a button labeled 'Imprimir Reporte'.

**Figura 14:** Pagina de Reporte.

Fuente: Torres (2022)

## CAPÍTULO V

### CONCLUSIONES Y RECOMENDACIONES

#### 5.2 Conclusiones

Los resultados obtenidos muestran que la implementación de Deep Learning a través de transfer Learning para el reconocimiento de presencia de hemorragia y tumores cerebrales en imágenes de resonancia magnética del cerebro, tiene una gran capacidad para poder detectar la presencia de éstos al haber logrado valores sobre el 80% en los experimentos. Adicionalmente, es importante destacar que la experiencia de este trabajo pide poner mayor énfasis en un análisis de los dataset para detectar el optimizador más acorde para dicho grupo de imágenes puesto que, en esta oportunidad, los resultados obtenidos al momento de utilizar el optimizador Adam fueron muy inferiores a los que se lograron con el optimizador RMSprop.

Además, al analizar de manera independiente el funcionamiento de la red tanto para la detección de hemorragia como para los tumores, se alcanzaron valores de precisión mayores que para cuando la red es entrenada para la detección de ambos tipos de imágenes. Esto permite seguir explorando el trabajo de este documento a través de redes especializadas en una patología particular por sobre una sola red que intente “abarcarse más” resultados posibles.

#### 5.2 Recomendaciones

Sin perjuicio de lo anterior, es importante destacar que esta investigación aún posee puntos importantes a desarrollar por lo que, si bien es cierto que los resultados conseguidos pueden ser considerados eficientes en un ambiente controlado, en este caso se está estudiando la detección de dos afecciones cerebrales las cuales pueden comprometer severamente la vida de una persona.

Por esto, la precisión obtenida podría no ser adecuada para su uso en el actual campo médico como un “diagnóstico definitivo”, pero sí se puede considerar un apoyo para discriminar casos que, posiblemente, podrían ser importantes de ser examinados por un especialista antes que otros. En términos simples, priorizar. Además, consideramos que la precisión alcanzada puede ser mejorada mediante la obtención de un dataset más amplio que el utilizado durante este trabajo. Otro punto importante para el trabajo futuro está en la utilización de las imágenes sin modificar su tamaño y estudiar los efectos que esto podría llevar en cuanto a las predicciones en un entorno controlado.

En lo venidero, consideramos importante hacer pruebas en nuestras propias configuraciones (redes neuronales propias) para determinar si otros optimizadores podrían tener un mejor desempeño en este tipo de imágenes de manera de identificar o dar mayor sustento a nuestro “punto de quiebre”: El optimizador. Finalmente, podemos decir que este trabajo da un punto de partida para que futuras investigaciones puedan generar mayores niveles de precisión y con ello se pueda reducir el tiempo para diagnosticar casos críticos y agilizar el inicio de tratamientos vitales para los pacientes.

## REFERENCIAS BIBLIOGRÁFICA.

- Arias Fidias (2004). El proyecto de investigación. Introducción a la metodología científica 5ta edición [Documento en Línea]. Disponible: [https://es.scribd.com/doc/131137657/EL-PROYECTO-DE-  
INVESTIGACION-Fidias-Arias](https://es.scribd.com/doc/131137657/EL-PROYECTO-DE-INVESTIGACION-Fidias-Arias)
- Arias Fidias (2006). El proyecto de investigación. Introducción a la metodología científica 6ta edición [Documento en Línea]. Disponible: [https://www.researchgate.net/publication/301894369\\_EL\\_PROYECTO\\_  
DE\\_INVESTIGACION\\_6a\\_EDICION](https://www.researchgate.net/publication/301894369_EL_PROYECTO_DE_INVESTIGACION_6a_EDICION)
- Balestrini, M. (2006). Elaboración de un proyecto de grado. 6ta edición. [Documento en Línea]. Disponible: [https://drive.google.com/file/d/0B1sTcIvKGVsYt1FFa0JYMXFEejg/vie  
w?resourcekey=0-q-4eI4j8N4MSEkr7B1O9Vg](https://drive.google.com/file/d/0B1sTcIvKGVsYt1FFa0JYMXFEejg/view?resourcekey=0-q-4eI4j8N4MSEkr7B1O9Vg)
- Barrientos et al. (2021). Deep Learning aplicado para la detección de hemorragias y tumores cerebrales [Documento en Línea]. Disponible en, [https://repositorio.uft.cl/xmlui/bitstream/handle/20.500.12254/2227/Deep  
%20learning%20aplicado%20para%20la%20deteccio%CC%81n%20de  
%20hemorragias%20y%20tumores%20cerebrales.pdf?sequence=3&isAl  
lowed=y](https://repositorio.uft.cl/xmlui/bitstream/handle/20.500.12254/2227/Deep%20learning%20aplicado%20para%20la%20deteccio%CC%81n%20de%20hemorragias%20y%20tumores%20cerebrales.pdf?sequence=3&isAllowed=y)
- Calvo (2020). Aprendizaje por transferencia: NLP [Documento en Línea]. Disponible en, [https://www.europeanvalley.es/noticias/aprendizaje-por-  
transferencia-nlp/](https://www.europeanvalley.es/noticias/aprendizaje-por-transferencia-nlp/)
- Castro, M. (2003). El proyecto de investigación y su esquema de elaboración. (2ª Edición). Caracas: Uyapal. [Documento en Línea]. Disponible en, [http://investigacionmetodologicaderojas.blogspot.com/2017/09/poblacion  
-y-muestra.html](http://investigacionmetodologicaderojas.blogspot.com/2017/09/poblacion-y-muestra.html)
- Chávez, N. (2007). Introducción a la Investigación Educativa. 4ta Edición. Maracaibo, Venezuela. [Documento en Línea]. Disponible en, [https://www.unisinu.edu.co/wp-content/uploads/Libro-Procesos-de-  
Acompa%C3%B1amiento.pdf](https://www.unisinu.edu.co/wp-content/uploads/Libro-Procesos-de-Acompa%C3%B1amiento.pdf)

- Chiavenato (2008). Administración de Recursos Humanos, 5ta Edición. [Documento en Línea]. Disponible en, <http://www.untumbes.edu.pe/vcs/biblioteca/document/varioslibros/Administraci%C3%B3n%20de%20recursos%20humanos.%20Chiavenato.pdf>
- Chollet, F. (2017). Deep learning with python. Shelter Island, New York: Manning Publications. [Documento en Línea]. Disponible en, <https://brapci.inf.br/index.php/res/download/169547>
- De Cecco (2021) ¿Cómo puede la inteligencia artificial mejorar la salud de los latinoamericanos? Disponible en, <https://www.caf.com/es/conocimiento/visiones/2021/09/como-puede-la-inteligencia-artificial-mejorar-la-salud-de-los-latinoamericanos/#:~:text=S%C3%B3lo%20seis%20pa%C3%ADses%20de%20Am%C3%A9rica,o%20gastos%20en%20salud%20catastr%C3%B3ficos>
- Guerra y Rivas (2018) Detección de microcalcificaciones en imágenes mamográficas usando redes neuronales. [Documento en Línea]. Disponible en, [http://ve.scielo.org/scielo.php?script=sci\\_arttext&pid=S0798-40652011000300002](http://ve.scielo.org/scielo.php?script=sci_arttext&pid=S0798-40652011000300002)
- Heinemann (2003). Introducción a la Metodología de la Investigación Empírica en las Ciencias del Deporte. [Documento en Línea]. Disponible en, <https://seminariodemetodologiadelainvestigacion.files.wordpress.com/2011/06/introduccion-a-la-metodologia-de-la-investigacion-empirica-en-las-ciencias-del-deporte.pdf>
- Hernández, Fernández y Baptista (2006). Metodología de la Investigación. [Documento en Línea]. Disponible en, <https://metinvest.jimdofree.com/t%C3%A9nicas/>
- Hernández, O. (2012). Estadística Elemental para Ciencias Sociales. (Tercera Edición). San José, Costa Rica: Editorial Universidad de Costa Rica. [Documento en Línea]. Disponible en, <https://investigaliacr.com/investigacion/la-encuesta-y-el-cuestionario/>

- Hugo Cerda (1999). *Cómo se elabora un proyecto*. (2º edición). Caracas. Venezuela. [Documento en Línea]. Disponible en, <http://loimportantedeyasmin.blogspot.com/2008/10/proyecto-de-investigacin-y-ejecucin-etc.html>
- IBM. (2018). IBM Watson Imaging Patient Synopsis.
- IBM. (2016). Imagine your world with Watson. Treatment and differential diagnosis insights for the physician's consideration in the moments that matter most, 8. Retrieved from <https://www.ibm.com/blogs/watson-health/wp-content/uploads/2016/12/WHI-OverviewExecutive-Brief.pdf>
- Kawulich (2005) Observación Participante. [Documento en Línea]. Disponible: <https://www.buenastareas.com/ensayos/Observaci%C3%B3nParticipante/848775.html>
- Leivi (2019). Análisis de la implementación de Machine Learning en el diagnóstico por imágenes [Documento en Línea]. Disponible en, <https://repositorio.udesa.edu.ar/jspui/bitstream/10908/16748/1/%5BP%5D%5BW%5D%20T.%20M.%20Ges.%20Leivi,%20Alejo%20Ezequiel.pdf>
- López Briega, R. (2016). Redes neuronales convolucionales con TensorFlow. Recuperado de <https://relopezbriega.github.io/blog/2016/08/02/redes-neuronales-convolucionales-contensorflow/>
- Madrid, G. (2013). Iniciativas de Evaluación y Coste Efectividad en Radiología, 14(3), 359–361.
- Oliveros (2018) Procesamiento de Imágenes Diagnosticas Para la Detección de Anomalías Mamarias. [Documento en Línea]. Disponible en, <http://virtual.urbe.edu/tesispub/0102484/intro.pdf>
- Páez, I. (2006). Estrategias de aprendizaje -investigación documental. Laurus, Revista de Educación (12), 254-266.
- Palella y Stracruzzi (2017). Metodología de la Investigación. [Documento en Línea]. Disponible en, [https://metinvest.jimdofree.com/marco-te%C3%B3rico/#:~:text=Palella%20y%20Stracruzzi%20\(2017\)%20indic an,55](https://metinvest.jimdofree.com/marco-te%C3%B3rico/#:~:text=Palella%20y%20Stracruzzi%20(2017)%20indic an,55).

- Petersen, P., Raslan, M., & Voigtlaender, F. (2020). Topological properties of the set of functions generated by neural networks of fixed size. *Computing Research Repository*. Recuperado de <https://arxiv.org/abs/1806.08459>
- Petersen, P., & Voigtländer, F. (2018). Optimal approximation of piecewise smooth functions using deep relu neural networks. *Neural networks: the official journal of the International Neural Network Society* (108), 296–330. doi: 10.1016/j.neunet.2018.08.019
- Plata de Plata y Fernández (2006) Metodología de la Investigación. Universidad Rafael Bellosó Chachín. Maracaibo- Venezuela [Documento en Línea]. Disponible en, <https://virtual.urbe.edu/tesispub/0105842/conclu.pdf>
- Sabino (2002). El proceso de investigación. [Documento en Línea]. Disponible en: [http://paginas.ufm.edu/sabino/ingles/book/proceso\\_investigacion.pdf](http://paginas.ufm.edu/sabino/ingles/book/proceso_investigacion.pdf)
- Sáenz et al. (2018). Detección de tumores cerebrales, a partir de neuroimágenes, utilizando una técnica computacional híbrida [Documento en Línea]. Disponible en, <https://bonga.unisimon.edu.co/handle/20.500.12442/6482?show=full>
- Sampieri Hernández (2006). Metodología de la investigación 4ta edición [Documento en Línea]. Disponible: <http://187.191.86.244/rceis/registro/Metodolog%C3%ADa%20de%20la%20Investigaci%C3%B3n%20SAMPIERI.pdf>
- SAS Institute Inc. (2017) Deep Learning Qué es y por qué es importante [Documento en Línea]. Disponible en, [https://www.sas.com/es\\_ar/insights/analytics/deep-learning.html#:~:text=El%20deep%20learning%20es%20un,de%20im%C3%A1genes%20o%20hacer%20predicciones](https://www.sas.com/es_ar/insights/analytics/deep-learning.html#:~:text=El%20deep%20learning%20es%20un,de%20im%C3%A1genes%20o%20hacer%20predicciones)
- Tamayo y Tamayo, M. (2007) El proceso de la Investigación Científica. 4ta Edición [Documento en Línea]. Disponible: [https://www.academia.edu/17470765/EL\\_PROCESO\\_DE\\_INVESTIGACION\\_CIENTIFICA\\_MARIO\\_TAMAYO\\_Y\\_TAMAYO\\_1?auto=download](https://www.academia.edu/17470765/EL_PROCESO_DE_INVESTIGACION_CIENTIFICA_MARIO_TAMAYO_Y_TAMAYO_1?auto=download)

Tamayo y Tamayo, M. (2008) El proceso de la Investigación Científica. 5ta Edición  
[Documento en Línea]. Disponible:

<https://www.urbe.edu/UDWLibrary/InfoBook.do?id=32848>

UPEL (2010) Manual de Trabajo de Grados de especialización y Maestría y Tesis  
Doctorales. Documento en Línea. Disponible:

<http://tesisdeinvestig.blogspot.com/2011/07/proyectos-factibles-manual-upel.html>