

Escuela de Posgrado

MAESTRÍA EN CIENCIAS DE DATOS

Tesis

**Implementación de un modelo de clasificación y
detección de tumores cerebrales en imágenes de
RM, basado en técnicas de ciencia de datos**

Jerónimo Canahuirí Ayerbe
Jackson M'Coy Romero Plasencia
Ivan Velasquez Quintanilla

Para optar el Grado Académico de
Maestro en Ciencias de Datos

Huancayo, 2025

Repositorio Institucional Continental
Tesis digital



Esta obra está bajo una Licencia "Creative Commons Atribución 4.0 Internacional" .

ANEXO 6**INFORME DE CONFORMIDAD DE ORIGINALIDAD DEL
TRABAJO DE INVESTIGACIÓN**

A : Mg. Jaime Sobrados Tapia
: Director Académico de la Escuela de Posgrado

DE : **Kevin Rafael Palomino Pacheco**
: Asesor del Trabajo de Investigación

ASUNTO : Remito resultado de evaluación de originalidad de Trabajo de
Investigación

FECHA : 23 de febrero del 2025

Con sumo agrado me dirijo a vuestro despacho para saludarlo y en vista de haber sido designado Asesor del Trabajo de Investigación/Tesis/Artículo Científico titulado **"Implementación de un modelo de clasificación y detección de tumores cerebrales en imágenes de RM, basado en técnicas de ciencia de datos"**, perteneciente a los **Mg. Jackson M'coy Romero Plasencia, Bach. Jeronimo Canahuirí Ayerbe, y Bach. Ivan Velasquez Quintanilla**, de la **Maestría en ciencia de datos**; se procedió con el análisis del documento mediante la herramienta "Turnitin" y se realizó la verificación completa de las coincidencias resaltadas por el software, cuyo resultado es **9%** de similitud (informe adjunto) sin encontrarse hallazgos relacionados con plagio. Se utilizaron los siguientes filtros:

- Filtro de exclusión de bibliografía SÍ NO
- Filtro de exclusión de grupos de palabras menores (Máximo nº de palabras excluidas: < 40) SÍ NO
- Exclusión de fuente por trabajo anterior del mismo estudiante SÍ NO

En consecuencia, se determina que el trabajo de investigación constituye un documento original al presentar similitud de otros autores (citas) por debajo del porcentaje establecido por la Universidad.

Recae toda responsabilidad del contenido de la tesis sobre el autor y asesor, en concordancia a los principios de legalidad, presunción de veracidad y simplicidad, expresados en el Reglamento del Registro Nacional de Trabajos de Investigación para optar grados académicos y títulos profesionales – RENATI y en la Directiva 003-2016-R/UC.

Esperando la atención a la presente, me despido sin otro particular y sea propicia la ocasión para renovar las muestras de mi especial consideración.

Atentamente,



Kevin Rafael Palomino Pacheco
DNI: 1045711819

DECLARACIÓN JURADA DE AUTENTICIDAD

Yo, **JERONIMO CANAHUIRI AYERBE**, identificado con Documento Nacional de Identidad N° **05071254**, de la **MAESTRÍA EN CIENCIA DE DATOS**, de la Escuela de Posgrado de la Universidad Continental, declaro bajo juramento lo siguiente:

1. La Tesis titulada "IMPLEMENTACIÓN DE UN MODELO DE CLASIFICACION Y DETECCIÓN DE TUMORES CEREBRALES EN IMÁGENES DE RM, BASADO EN TÉCNICAS DE CIENCIA DE DATOS", es de mi autoría, el mismo que presento para optar el Grado Académico de MAESTRO EN CIENCIA DE DATOS.
2. La Tesis no ha sido plagiada ni total ni parcialmente, para lo cual se han respetado las normas internacionales de citas y referencias para las fuentes consultadas, por lo que no atenta contra derechos de terceros.
3. La Tesis es original e inédito, y no ha sido realizado, desarrollado o publicado, parcial ni totalmente, por terceras personas naturales o jurídicas. No incurre en autoplagio; es decir, no fue publicado ni presentado de manera previa para conseguir algún grado académico o título profesional.
4. Los datos presentados en los resultados son reales, pues no son falsos, duplicados, ni copiados, por consiguiente, constituyen un aporte significativo para la realidad estudiada.

De identificarse fraude, falsificación de datos, plagio, información sin cita de autores, uso ilegal de información ajena, asumo las consecuencias y sanciones que de mi acción se deriven, sometiéndome a las acciones legales pertinentes.

Lima, 07 de mayo de 2025

J Canahui

JERONIMO CANAHUIRI AYERBE
DNI. N° 05071254



Huella

Arequipa

Av. Los Incas S/N,
José Luis Bustamante y Rivero
(054) 412 030

Calle Alfonso Ugarte 607, Yanahuara
(054) 412 030

Huancayo

Av. San Carlos 1980
(064) 481 430

Cusco

Urb. Manuel Prado Este B, N° 7 Av. Collisuyo
(084) 480 070

Sector Angostura KM. 10,
carretera San Jerónimo - Saylla
(084) 480 070

Lima

Av. Alfredo Mendiolá 5210, Los Olivos
(01) 213 2760

Jr. Junín 355, Miraflores
(01) 213 2760

DECLARACIÓN JURADA DE AUTENTICIDAD

Yo, JACKSON M'COY ROMERO PLASENCIA, identificada con Documento Nacional de Identidad N° 41264360, egresada de la MAESTRÍA EN CIENCIA DE DATOS, de la Escuela de Posgrado de la Universidad Continental, declaro bajo juramento lo siguiente:

1. La Tesis titulada "IMPLEMENTACIÓN DE UN MODELO DE CLASIFICACION Y DETECCION DE TUMORES CEREBRALES EN IMÁGENES DE RM, BASADO EN TÉCNICAS DE CIENCIA DE DATOS" es de mi autoría, la misma que presento para optar el Grado Académico de MAESTRO EN CIENCIA DE DATOS.
2. La Tesis no ha sido plagiada ni total ni parcialmente, para lo cual se han respetado las normas internacionales de citas y referencias para las fuentes consultadas, por lo que no atenta contra derechos de terceros.
3. La Tesis es original e inédita, y no ha sido realizada, desarrollada o publicada, parcial ni totalmente, por terceras personas naturales o jurídicas. No incurre en autoplagio; es decir, no fue publicada ni presentada de manera previa para conseguir algún grado académico o título profesional.
4. Los datos presentados en los resultados son reales, pues no son falsos, duplicados, ni copiados, por consiguiente, constituyen un aporte significativo para la realidad estudiada.

De identificarse fraude, falsificación de datos, plagio, información sin cita de autores, uso ilegal de información ajena, asumo las consecuencias y sanciones que de mi acción se deriven, sometiéndome a las acciones legales pertinentes.

Lima, 18 de noviembre de 2024.



JACKSON M'COY ROMERO PLASENCIA
DNI. N° 41264360



Huella

Arequipa

Av. Los Incas S/N,
José Luis Bustamante y Rivero
(054) 412 030

Calle Alfonso Ugarte 607, Yanahuara
(054) 412 030

Huancayo

Av. San Carlos 1980
(064) 481 430

Cusco

Urb. Manuel Prado - Lote B, N° 7 Av. Collasuyo
(084) 480 070

Sector Angostura KM. 10,
carretera San Jerónimo - Saylla
(084) 480 070

Lima

Av. Alfredo Mendiola 5210, Los Olivos
(01) 213 2760

Jr. Junín 355, Miraflores
(01) 213 2760

DECLARACIÓN JURADA DE AUTENTICIDAD

Yo, VELASQUEZ QUINTANILLA IVAN, identificado con Documento Nacional de Identidad N° 41913959, de la MAESTRÍA EN CIENCIA DE DATOS, de la Escuela de Posgrado de la Universidad Continental, declaro bajo juramento lo siguiente:

1. La Tesis titulada "IMPLEMENTACIÓN DE UN MODELO DE CLASIFICACION Y DETECCIÓN DE TUMORES CEREBRALES EN IMÁGENES DE RM, BASADO EN TÉCNICAS DE CIENCIA DE DATOS", es de mi autoría, el mismo que presento para optar el Grado Académico de MAESTRO EN CIENCIA DE DATOS.
2. La Tesis no ha sido plagiada ni total ni parcialmente, para lo cual se han respetado las normas internacionales de citas y referencias para las fuentes consultadas, por lo que no atenta contra derechos de terceros.
3. La Tesis es original e inédita, y no ha sido realizado, desarrollado o publicado, parcial ni totalmente, por terceras personas naturales o jurídicas. No incurre en autoplagio; es decir, no fue publicado ni presentado de manera previa para conseguir algún grado académico o título profesional.
4. Los datos presentados en los resultados son reales, pues no son falsos, duplicados, ni copiados, por consiguiente, constituyen un aporte significativo para la realidad estudiada.

De identificarse fraude, falsificación de datos, plagio, información sin cita de autores, uso ilegal de información ajena, asumo las consecuencias y sanciones que de mi acción se deriven, sometiéndome a las acciones legales pertinentes.

Lima, 13 de mayo de 2025



VELASQUEZ QUINTANILLA IVAN
DNI. N° 41913959



Huella

Arequipa

Av. Los Incas S/N,
José Luis Bustamante y Rivero
(054) 412 030

Calle Alfonso Ugarte 607, Yanahuara
(054) 412 030

Huancayo

Av. San Carlos 1980
(064) 481 430

Cusco

Uta Manuel Prado - Lote B, N° 7 Av. Gólleny
(084) 460 020

Sector Arquisura KM. 10,
carretera San Jerónimo - Saylla
(084) 460 020

Lima

Av. Alfonso Menéndez 5210, Los Olivos
(01) 213 2760

R. Junín 355, Miraflores
(01) 215 2761

IMPLEMENTACIÓN DE UN MODELO DE CLASIFICACION Y DETECCION DE TUMORES CEREBRALES EN IMÁGENES DE RM, BASADO EN TÉCNICAS DE CIENCIA DE DATOS

INFORME DE ORIGINALIDAD

9%

INDICE DE SIMILITUD

8%

FUENTES DE INTERNET

3%

PUBLICACIONES

4%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	upcommons.upc.edu Fuente de Internet	2%
2	Submitted to Universidad Continental Trabajo del estudiante	1%
3	bibdigital.epn.edu.ec Fuente de Internet	1%
4	oldri.ues.edu.sv Fuente de Internet	1%
5	repositorio.continental.edu.pe Fuente de Internet	1%
6	www.medmultilingua.com Fuente de Internet	1%
7	Delgado Goñi, Teresa, Universitat Autònoma de Barcelona. Departament de Bioquímica i de Biologia Molecular. "Aproximación a la caracterización morfológica y molecular por IRM y ERM de la respuesta a la terapia en	<1%

modelos pre-clínicos de glioma", [Barcelona] :
Universitat Autònoma de Barcelona.
Departament de Bioquímica i Biologia
Molecular,, 2012

Fuente de Internet

8

Luis Enrique Contreras. "EPIDEMIOLOGÍA DE
TUMORES CEREBRALES", Revista Médica
Clínica Las Condes, 2017

Publicación

<1 %

9

www.fesc.edu.co

Fuente de Internet

<1 %

10

Jhon Jairo Sáenz Gamboa. "Machine Learning
en Resonancia Magnética. Describiendo la
Fisiopatología del Dolor Lumbar", Universitat
Politecnica de Valencia, 2024

Publicación

<1 %

11

tableros.serigrafistas.net

Fuente de Internet

<1 %

12

Submitted to Universidad Anahuac México
Sur

Trabajo del estudiante

<1 %

13

deepnote.com

Fuente de Internet

<1 %

14

bibliotecadigital.exactas.uba.ar

Fuente de Internet

<1 %

15	Submitted to Universidad Internacional de la Rioja Trabajo del estudiante	<1 %
16	hdl.handle.net Fuente de Internet	<1 %
17	ichi.pro Fuente de Internet	<1 %
18	repositoriodigital.uns.edu.ar Fuente de Internet	<1 %
19	Submitted to Ilerna Online Blackboard Trabajo del estudiante	<1 %

Excluir citas

Apagado

Excluir coincidencias < 40 words

Excluir bibliografía

Activo

Asesor

Dr. Kevin Rafael Palomino Pacheco

Agradecimiento

Al concluir este trabajo, quiero expresar mi más profundo agradecimiento a todas las personas que han sido parte de este camino.

A mi familia, por ser mi pilar fundamental. A mis padres, por su amor incondicional, sus sacrificios y su constante apoyo en cada etapa de mi vida.

A nuestro asesor de tesis, Kevin Rafael Palomino Pacheco por su guía, paciencia y dedicación. Sus conocimientos y consejos han sido fundamentales para la realización de este proyecto, y su compromiso con la excelencia me ha inspirado profundamente.

A los docentes que, a lo largo de nuestra formación académica, han dejado huella con sus enseñanzas y pasión por el conocimiento.

Finalmente, agradezco a Universidad Continental, cuya colaboración y recursos hicieron posible que este proyecto llegara a buen término.

A todos ustedes, mi más sincero agradecimiento. Este logro no habría sido posible sin cada una de sus contribuciones.

Con gratitud,

Jackson M'coy Romero Plasencia
Jeronimo Canahuirí Ayerbe
Iván Velásquez Quintanilla

Índice

Asesor	ii
Agradecimiento	iii
Índice.....	iv
Índice de tablas	vi
Índice de figuras	vii
Resumen.....	ix
Abstract.....	x
Introducción.....	xi
Capítulo I: Planteamiento del estudio.....	13
1.1. Planteamiento y formulación del problema	13
1.1.1. <i>Planteamiento del problema</i>	13
1.1.2. <i>Formulación del problema</i>	16
1.2. Determinación de objetivos.....	17
1.2.1. <i>Objetivo general</i>	17
1.2.2. <i>Objetivos específicos</i>	17
1.3. Justificación e importancia del estudio.....	17
1.3.1. <i>Justificación teórica</i>	17
1.3.2. <i>Justificación metodológica</i>	18
1.3.3. <i>Justificación social</i>	18
1.4. Limitaciones de la presente investigación.....	19
Capítulo II: Marco teórico	20
2.1. Antecedentes de la investigación.....	20
2.1.1. <i>Internacionales</i>	20
2.1.2. <i>Nacionales</i>	23
2.2. Bases teóricas	26
2.2.1. <i>Desarrollo histórico</i>	30
2.2.2. <i>Fundamentación teórica</i>	35
2.2.3. <i>Marco conceptual</i>	37
2.3. Definición de términos básicos	39
Capítulo III: Hipótesis y variables	41
3.1. Hipótesis	41
3.1.1. <i>Hipótesis general</i>	41

3.1.2.	<i>Hipótesis específicas</i>	41
3.2.	Operacionalización de variables	41
3.2.1.	<i>Variable 1</i>	41
3.2.2.	<i>Variable 2</i>	42
3.3.	Matriz de operacionalización de variables	42
Capítulo IV: Metodología del estudio		43
4.1.	Enfoque, tipo y alcance de investigación	43
4.1.1.	<i>Enfoque</i>	43
4.1.2.	<i>Tipo y alcance</i>	43
4.2.	Diseño de la investigación	44
4.3.	Población y muestra	44
4.3.1.	<i>Población</i>	44
4.3.2.	<i>Muestra</i>	44
4.4.	Técnicas e instrumentos de recolección de datos	45
4.4.1.	<i>Técnicas e instrumentos</i>	45
4.4.2.	<i>Validez y confiabilidad</i>	45
4.4.3.	<i>Procedimiento de recolección de datos</i>	47
4.5.	Técnicas de análisis de datos	47
Capítulo V: Resultados		48
5.1.1	<i>Descripción de la base de datos</i>	48
5.1.2	Descripción de los modelos utilizados	67
5.1.3	<i>Resultados</i>	90
5.2	Discusión de resultados	97
Conclusiones		101
Recomendaciones		103
Referencias		105
Anexos		116

Índice de tablas

Tabla 1 Características, mínimo y máximo de las imágenes de base de Si Tumores (SiT)	49
Tabla 2 Medidas descriptivas de las imágenes si Tumor (SiT)	49
Tabla 3 Tipos de Formatos de las imágenes de la RM en el grupo SiT	50
Tabla 4 Características, mínimo y máximo de las imágenes de base de Si Tumores (SiT)	52
Tabla 5 Medidas descriptivas de las imágenes no Tumor (NoT)	52
Tabla 6 Tipos de Formatos de las imágenes de la RM en la base de datos	53
Tabla 7 Características de las imágenes de base de entrenamiento	56
Tabla 8 Características de las imágenes de base de entrenamiento	57
Tabla 9 Medidas descriptivas de las imágenes del grupo Tumor, base entrenamiento	57
Tabla 10 Medidas descriptivas de las imágenes del grupo No Tumor, base entrenamiento	58
Tabla 11 Tipos de Formatos de las imágenes de la RM en la base de entrenamiento	58
Tabla 12 Características de las imágenes de la base de validación	63
Tabla 13 Características, mínimo y máximo de las imágenes de base de validación	64
Tabla 14 Medidas descriptivas de las imágenes de la base de Tumor de la base de validación	64
Tabla 15 Medidas descriptivas de las imágenes de la base de No Tumor del grupo de validación	65
Tabla 16 Características de los modelos entrenados	90
Tabla 17 Indicadores del Modelo VGG16:	91
Tabla 18 indicadores del Modelo InceptionV3	92
Tabla 19 indicadores del Modelo InceptionV3	93
Tabla 20 Modelos de Machine Learning para clasificación de imágenes	95
Tabla 21 Modelos de Deep Learning para clasificación de imágenes	95
Tabla 22 Indicadores de los modelos de maching learning	96

Índice de figuras

Figura 1 Número de casos de tumores notificados 2022-2023	15
Figura 2 Distribución de imágenes según tipo de formato, grupo SiTumor	50
Figura 3 Distribución de imágenes Si Tumor según dimensiones (Ancho x Alto), grupo SiTumor.....	51
Figura 4 Distribución de imágenes según tamaño, grupo SiTumor	51
Figura 5 <i>Distribución de imágenes según tipo de formato para el grupo No tumor</i>	53
Figura 6 Distribución de imágenes según dimensiones (Ancho x Alto), grupo No Tumor.....	53
Figura 7 Distribución de imágenes según tamaño, grupo No Tumor.....	54
Figura 8 Imágenes de cerebro que presentan tumor (SiT) por resonancia RM..	55
Figura 9 Distribución de imágenes según: tipo de formato.....	59
Figura 10 Distribución de imágenes según: dimensiones (Ancho x Alto)	59
Figura 11 Distribución de imágenes según: tamaño.....	60
Figura 12 Distribución de imágenes según: tipo de formato para grupo No tumor	60
Figura 13 Distribución de imágenes No tumor según dimensiones.....	61
Figura 14 Imágenes de cerebro que presentan tumor por resonancia	61
Figura 15 Imágenes de cerebro que presentan tumor por resonancia	62
Figura 16 Imágenes de cerebro que no presentan tumores por resonancia magnética.....	63
Figura 17 Distribución de imágenes según: tipo de formato.....	65
Figura 18 Distribución de imágenes según: tamaño (Bytes)	66
Figura 19 Distribución de las imágenes según: dimensiones	66
Figura 20 Distribución de imágenes según: Tamaño	67
Figura 21 Modelo Densenet	69
Figura 22 Modelo Resnet	74
Figura 23 Arquitectura Modelo Vgg16.....	79
Figura 24 Arquitectura Modelo InceptionV3.....	85
Figura 25 Curvas de precisión de grupos de entrenamiento y validación, Modelo VGG16	91

Figura 26 Curvas de precisión de grupo de entrenamiento y validación, Modelo InceptionV3	92
Figura 27 Curvas de precisión de grupos de entrenamiento y validación, Modelo InceptionV3	94
Figura 28 Curvas ROC de los modelos maching learning	97

Resumen

Este estudio se propone desarrollar un modelo para la detección de tumores cerebrales a través de imágenes de resonancia magnética (RM), basado en técnicas de aprendizaje profundo, con la finalidad de mejorar la precisión de la clasificación y la detección de tumores a partir de imágenes de RM. Para la muestra se consideraron 2 bases de datos de imágenes, la primera estuvo conformada por 253 imágenes de las cuales 98 no tiene tumor cerebral y 155 si tienen tumor cerebral y la segunda base de datos considerada por 2747 imágenes. La metodología adoptada implementa un enfoque cuantitativo, de alcance explicativo, y adopta un diseño no experimental y transeccional. Los hallazgos indicaron que las metodologías de aprendizaje automático proporcionaron una precisión de 0.875, mientras que las técnicas de aprendizaje profundo proporcionaron una precisión de 0.9375, para una muestra de imágenes; posteriormente se trabajó con una muestra mayor de imágenes; para ser exactos 2747 imágenes, donde a partir de los modelos de aprendizaje profundo se obtuvo un accuracy de 0.96 con el modelo Desenet121 y con el modelo VGG16 con una precisión de 1.

En casos simples, los radiólogos con experiencia pueden completar el análisis en un tiempo que oscila entre 10 y 30 minutos. Por otro lado, en situaciones más complejas, la duración del análisis puede extenderse a una hora o incluso más. De esta manera, se concluye que los modelos de aprendizaje profundo son los mejores al momento de trabajar con imágenes, en este caso en particular; con imágenes de tumor cerebral, mejorando la precisión de la clasificación y la detección de tumores cerebrales mediante imágenes de resonancia magnética.

Palabras claves: tumor cerebral, resonancia magnética, aprendizaje profundo, aprendizaje automático, precisión

Abstract

The present study aims to develop a classification and detection model for brain tumors from brain MRI images, based on deep learning techniques, to improve the accuracy of classification and detection of brain tumors from MRI images. The sample consisted of 253 images, of which 98 do not have a brain tumor and 155 do have a brain tumor. The methodology employed develops a quantitative approach, with an explanatory scope, and a non-experimental and cross-sectional design. The results showed that machine learning techniques achieved a maximum accuracy of 0.875, whereas deep learning techniques provided an accuracy of 0.9375. for a sample of 253 images; subsequently, a larger sample of images was worked on; to be exact, 2747 images, where from the deep learning models a precision of 0.96 was obtained with the Desenet121 model and with the VGG16 model a precision of 1.

In simple cases, experienced radiologists can complete the analysis in a time ranging from 10 to 30 minutes. On the other hand, in more complex situations, the analysis duration can extend to an hour or even more. In this sense, It was concluded that deep learning models are the best when it comes to working with images, in this particular case; with brain tumor images, improving the accuracy of classification and detection of brain tumors from magnetic resonance images.

Keywords: brain tumor, magnetic resonance imaging, deep learning, machine learning, accuracy

Introducción

La detección temprana de tumores cerebrales es uno de los retos más complejos y cruciales en la medicina moderna, dado que los tumores cerebrales pueden ser letales si no se detectan a tiempo. El cáncer cerebral representa una proporción significativa de las muertes por cáncer a nivel mundial, lo que resalta la urgente necesidad de desarrollar métodos de diagnóstico más precisos y rápidos. La Resonancia Magnética se ha consolidado como una de las técnicas más eficaces para la detección y diagnóstico de tumores, gracias a su capacidad de proporcionar imágenes detalladas y no invasivas. No obstante, la interpretación de las imágenes de resonancia magnética demanda un elevado nivel de especialización, lo cual puede resultar en un proceso prolongado y susceptible a errores humanos. Esto incrementa la probabilidad de diagnósticos inexactos o retardados.

En este contexto, la aplicación de técnicas de aprendizaje automático para ayudar en la identificación y categorización de tumores cerebrales mediante imágenes de resonancia magnética constituye una alternativa promisoría. En el ámbito nacional, diversos hospitales y centros de investigación están investigando el potencial de la inteligencia artificial con el fin de mejorar la exactitud y eficiencia en los diagnósticos médicos. No obstante, la aplicación de dichas tecnologías se encuentra restringida en diversos contextos, sobre todo en zonas con escasez de recursos médicos.

La finalidad principal de este estudio es la implementación de un modelo de clasificación y detección de tumores cerebrales de imágenes de RM cerebrales, basado en técnicas de aprendizaje profundo, para mejorar la precisión de la clasificación y la detección de tumores cerebrales a partir de imágenes de RM, con el fin de optimizar el proceso diagnóstico. La relevancia de este estudio reside en la potencial reducción de los periodos de diagnóstico, mejorar la precisión de la identificación de tumores y disminuir la carga de trabajo de los radiólogos. Además, este modelo puede tener implicaciones prácticas significativas, como el apoyo en el entorno de la toma de decisiones clínicas con falta de personal especializado. Teóricamente, esta investigación contribuirá al campo de la inteligencia artificial

aplicada a la medicina, abriendo nuevas vías para la automatización de tareas complejas.

La estructura de este estudio se presenta de la siguiente manera. En primer lugar, se expone el planteamiento del problema, donde se introducirá el contexto general del diagnóstico de tumores cerebrales y se justifica la importancia de investigar este fenómeno. En segundo lugar, se expone el marco teórico, el cual comprende una revisión de los antecedentes de investigaciones anteriores, las fundamentaciones teóricas que respaldan el análisis y la definición de los términos clave. En tercer lugar, se formulan las hipótesis generales y específicas que serán evaluadas. En cuarto lugar, se describe la metodología del estudio, especificando el tipo de investigación, diseño de investigación, las variables, la población y la muestra, así como los instrumentos y procedimientos de recolección y análisis de datos. Al final, se presentan los resultados obtenidos, seguidos por una discusión de los mismos, y se concluye con las conclusiones y recomendaciones derivadas del estudio.

Este trabajo busca contribuir a la mejora del diagnóstico de tumores cerebrales, con el uso de la tecnología de vanguardia, para ofrecer resultados rápidos y precisos que puedan ayudar a salvar vidas.

Capítulo I: Planteamiento del estudio

1.1. Planteamiento y formulación del problema

1.1.1. Planteamiento del problema

Detectar de manera exacta y de forma temprana los tumores cerebrales, es uno de los retos más difíciles en el área de neuro oncología. A partir de datos obtenidos de la Organización Mundial de Salud (OMS,2022), los tumores cerebrales, constituyen una proporción sumamente significativa de los fallecimientos; de forma global; asociados al cáncer. Teniendo en cuenta lo anterior, es de suma importancia y necesidad prioritaria para la sociedad, la detección oportuna de tumores cerebrales; esto garantiza, en muchos casos, la sobrevivencia del paciente (OMS, 2022). De este modo, la necesidad de mejorar los métodos diagnósticos se deriva de la alta incidencia de enfermedades y fallecimientos asociados a esta patología, lo cual requiere la implementación de herramientas avanzadas.

De todas las técnicas existente para detectar de manera precoz tumores cerebrales, la resonancia magnética se ha posicionado como una técnica fundamental. Por otro lado, es necesario el uso y manejo de herramientas sofisticadas tales como la inteligencia artificial y el aprendizaje automático en el procesamiento de imágenes. Siguiendo esta línea, Lauwers et al., (2022), en su investigación titulada: “Avances en el uso de la resonancia magnética para la detección de tumores cerebrales” ha establecido que la resonancia magnética se ha consolidado como un instrumento esencial en el diagnóstico de diversas afecciones neurológicas, incluyendo los tumores cerebrales.

En el mismo sentido, Mahmud et al., (2021), investigaron: “Limitaciones de la resonancia magnética en el diagnóstico de tumores cerebrales”, donde encontraron que el análisis de las imágenes de resonancia requiere un nivel avanzado de interpretación, lo que en muchos casos puede llevar a diagnósticos erróneos o retrasados y está directamente asociada a la falta de

precisión en la identificación de bordes tumorales, la dificultad para diferenciar entre tejidos neoplásicos y no neoplásicos.

Por otra parte, es importante mencionar que la evolución de la tecnología tal como la inteligencia artificial y el aprendizaje profundo ha facilitado el incremento de la exactitud y rapidez en la identificación de tumores cerebrales. Estas herramientas posibilitan un análisis minucioso de las imágenes de resonancia magnética al identificar patrones y anomalías que podrían no ser perceptibles a simple vista. Por otro lado, Zhang et al., (2023), en su tesis: “Aplicaciones de machine learning en la detección temprana de tumores cerebrales mediante resonancia magnética”, el objetivo es establecer que los algoritmos de aprendizaje automático empleados en el análisis de imágenes son adecuados para incrementar de manera significativa la exactitud diagnóstica; así mismo, encontró que está disminuyendo la incidencia de resultados negativos incorrectos y mejorando la predicción del curso clínico de los pacientes.

En diversos centros de investigación y hospitales alrededor del mundo, se han estado implementando sistemas avanzados para el procesamiento de imágenes. La implementación de tecnología relacionada con la inteligencia artificial en la detección temprana de tumores cerebrales ha resultado en una mejora en la eficacia del diagnóstico y una reducción de los costos tanto en el diagnóstico como en el tratamiento. Este avance beneficia tanto a los pacientes como a los sistemas de salud en diversos países.

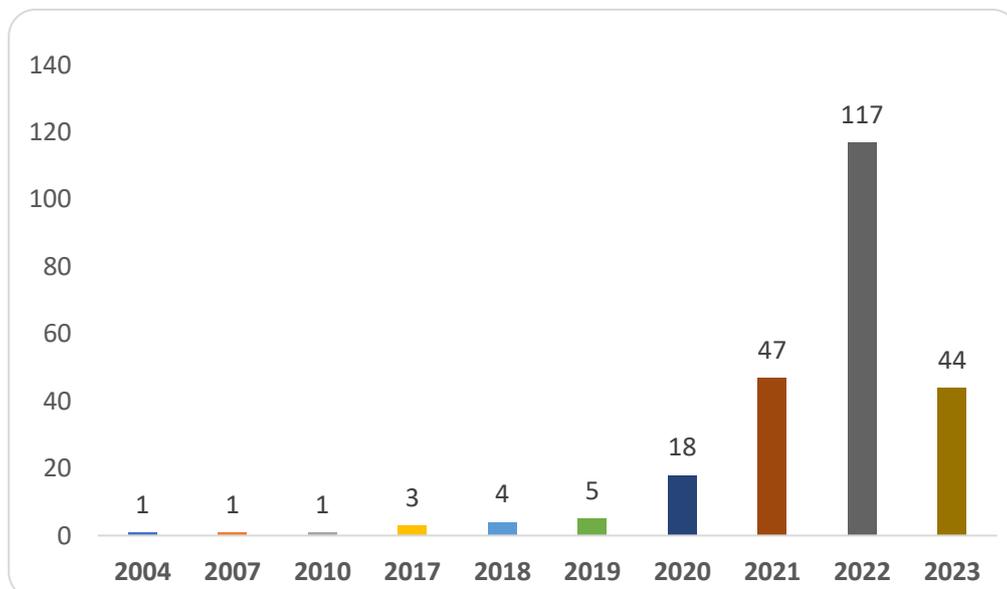
En el contexto de Latinoamérica, las prácticas de estos procedimientos carecen de una inversión significativa lo restringe el uso de tecnologías de vanguardia para la detección de tumores cerebrales, lo cual está relacionado por la idiosincrasia y diversos desafíos netamente económicos o relacionales con políticas gubernamentales. Investigaciones como la de Gómez, H et al., (2022) titulada como “*Implementación de inteligencia artificial en el diagnóstico oncológico en América Latina*”, ha encontrado que, a pesar de esta realidad, en países como Brasil, Argentina y México los intentos de modernización de los

sistemas de salud no se dan en su totalidad; debido a la infraestructura tecnológica y la falta de información especializada. A esto se le suma la falta de inversión en tecnologías avanzadas y en la actualización de los sistemas de diagnóstico; éste es un factor crítico para el incremento en diagnósticos tardíos, lo cual pueden generar una muerte prematura de los pacientes.

Así mismo, Pérez et al., (2023) en su investigación: “Acceso a tecnologías avanzadas para el diagnóstico de tumores cerebrales en Perú”, la sociedad peruana, no está exenta de esta problemática donde la no disponibilidad de tecnologías de diagnóstico de vanguardia en un factor clave.

La otra cara de la moneda son las áreas rurales que, en contraste con el área urbana, la situación es más alarmante; un rasgo a un más arraigado es la frecuente la carencia de herramientas avanzadas para el procesamiento preciso de las imágenes. De manera concreta, los factores que agudizan el aumento de la tasa de mortalidad, diagnósticos fuera de tiempo y minimizan la oportunidad de recibir tratamiento eficaz se presenta en la Figura 1.

Figura 1
Número de casos de tumores notificados 2022-2023



Fuente: Oficina de Epidemiología y Salud Ambiental

Otra problemática presente es la incipiente capacitación de profesionales de salud en el uso de tecnologías de imagen, a pesar del vasto desarrollo en este campo de la ciencia. Es por ello que, Gonzáles et al., (2021), menciona que muchos de los especialistas no están familiarizados con las innovaciones más recientes en inteligencia artificial y machine learning, lo cual obstaculiza la implementación efectiva de dichos sistemas en el ámbito clínico.

Entre las dificultades más primordiales se encuentran: acceso a la resonancia magnética, infraestructura y equipamiento, capacitación y recursos humanos, costo y cobertura y perspectivas de mejoras. Como lo hace notar Flores & Mendoza (2021), en un estudio regional realizado en el Hospital Regional de Ayacucho, descubrió que el período medio para diagnosticar un tumor cerebral era de seis meses a partir de la manifestación inicial de los síntomas. Esta demora se atribuyó a la escasez de recursos y a la limitada presencia de especialistas en neuroimagen. He aquí la importancia de disponer de herramientas que permitan realizar un diagnóstico temprano y preciso.

Aunque se han logrado avances significativos, existen desafíos continuos en la aplicación de modelos de aprendizaje automático que puedan ser generalizados a diferentes conjuntos de datos y contextos clínicos. Para superar los obstáculos en el campo de la detección de tumores, es necesario abordar las variaciones en la calidad de las imágenes, la diversidad de tipos de tumores y la escasez de conjuntos de datos etiquetados.

1.1.2. Formulación del problema

1. *Problema general*

¿En qué medida un modelo basado en técnicas de ciencia de datos puede mejorar la clasificación y detección de tumores cerebrales en imágenes de resonancia magnética?

2. Problemas específicos

- ¿Cómo obtener y preprocesar un conjunto de datos que sea suficientemente diverso y representativo para entrenar modelos de clasificación de tumores cerebrales?
- ¿Qué modelo de aprendizaje automático ofrece el mejor rendimiento en la clasificación precisa de imágenes de tumores cerebrales?
- ¿Qué métricas y métodos de validación son más adecuados para evaluar la eficacia de los modelos en la detección de tumores cerebrales?

1.2. Determinación de objetivos

1.2.1. Objetivo general

Implementar un modelo de detección de tumores cerebrales de imágenes de RM cerebrales, basado en técnicas de aprendizaje profundo, para mejorar la precisión de la detección de tumores cerebrales a partir de imágenes de RM.

1.2.2. Objetivos específicos

- Obtener y preparar un conjunto de datos diverso y representativo de imágenes de tumores de cerebro para el entrenamiento del modelo.
- Identificar el mejor modelo capaz de clasificar imágenes de tumores con alta precisión.
- Validar y evaluar los modelos de aprendizaje automático en la detección de tumores cerebrales.

1.3. Justificación e importancia del estudio

1.3.1. Justificación teórica

Realizar el análisis de imágenes con técnicas avanzadas, que incluye el uso de herramientas como machine learning y aprendizaje profundo, se ha convertido en un campo fundamental en disciplinas como la neurociencia y la radiología. Sin embargo, a pesar de los avances muy altamente significativos logrados en la

tecnología de resonancia magnética, continúa presentando dificultades. La justificación teórica de esta investigación se encuentra en su contribución al cuerpo de conocimiento existente en el campo del diagnóstico médico.

Considerando para ello la identificación de mejoras en la sensibilidad y especificidad de estas herramientas en comparación con métodos tradicionales no solo contribuirá a ampliar el conocimiento del potencial de las nuevas tecnologías, sino que también sentará las bases científicas para investigaciones futuras y el desarrollo de prácticas clínicas más efectivas. En este sentido, se prevé que este estudio proporcione una referencia para analizar el impacto de las innovaciones tecnológicas en la medicina contemporánea y valorando la aplicación de las técnicas de Ciencia de datos.

1.3.2. Justificación metodológica

Desde un enfoque metodológico, esta investigación se basa en un diseño comparativo que facilitará una valoración sólida de las herramientas sofisticadas de análisis de imágenes. Es por esto que, el uso de técnicas cuantitativas, tales como el análisis de tasas de detección, sensibilidad, especificidad y tiempo de diagnóstico, permitirá obtener información precisa que resulta fundamental para evaluar la eficacia de las tecnologías emergentes en contraste con los enfoques convencionales de interpretación radiológica.

La justificación de este enfoque metodológico radica en la importancia de adquirir pruebas empíricas que sustenten la integración de tecnologías avanzadas en el ámbito clínico, lo cual puede incidir positivamente en la salud de la población. A la larga esto posibilitará la generalización de los hallazgos a poblaciones similares.

1.3.3. Justificación social

La detección precoz de tumores cerebrales es crucial desde un enfoque social, ya que la sobrevivencia y el bienestar de los pacientes se encuentran estrechamente ligados al instante en que se realiza el diagnóstico. La incidencia de enfermedades neurológicas está en aumento en el contexto de Lima, lo cual resalta la relevancia

social significativa de este estudio, considerando la limitación de recursos de salud en la región. La evaluación del impacto de herramientas avanzadas en el diagnóstico tiene como objetivo contribuir a la mejora de los sistemas de salud locales, permitiendo un acceso más efectivo a diagnósticos precisos y oportunos. Este estudio contribuirá a aumentar la conciencia pública acerca de la relevancia de la detección temprana y la aplicación de tecnología avanzada en el ámbito de la atención médica. En última instancia, el objetivo de la investigación es mejorar tanto los resultados clínicos como promover el bienestar social.

1.4. Limitaciones de la presente investigación

Se requiere de contar con computadoras o laptops con alto nivel de procesamiento de imágenes, lo cual conlleva a altos costos de inversión. Otra de las limitaciones importantes son la cantidad de imágenes y la calidad de ellas, ya que si éstas están demasiadas saturadas no se va poder llevar a determinar de forma clara su clasificación en cuanto a la detección de tumores. En cuanto a la parte computacional se realizarán pruebas exhaustivas y validaciones cruzadas, asegurando que el modelo desarrollado sea robusto y confiable y también la optimización de hiperparámetros.

Capítulo II: Marco teórico

2.1. Antecedentes de la investigación

2.1.1. Internacionales

En los últimos diez años, la inteligencia artificial ha adquirido relevancia creciente en el ámbito de la medicina, especialmente en la identificación de tumores cerebrales. Las redes neuronales convolucionales son una arquitectura de inteligencia artificial que se ha empleado extensamente en el análisis de imágenes médicas con una alta precisión. Las redes neuronales convolucionales tienen la capacidad de categorizar de forma automática los tumores cerebrales en distintas clases, como gliomas, meningioma, pituitarios y metástasis, así como de predecir su grado de malignidad a partir de las características presentes en las imágenes médicas (Zhao, 2020)

En su estudio, Zhou et al., (2019) crearon un modelo de inteligencia artificial fundamentado en el aprendizaje profundo que demuestra una mayor eficacia en la identificación de gliomas de grado bajo y alto en comparación con enfoques convencionales, empleando imágenes de resonancia magnética. El empleo de estrategias de aprendizaje profundo ha demostrado una precisión de hasta el 94% en la categorización de neoplasias cerebrales, lo cual optimiza el proceso diagnóstico.

Por otra parte, el empleo de inteligencia artificial no se ha restringido únicamente a la detección, sino que también ha influido en la planificación del tratamiento. De acuerdo con Skogen (2020), los algoritmos de inteligencia artificial tienen la capacidad de predecir de manera precisa la reacción del paciente ante diferentes modalidades terapéuticas, tales como la radioterapia y la quimioterapia. La personalización de las terapias ha posibilitado una mejora en los resultados clínicos y una reducción de los efectos secundarios.

La segmentación de tumores cerebrales es un proceso relevante en el campo de

la medicina para identificar y delimitar con precisión la extensión de un tumor en imágenes médicas fundamentada en inteligencia artificial. La precisa segmentación de los tumores cerebrales resulta fundamental en la planificación de la intervención quirúrgica y las terapias complementarias. Históricamente, la segmentación de imágenes médicas ha sido llevada a cabo de forma manual por profesionales de la radiología, lo cual requiere una considerable cantidad de tiempo y puede estar sujeto a posibles errores.

Según un estudio realizado por Pereira (2021) se ha comprobado que los algoritmos de redes neuronales profundas tienen la capacidad de segmentar los tumores cerebrales con una precisión superior a la de los métodos manuales. Los modelos mencionados han demostrado ser especialmente eficaces para la detección de los márgenes tumorales en glioblastomas, que son considerados uno de los tipos de tumores cerebrales más agresivos. Al asegurar una segmentación más precisa, se logra una planificación quirúrgica que es tanto más segura como más eficaz.

En los últimos cinco años, se ha demostrado que la integración de diversas modalidades de imágenes es un método prometedor para aumentar la precisión en la identificación de tumores cerebrales. Las técnicas multimodales combinan información obtenida de resonancia magnética, tomografía por emisión de positrones (PET) y tomografía computarizada (CT) con el fin de ofrecer una perspectiva integral del tumor y su entorno circundante (Fang, 2019). La observación conjunta de imágenes permite a los profesionales de la medicina analizar tanto la morfología como la actividad metabólica de la neoplasia, aspecto crucial en la distinción entre tumores malignos y benignos.

Investigaciones recientes han indicado que la aplicación de técnicas multimodales puede ser útil para anticipar la evolución clínica del paciente y la posibilidad de reaparición del tumor (Chang, 2020). El enfoque multimodal ha demostrado ser efectivo para monitorear la respuesta al tratamiento, lo que posibilita la adaptación de las terapias de acuerdo con la evolución del tumor.

La relevancia del impacto de la automatización en los resultados clínicos es significativa en la salud. La influencia de la automatización en los resultados clínicos ha sido ampliamente estudiada e investigada en el ámbito de la medicina. La automatización en los procesos clínicos ha demostrado tener efectos significativos en la eficiencia y precisión de los tratamientos médicos, así como en la reducción de errores humanos; la automatización en la detección y clasificación de tumores cerebrales ha demostrado tener un efecto beneficioso en la exactitud del diagnóstico y en los desenlaces clínicos de los pacientes.

Por el contrario, Isensee et al., (2021) manifiestan que en investigaciones recientes han evidenciado que los algoritmos fundamentados en Inteligencia Artificial tienen la capacidad de disminuir de manera considerable el tiempo requerido para alcanzar un diagnóstico preciso. Lo cual genera una intervención más ágil e incrementa las posibilidades de éxito en el tratamiento. Por otra parte, Esteva et al., (2021) implementó una herramienta automatizada de segmentación de tumores, la cual se destaca como ejemplo relevante y ha sido empleada en ensayos clínicos con el propósito de evaluar su eficacia en ambientes hospitalarios. Los resultados del estudio que la herramienta ayuda a detectar tumores cerebrales en fases iniciales con una precisión que supera el 90%. Esto ha posibilitado la realización de cirugías más tempranas y menos invasivas. De este modo, se vislumbran tendencias futuras que prometen mejorar significativamente la precisión y eficacia de los métodos diagnósticos disponibles en la detección de tumores cerebrales.

Se prevé que, en un futuro cercano, la detección de tumores cerebrales experimentará mejoras gracias al progreso de la investigación en inteligencia artificial y aprendizaje automático. De acuerdo a lo propuesto por Haque et al., (2020) las tendencias futuras en el campo implican el uso de la Inteligencia Artificial no solo para detectar y categorizar tumores, sino también para predecir su evolución y evaluar la efectividad de un determinado tratamiento.

En consecuencia, Wang et al., (2021) se refieren a la integración de datos genómicos y clínicos con imágenes médicas en el abordaje terapéutico del cáncer

cerebral se plantea como una estrategia personalizada que ajusta los tratamientos a las características específicas de los tumores y de los pacientes. En América Latina, los problemas económicos y estructurales en el sistema de salud no han permitido el acceso a técnicas avanzadas de diagnóstico por imágenes, como la resonancia magnética (RM) y la tomografía computarizada (CT). En los últimos cinco años, se han realizado significativos esfuerzos para mejorar la capacidad diagnóstica en el tratamiento de tumores cerebrales.

Por su parte Miller et al., (2020), dio a conocer que varios estudios le han dado la importancia a la implementación de tecnologías avanzadas, como la resonancia magnética funcional (fMRI) y la espectroscopía por resonancia magnética (MRS), en hospitales de países como Brasil, Argentina y México. En ese sentido Costa et al., (2021) manifestó que habiéndose realizado un estudio en Brasil resaltó la eficacia de las redes neuronales convolucionales en la detección de gliomas, logrando una precisión de aproximadamente el 92%, cifra equiparable a la obtenida en investigaciones a nivel internacional.

La detección de tumores cerebrales a través de imágenes de resonancia magnética (RM) puede experimentar variaciones sustanciales en función de la complejidad del caso, la calidad de las imágenes y la pericia del profesional especializado. En casos simples, los radiólogos con experiencia pueden completar el análisis en un tiempo que oscila entre 10 y 30 minutos. Por otro lado, en situaciones más complejas, la duración del análisis puede extenderse a una hora o incluso más. Las herramientas de inteligencia artificial están contribuyendo a la disminución del tiempo de análisis al procesar imágenes en cuestión de segundos (Barcelona., 2018, PortalCLÍNICA., 2023).

2.1.2. Nacionales

Debido a los problemas de infraestructura y la no disponibilidad de tecnología actualizadas, en Perú, la identificación de tumores cerebrales es un utopía. A pesar de ello en los últimos cinco años, se han generado iniciativas con el fin de mejorar el diagnóstico a través de la implementación de tecnologías innovadoras,

como el machine learning y el deep learning, en el análisis de imágenes médicas.

En 2019, el Instituto Nacional de Enfermedades Neoplásicas (INEN) llevó a cabo un estudio que examinó la utilización de resonancia magnética y espectroscopía por RM para la detección precoz de glioblastomas multiformes, que constituyen el tipo más agresivo de neoplasia cerebral. Por lo tanto, Vargas et al., (2019), gracias a que implementó técnicas avanzadas en imágenes, obtuvo una mejor significativa en la precisión diagnóstica; estas técnicas permitieron diferenciar con mayor precisión entre tumores benignos y malignos en comparación con los métodos convencionales.

De acuerdo con García et al., (2021) en algunos hospitales de Lima, se ha conseguido automatizar la segmentación de tumores en imágenes de resonancia magnética, para lo cual se ha necesitado trabajar con redes neuronales. Esta automatización ha contribuido a la disminución del tiempo de diagnóstico y a la mejora de los resultados clínicos. Por otra parte, Córdova et al., (2020) investigó el incremento de la precisión en el diagnóstico de tumores cerebrales en pacientes peruanos mediante el uso de resonancia magnética. La presente investigación tuvo por finalidad la utilización de técnicas avanzadas lo cual generó una mayor capacidad de detección de tumores en fases iniciales.

Siguiendo esta misma línea, Valverde et al., (2019) en su investigación: “Aplicación de redes neuronales en la detección automática de tumores cerebrales en Perú”, con la finalidad de examinar el empleo de la inteligencia artificial en el proceso de segmentación automatizada de tumores cerebrales a partir de imágenes de resonancia magnética. El estudio se realizó en el Hospital Nacional Edgardo Rebagliati Martins donde se llegó a determinar la capacidad de los algoritmos de aprendizaje profundo para optimizar los tiempos de diagnóstico. Por otro lado, Torres et al., (2021) investigaron: “Espectroscopía por resonancia magnética en el diagnóstico de gliomas en Perú: Un estudio multicéntrico”, y con el propósito de analizar el uso de técnicas de espectroscopía aplicado a pacientes diagnosticados con gliomas.

En particular, Pérez et al., (2020), aplicaron la resonancia magnética ponderada por difusión en la detección de tumores cerebrales en niños; esta metodología ayudó a diferenciar con mayor exactitud los diferentes tipos de tumores. Teniendo en cuenta que, a partir del estudio desarrollado por Quispe et al., (2021) en “Modelos predictivos basados en inteligencia artificial para el tratamiento de glioblastomas en Perú”, el modelo predictivo formulado en base a la inteligencia artificial ayudó a prevenir la eficacia del tratamiento de radioterapia.

Con la finalidad de detectar meningiomas, Gutiérrez et al., (2020) evaluaron la efectividad de la resonancia magnética, en diversos centros hospitalarios de las ciudades de Lima y Cusco. A partir de un estudio realizado por Valencia et al., (2019) se mejoró la precisión del diagnóstico, al implementar técnicas de inteligencia artificial, con la finalidad de segmentar tumores cerebrales.

Por otro lado, Jiménez et al., (2019) estudió el uso de la inteligencia artificial y como ésta, reduce el tiempo de diagnóstico de tumores cerebrales en niños de Perú. En el mismo sentido, Arévalo et al., (2021) evaluaron los resultados obtenidos de tumores cerebrales, guiados por resonancia magnética. Por su parte, Suárez et al., (2020) llegaron a estudiar la resonancia magnética, con la finalidad de identificar de forma temprana los tumores cerebrales, lo cual ayudaba en la precisión diagnóstica.

Finalmente, Espinoza et al., (2019), analizaron el uso de la aplicación de redes neuronales profundas en el proceso de clasificación automatizada de imágenes de tumores cerebrales en el Hospital Nacional dos de Mayo. En su estudio, Huamán et al., (2021) analizaron la implementación de la inteligencia artificial en establecimientos de salud ubicados en zonas rurales con el propósito de mejorar el diagnóstico en la detección de tumores cerebrales a través del análisis de imágenes de resonancia magnética.

2.2. Bases teóricas

Aprendizaje automático aplicado a la clasificación de tumores cerebrales

De acuerdo a M.I. & T.M., (2015) el aprendizaje automático constituye una destacada disciplina dentro del campo de la inteligencia artificial. Desde la realización del test de Turing en 1950, ha experimentado significativos avances, representando una novedosa perspectiva en la aplicación de conceptos computacionales y tecnología de vanguardia. El Machine Learning posibilita que los sistemas adquieran conocimiento y perfeccionen sus capacidades de manera automática a través de la experiencia, sin necesidad de ser programados directamente. Además, posibilita que los algoritmos identifiquen patrones complejos de manera automática a partir de una base de datos.

En ese mismo sentido, Wang y et al, (2020), actualmente, se pueden identificar tres técnicas destacadas de Machine Learning. El aprendizaje supervisado implica que la máquina se entrena utilizando datos que han sido previamente etiquetados. En este trabajo, se utilizará una red específica, la cual analizará imágenes de cerebros con etiquetas que indican si se trata de no tumor, glioma, meningioma y pituitario.

El aprendizaje no supervisado se caracteriza por algoritmos que operan sin la necesidad de contar con un conocimiento previo, a diferencia del aprendizaje supervisado. El sistema en sí mismo identificará patrones, similitudes o características de forma autónoma. Por consiguiente, la máquina debe ser autónoma. Cuando se tienen identificadas todas las variables de entrada pertinentes para una respuesta, es posible inferir que puntos con características similares en las variables de entrada también presentarán similitudes en las variables de salida, incluso en ausencia de muestras etiquetadas. (DataCmp, 2024)

En el aprendizaje automático por refuerzo, la máquina se entrena mediante un proceso de prueba y error para aprender a tomar las decisiones más adecuadas, utilizando un sistema de recompensas. En este enfoque, la máquina recibe

retroalimentación sobre las decisiones correctas, lo que le permite mejorar su desempeño y aprender progresivamente con el tiempo. (Luthy, 2022)

A continuación, se presentan algunas de las técnicas más comúnmente empleadas en cada proceso de aprendizaje:

- Según Pelegero A. , (2022), en el ámbito del aprendizaje supervisado, se pueden identificar dos problemas fundamentales: la regresión y la clasificación. En el contexto de análisis de datos, la finalidad es pronosticar un resultado que presenta variabilidad dentro de un intervalo numérico. Por ejemplo, es factible predecir la edad de una persona a partir de una fotografía suya. En el campo de la clasificación, el objetivo es realizar predicciones sobre resultados que se presentan en forma de categorías. Un ejemplo ilustrativo es el presente estudio, que consiste en la detección de tumores cerebrales en pacientes mediante el análisis de imágenes de resonancia magnética (IRM).
- En el ámbito del aprendizaje no supervisado, se destacan dos técnicas importantes: el Clustering y la Detección de Anomalías. Por un lado, el clustering consiste en la agrupación de datos de entrada de acuerdo con criterios específicos, como en el caso de la venta de productos. Por otro lado, la detección de anomalías se encarga de agrupar los datos de entrada según parámetros normales predefinidos, identificando aquellos que no se ajustan. La técnica de detección de anomalías resuelve diversos problemas, como el fraude de las tarjetas de crédito, la videovigilancia y las intrusiones en redes.(Nieves Martínez, (2024))
- La técnica principal en el aprendizaje por refuerzo consiste en la resolución de juegos para lograr un rendimiento superior al humano.

Los modelos de aprendizaje profundo son estructuras computacionales que imitan el funcionamiento del cerebro humano para procesar datos y realizar tareas complejas. De igual forma LeCun et al., (2022) propone que el aprendizaje profundo, es una disciplina perteneciente al campo del aprendizaje automático,

emplea redes neuronales artificiales con múltiples capas con el fin de analizar y adquirir conocimiento a partir de extensos conjuntos de datos.

Por otro lado, García R. , (2023), manifiesta que concretamente, el aprendizaje profundo es una técnica que capacita a los sistemas informáticos para llevar a cabo funciones que imitan las capacidades humanas, tales como el reconocimiento de voz, de imágenes y la capacidad predictiva. El aprendizaje profundo difiere de los métodos tradicionales al establecer parámetros de datos fundamentales y capacitar a las computadoras para reconocer patrones mediante múltiples capas de procesamiento, en lugar de simplemente organizar datos para procesar ecuaciones predefinidas

En ese sentido, Díaz Ramírez,(2021) menciona que el interés contemporáneo en el aprendizaje profundo puede atribuirse parcialmente a los progresos que la inteligencia artificial ha realizado en el ámbito de la inteligencia artificial está experimentando en la actualidad, siendo este uno de los pilares fundamentales de la IA. En resumen, las técnicas de aprendizaje profundo han mejorado nuestra capacidad para clasificar, reconocer, detectar y describir, lo que se traduce en una mayor comprensión.

Desde la perspectiva del propósito de esta investigación centrado en la detección de tumores cerebrales, resulta viable entrenar modelos de aprendizaje profundo haciendo uso de imágenes de resonancia magnética debidamente etiquetadas, con el propósito de identificar distintos tipos de anomalías. Los tumores cerebrales, que consisten en masas de células anormales desarrolladas en el cerebro, pueden ser benignos o malignos y generan síntomas como dolores de cabeza, alteraciones en la visión y convulsiones. Estas afecciones comparten relevancia clínica con otras enfermedades cerebrovasculares, como los accidentes cerebrovasculares (ACV), aneurismas y malformaciones arteriovenosas (MAV), las cuales figuran entre las primordiales causas de mortalidad y discapacidad a nivel global. Dichas condiciones, originadas por anomalías en el flujo sanguíneo cerebral, pueden provocar lesiones tisulares permanentes si no se detectan a tiempo. Por ello, la detección precoz es esencial para reducir la tasa de mortalidad y mejorar la calidad

de vida de los pacientes. Sin embargo, este desafío persiste debido a la complejidad de los síntomas clínicos y a la necesidad de tecnologías avanzadas para un diagnóstico preciso (OMS, 2022).

En una situación inusual, se produce una mutación en el ADN de un individuo humano, lo que ocasiona una duplicación anormal de las células en el cerebro, resultando en una división acelerada y una mayor longevidad de estas células en comparación con las células normales. Las células anómalas se agrupan formando una masa que puede localizarse en diferentes áreas del cerebro. La acumulación de células anómalas en el cerebro se define como un tumor cerebral. Los tumores cerebrales tienen la capacidad de dañar las células sanas o no anómalas del cerebro. Los tumores en el cerebro pueden clasificarse en benignos o malignos. Los tumores benignos se caracterizan por su naturaleza no cancerosa, mientras que los tumores malignos se distinguen por su capacidad de invadir y propagarse a otros tejidos del cuerpo humano, siendo también denominados cancerígenos. (Molina et al.,(2021))

Chandara et al., (2018), propone que los tumores cerebrales pueden ser clasificados según su origen en primarios, cuando se originan en el cerebro mismo, y cuando se originan en otras partes del cuerpo y se propagan al cerebro, provocando metástasis. Las neoplasias primarias pueden clasificarse en malignos y benignos, mientras que las neoplasias secundarias son siempre malignas.

Completando la idea de Chandara, Díaz & Martínez, (2022), mencionan que la técnica de diagnóstico predominante en la actualidad es la resonancia magnética (RM) y que es un procedimiento que genera imágenes transversales del cuerpo sin emplear radiación, sino basándose en el principio del magnetismo. Además, en muchas ocasiones genera representaciones visuales de estructuras de tejidos blandos que suelen resultar difíciles de visualizar mediante otras metodologías. La detección de tumores en el cuerpo es comúnmente realizada a través de una técnica específica. En el caso de los tumores cerebrales y de médula, es común emplear resonancias magnéticas con la administración de un agente de contraste. A través de esta técnica es posible realizar un análisis preciso para determinar la

naturaleza maligna o benigna del tumor, lo que facilita a los profesionales médicos la determinación del periodo de tratamiento requerido.

Clinic, (2023), sugiere que la resonancia magnética ha transformado la práctica de la imagenología médica al ofrecer una visión detallada del interior del organismo humano. Este método es la base importante para el diagnóstico médico gracias a los principios básicos fundamentados en la física de los campos magnéticos y las interacciones con los núcleos atómicos. La resonancia magnética sigue siendo fundamental para mejorar la precisión en el diagnóstico y tratamiento de diversas enfermedades, gracias a su versatilidad y a los avances tecnológicos actuales.

2.2.1. Desarrollo histórico

Modelo de clasificación y detección

De acuerdo a Goodfellow et al., (2016), menciona que la clasificación y detección en ciencia de datos han evolucionado considerablemente en las últimas décadas, impulsadas por progresos en el aprendizaje automático y el procesamiento de grandes volúmenes de datos.

Evolución Histórica de los Modelos de Clasificación

Durante el siglo XX, se dio origen a las primeras aproximaciones, como: Regresión logística y análisis discriminante lineal. Luego la Introducción de las redes neuronales artificiales en la década de 1950, posteriormente los métodos estadísticos como Naïve Bayes y árboles de decisión. (LeCun et al., 2015)

La cúspide del aprendizaje automático (2000-2010), se dio cuando se empezó a desarrollar algoritmos de ensemble, como Random Forest y Gradient Boosting; así mismo se incrementó en el uso de Support Vector Machines (SVM). (Liu & Laptev, 2018)

En la década del (2010-2020) se dio inicio al desarrollo de modelos profundos con redes neuronales profundas para clasificación de imágenes y texto, del mismo modo la aparición de modelos como Convolutional Neural Networks (CNN) y Recurrent Neural Networks (RNN). Las tendencias actuales se basan en el estudio de los modelos de aprendizaje auto-supervisado y aprendizaje por refuerzo profundo, la implementación de Transformer Models en clasificación y detección de anomalías y el uso de métodos explicables en inteligencia artificial (AI) para mayor interpretabilidad. (Schmidhuber, 2020)

Principales Modelos de Clasificación, entre los cuales tenemos Naïve Bayes., Árboles de decisión y Random Forest, Reglas de asociación. En ese mismo sentido tenemos los modelos basados en optimización, tales como: Support Vector Machines (SVM), Regresión logística, Redes neuronales artificiales. (Alloghani et al., 2020)

Para el caso de detección, se tiene los siguientes modelos: métodos estadísticos, isolation forest y one-class SVM, autoencoders y GANs para detección de patrones irregulares y para la detección de imágenes: modelos como YOLO (You Only Look Once) y Faster R-CNN, aplicaciones en vigilancia y medicina. (Goodfellow, I., Bengio, Y., & Courville, A. (2019). *Deep Learning*. MIT Press.)

Tumores cerebrales y resonancia magnética

De acuerdo a Gómez Vega et al., (2019) menciona que los tumores del sistema nervioso central (SNC) se diferencian de las neoplasias en otras partes del cuerpo, ya que representan un desafío tanto diagnóstico como terapéutico, debido a la dificultad en la distinción entre tumores malignos y benignos. Asimismo, la resección quirúrgica no siempre se realiza de manera completa, eso que puede resultar en recaídas y afectar significativamente la función neurológica.

En ese sentido Contreras, (2017), sugiere que los tumores cerebrales constituyen un grupo heterogéneo debido a las diversas líneas celulares de las que se originan. Se pueden clasificar en dos categorías principales: lesiones primarias, que se

originan en células del sistema nervioso central, y lesiones secundarias, que se desarrollan en otras partes del cuerpo y se diseminan al cerebro como metástasis. Los tumores primarios más comunes son el meningioma y el glioblastoma, mientras que las metástasis más prevalentes provienen del cáncer de pulmón, mama y piel. Los tumores cerebrales primarios se categorizan en cuatro grados según la Organización Mundial de la Salud (OMS), clasificándose como de “bajo grado” aquellos de categoría I y II, y como de “alto grado” los de categoría III y IV.

Desde 1979, la Organización Mundial de la Salud estableció un system de clasificación para los tumores primarios del sistema nervioso central (TPSNC), fundamentado en la célula de origen del proceso tumoral y en características morfológicas vinculadas al pronóstico. Considerando estos fenómenos, los TPSNC se clasifican entre tumores: Grado I: Tumores localizados, de crecimiento lento y bajo potencial de transformación como un tumor de mayor malignidad. Grado II: Tumores de contorno difuso, crecimiento lento y, en algunos casos, con propensión a evolucionar hacia tumores de mayor malignidad. Grado III: Tumores infiltrativos con células atípicas o anaplásicas y un incremento en el número de mitosis. Grado IV: Tumores de crecimiento acelerado con elevada tasa mitótica, que pueden exhibir vasos neoformados y zonas de necrosis. (Sinning, 2017)

Kopec et al., (2021) indica que los tumores cerebrales pueden ser benignos, es decir, sin células cancerosas, o malignos, que contienen células cancerosas de rápido crecimiento que invaden o proliferan en áreas sanas del cerebro. Asimismo, se clasifican en dos categorías distintas según su origen: Los tumores cerebrales primarios se desarrollan dentro del cerebro, incluyendo el parénquima cerebral, la médula espinal o los nervios, y surgen cuando las células presentan mutaciones en su ADN. Pueden ser benignos o malignos. Un tumor metastásico o secundario se origina cuando las células cancerosas, comúnmente localizadas in los pulmones, las mamas y el colon, se diseminan en otras áreas del cuerpo, incluyendo el cerebro. Existen diversas categorías de tumores primarios. Los gliomas son tumores que se originan en el cerebro o en la médula espinal. Los gliomas constituyen el tipo más común de tumor cerebral en adultos, siendo responsables de aproximadamente el 42% de los tumores

cerebrales en esta población. Meningiomas: tumores que se originan en las membranas que constituyen la envoltura externa protectora del cerebro y la médula espinal. Un cuarto de todos los tumores cerebrales y medulares son meningiomas, de los cuales hasta el 85% son benignos. Los meningiomas pueden surgir a cualquier edad, aunque su incidencia se incrementa notablemente en individuos mayores de 65 años. Las mujeres presentan el doble de probabilidad que los hombres de desarrollar meningiomas. Generalmente, su crecimiento es lento y rara vez provocan síntomas. El tumor pituitario es un crecimiento anómalo que se origina en la glándula pituitaria, situada en la base del cerebro, detrás de la nariz. Algunos tumores pituitarios secretan cantidades excesivas de hormonas que regulan funciones corporales esenciales o producen niveles insuficientes de hormonas. La mayoría de los tumores hipofisarios son neoplasias benignas, denominadas adenomas. Estos se mantienen en la glándula pituitaria o en los tejidos circundantes y nunca se propagan en otras regiones del cuerpo.

Paul Lauterbur, un físico contemporáneo de Damadian, aplicó la técnica de RMN utilizando diversos gradientes magnéticos en las tres dimensiones del espacio para poder ejercer campos magnéticos de distinta intensidad en los diferentes puntos de un objeto en análisis. Esto permitía el registro de señales de diversas radiofrecuencias provenientes de cada punto espacial, generando una imagen en escala de grises que contenía la información de cada punto registrado, esto cual dio origen a la técnica de Imagen por Resonancia Magnética (IRM). (Acosta González, 2014)

Damadian, distinguido como el creador del primer escáner de resonancia magnética, demostró en 1971 que esta técnica podía ser empleada para la detección de patologías como el cáncer, constituyendo un punto de inflexión en la historia médica. Sus estudios iniciales en la caracterización de tejidos mediante resonancia magnética propiciaron el diseño de equipos de vanguardia, fundamentales en la práctica clínica contemporánea. Este estudio subraya no solo su repercusión técnica, sino también el impacto cultural y científico de la resonancia magnética en la interpretación del cuerpo humano y la identificación de patologías, consolidando su legado en la evolución del pensamiento médico.

La resonancia magnética ha revolucionado todas las disciplinas médicas, proporcionando una visualización más tangible y auténtica del organismo humano. Por ejemplo, en el campo de la neurología, la resonancia magnética ha proporcionado una perspectiva sobre el cerebro vivo, permitiendo a los investigadores mapear la estructura y funcionalidad cerebral. Esta tecnología, aplicada en diversas investigaciones, ha propiciado progresos significativos en la comprensión y tratamiento de trastornos neurológicos como el Alzheimer, la esclerosis múltiple y la epilepsia. Adicionalmente, se enfatiza la relevancia de la resonancia magnética en el diagnóstico de afecciones del sistema nervioso central. (Cedeño et al., 2024)

Por otro lado Acosta González, (2022) , estableció que la resonancia magnética desempeña un papel crucial en la identificación y caracterización de neoplasias cerebrales debido a su elevada resolución y habilidad para distinguir entre tejidos. Se trata de un procedimiento no invasivo que facilita la determinación del tipo de lesión, previene la realización de biopsias innecesarias y ofrece datos que facilitan la clasificación de los tumores. Esto permite mejorar la precisión del diagnóstico y la identificación de estrategias terapéuticas óptimas.

La resonancia magnética constituye un método diagnóstico empleado para adquirir imágenes de órganos y tejidos corporales, con la finalidad de simplificar el diagnóstico de una enfermedad o la visualización de una lesión. Se emplea una máquina que produce campos magnéticos mediante ondas de radio. Mediante la interacción de las ondas con el organismo, un ordenador las transforma en imágenes que contribuyen al diagnóstico. (Portal salud, s.f.)

La tomografía computarizada (TC) se destaca como uno de los instrumentos más frecuentemente utilizados para la identificación temprana de neoplasias cerebrales. Este enfoque emplea imágenes transversales del cerebro, facilitando la detección de anomalías en su estructura. La tomografía computarizada es rápida y comúnmente accesible en la mayoría de los establecimientos médicos. Actualmente, la Resonancia Magnética (RM) constituye el estándar de referencia para la identificación de neoplasias cerebrales. Emplea un campo magnético y

ondas de radio para producir imágenes detalladas de la estructura cerebral. La resonancia magnética con contraste proporciona a los profesionales médicos una visualización más precisa de los tumores, permitiendo distinguir entre el tejido sano y el afectado por la enfermedad. Es especialmente beneficioso para la detección de tumores en zonas difíciles de visualizar mediante la Tomografía Computarizada. (Bhattacharya & Mahajan, 2024)

La integración de imágenes de resonancia magnética con técnicas de ciencia de datos ha facilitado progresos notables en la identificación y clasificación de tumores cerebrales, proporcionando instrumentos valiosos para el diagnóstico y tratamiento de dichas patologías. (Afshar et al., 2018)

Los escáneres de imagenología por resonancia magnética son particularmente adecuados para la adquisición de imágenes de las regiones no óseas o de los tejidos blandos del organismo. El cerebro, la médula espinal y los nervios, junto con los músculos, ligamentos y tendones, se perciben con una mayor claridad en comparación con los rayos X y la tomografía computarizada (TC) convencionales. (Uner, s.f.)

2.2.2. Fundamentación teórica

Una neoplasia o tumor se define como una masa anómala que emerge como resultado de un incremento anormal en la proliferación celular. Esta puede manifestarse de manera maligna o benigna. El glioma, el meningioma y el tumor de la pituitaria son los tumores más prevalentes en el sistema nervioso central. El glioma surge a partir de las células neurogliales, conforme a lo estipulado por el Instituto Nacional del Cáncer (NIH): "células que mantienen las neuronas en su lugar y las ayuda a funcionar como deben". Una de las evaluaciones sugeridas para el estudio de esta forma de neoplasia es la resonancia magnética (MRI), dado que facilita la visualización precisa del edema cerebral. (Pérez M. , 2024)

Es importante saber que un tumor cerebral es definido como, la neoplasia derivada de los componentes celulares normales o tejidos embrionarios ectópicos. Puede ser una neoplasia secundaria de origen extracraneal con metástasis en el sistema nervioso central. También mencionado como enfermedades no neoplásicas que pueden imitar a los tumores. Además, se conceptualiza como una lesión originada por el crecimiento anómalo de células cerebrales o la proliferación descontrolada de las mismas. Las neoplasias cerebrales primarias comprenden cualquier lesión que se origina en el cerebro y que no se propaga hasta el cerebro desde otras regiones del organismo.

Además, todo proceso neoplásico se localiza tanto en la cavidad craneal como en las paredes internas de la misma (Nayeli, 2013); por lo cual para detectarlo a tiempo es necesario tomar una resonancia magnética haciendo uso de técnicas multimodales es fundamental para mejorar la detección y clasificación de tumores cerebrales.

En los últimos cinco años, se ha demostrado que la integración de diversas modalidades de imágenes es un método prometedor para aumentar la precisión en la identificación de tumores cerebrales. Las técnicas multimodales combinan información obtenida de resonancia magnética, tomografía por emisión de positrones (PET) y tomografía computarizada (CT) con el fin de ofrecer una perspectiva integral del tumor y su entorno circundante (Fang, 2019). La observación conjunta de imágenes permite a los profesionales de la medicina analizar tanto la morfología como la actividad metabólica de la neoplasia, aspecto crucial en la distinción entre tumores malignos y benignos.

De acuerdo con la Organización Mundial de la Salud y la Asociación Americana de Tumores Cerebrales, el sistema más común de clasificación utiliza una escala del I al IV para clasificar tumores de tipo benigno y maligno (Bahadure et al, 2017). Los tumores benignos se clasifican dentro del primer y el segundo nivel, y los malignos dentro de los últimos dos. Los grados I y II, los gliomas, son también llamados tumores de bajo grado debido a su crecimiento lento, mientras que los grados III y IV son llamados tumores de grado alto debido a que poseen un

crecimiento acelerado. Si los tumores de bajo grado no se tratan, es muy probable que se desarrollen lo suficiente para evolucionar a tumores de alto grado. Los pacientes con gliomas de grado II requieren un monitoreo serial y observaciones por medio de Imágenes por Resonancia Magnética IRM o Tomografía Computacional TC cada seis a doce meses. Los tumores cerebrales pueden afectar a cualquier individuo de cualquier edad y su impacto en el cuerpo puede no ser el mismo para cada individuo (Ordaz Bencomo et al., 2018).

Luego de tener una base de imágenes de cerebro, es necesario empezar con el entrenamiento de un modelo de ML. El aprendizaje profundo (DL) constituye una rama del aprendizaje automático, enfocada en el aprendizaje de características jerárquicas y representaciones de datos. Los algoritmos DL utilizan una disposición de numerosos procesos de procesamiento lineal para extraer características. Conforme se avanza en la red, la salida de cada estrato se transforma en la entrada del siguiente, lo cual contribuye a la abstracción de los datos.

Con un preprocesamiento mínimo, extrae atributos directamente de píxeles de las imágenes. La red empleada es Link Net, que es una arquitectura de red neuronal profunda, ligera y centrada en la segmentación semántica. CNN es una conocida tecnología de aprendizaje profundo que se utiliza en el reconocimiento de imágenes. La convolución y la agrupación son las dos estrategias principales utilizadas. Para lograr un alto nivel de precisión de clasificación, se organizan capas CNN. Además, cada capa convolucional solo descubre algunos mapas de características y se comparten los pesos asociados con los nodos CNN.

2.2.3. Marco conceptual

Para Alcaide-Leon et al., (2019) la resonancia magnética (RM) ha sido tradicionalmente uno de los procedimientos más empleados en la identificación de tumores cerebrales, gracias a su habilidad para producir imágenes minuciosas del cerebro. Los progresos recientes en resonancia magnética, tales como las técnicas ponderadas por difusión (DWI) y la espectroscopía por resonancia magnética (MRS), han incrementado la habilidad de los profesionales médicos para distinguir

entre tumores y otras formaciones anómalas en el cerebro. La caracterización de la composición tisular del tumor y su entorno peritumoral también es posible mediante estos métodos. Sin embargo, Sourbron, (2020) manifiesta que un avance significativo en esta área es la resonancia magnética funcional, la cual posibilita la detección de tumores y la identificación de las regiones cerebrales afectadas por la actividad tumoral. Al analizar las variaciones en el flujo sanguíneo cerebral, es posible adquirir datos acerca de la localización y la repercusión funcional de los tumores, especialmente en zonas delicadas como el tronco encefálico o las regiones motoras.

En estos tiempos el aprendizaje profundo constituye un subcampo del aprendizaje automático, enfocado en el aprendizaje a través de estratos sucesivos de representación gráfica. El término "depth" no se refiere a la profundidad de la comprensión adquirida, sino a la cantidad de capas o niveles de representación que aportan a la red. Además, el Deep Learning se fundamenta en el algoritmo de las redes neuronales, que, en diversas arquitecturas, han evidenciado un rendimiento óptimo en áreas como la visión por computadora, el reconocimiento de voz y el procesamiento de lenguaje natural, entre otros.

(Hidalgo Barrientos, M. F., et al 2021).

Una solución informática destinada a la automatización de la identificación de patologías en las imágenes clínicas. Aunque no constituiría un diagnóstico definitivo sin la firma de un profesional médico, facilitaría la mitigación de los periodos vinculados al proceso, contribuyendo a la identificación de casos que podrían presentar un mayor riesgo para el paciente y, por ende, posibilitando una priorización de una evaluación profesional. Para alcanzar estos objetivos, se ha identificado el aprendizaje profundo, en concordancia con otros autores, como un instrumento eficiente para la predicción y detección de diversas condiciones en los seres humanos.

En el presente estudio se van a utilizar las imágenes de RM de tal manera que se pueda hacer uso de Machine Learning, para hacer la identificación de tumores y la clasificación de las mismas.

2.3. Definición de términos básicos

- Tumor cerebral: se define como un conjunto de células anómalas que proliferan en el cerebro. Estos tumores pueden clasificarse en primarios (metastásicos), cuando se originan en el tejido cerebral, o secundarios (metastásicos), cuando se originan de neoplasias en otras regiones corporales que se propagan al cerebro. Los tumores primarios más frecuentemente observados en individuos adultos comprenden meningiomas y gliomas, mientras que las metástasis cerebrales tienden a originarse de cánceres de pulmón, mama y piel (Gómez.Vega et al., 2019)
- La resonancia magnética: Se trata de una metodología de imagenología médica no invasiva que emplea campos magnéticos y ondas de radio para producir imágenes detalladas de los órganos y tejidos corporales. La resonancia magnética es particularmente valiosa para el diagnóstico de diversas afecciones médicas, dado que proporciona una elevada resolución de contraste entre los diversos tejidos blandos (Kohn, 2009)
- Aprendizaje profundo: se trata de una subdisciplina del aprendizaje automático enfocada en la utilización de redes neuronales artificiales de múltiples estratos para la modelización y extracción de características complejas de grandes volúmenes de datos. Esta metodología ha evidenciado su efectividad en tareas tales como el reconocimiento de voz, la visión por computadora y el procesamiento del lenguaje natural. (Campaz-Usuga, 2021)
- Aprendizaje automático: se trata de una subdisciplina de la inteligencia artificial centrada en el desarrollo de algoritmos y modelos que habilitan a las máquinas computacionales para adquirir y realizar predicciones o decisiones fundamentadas en información. Contrariamente a los sistemas que se rigen por directrices explícitas, el aprendizaje automático reconoce

patrones en los datos con el objetivo de optimizar su desempeño en tareas específicas. (González H. , 2023)

- Redes convolucionales: Se trata de modelos computacionales inspirados en el cerebro humano, compuestos por nodos interconectados denominados neuronas artificiales. Estas redes desempeñan un papel crucial en el aprendizaje automático y el aprendizaje profundo, y se emplean en tareas complejas como el reconocimiento de voz, la visión por computadora y la traducción automática. (LeCun Y. , 2015)

Capítulo III: Hipótesis y variables

3.1. Hipótesis

3.1.1. Hipótesis general

El modelo de clasificación y detección de tumores cerebrales de imágenes basado en técnicas de aprendizaje automático y profundo mejora la precisión de la clasificación y la detección de tumores cerebrales

3.1.2. Hipótesis específicas

- La utilización de un conjunto de datos diverso y representativo, junto con técnicas adecuadas de preprocesamiento, mejora significativamente el rendimiento del modelo en la clasificación de tumores cerebrales.
- Los modelos basados en redes neuronales convolucionales profundas (CNN) presentan un mayor nivel de precisión en la clasificación de imágenes de tumores cerebrales en comparación con otros modelos de aprendizaje automático tradicionales.
- La validación mediante técnicas como la validación cruzada y el uso de métricas como precisión, recall, F1-score y AUC-ROC permite evaluar de manera efectiva el desempeño de los modelos en la detección de tumores cerebrales.

3.2. Operacionalización de variables

En la presente investigación se han identificado dos variables: imágenes de tumores cerebrales por RM (en función de píxeles) y la categoría del tumor.

3.2.1. Variable 1

Categoría de las Imágenes de tumores cerebrales por RM

3.2.2. Variable 2

Imágenes de tumores cerebrales por RM

3.3. Matriz de operacionalización de variables

Matriz de operacionalización de variables

Variable	Definición conceptual	Definición operativa	Dimensiones	Indicadores	Escala de valoración	instrumentos
V1: Categoría de las Imágenes de tumores cerebrales por RM	Clasificación de imágenes de resonancia magnética cerebral según la presencia o ausencia de tumores, utilizada para el entrenamiento de modelos de detección.	Conjunto de imágenes digitales (PNG, JPG) etiquetadas manual o automáticamente con categorías: "Tumor presente" (1) o "Tumor ausente" (0).	Clasificación binaria	Presencia o ausencia de tumor	Escala nominal: "Tumor presente" (1) / "Tumor ausente" (0)	Dataset médico de Kaggle, con Scripts en Python
V2: Imagen del tumor	Representación visual de una anomalía en el tejido cerebral capturada mediante resonancia magnética.	Regiones segmentadas dentro de las imágenes de RM que corresponden a masas tumorales, obtenidas mediante técnicas de procesamiento de imágenes.	Segmentación del tumor	Área del tumor, Intensidad de píxeles, Forma del tumor	Escala continua (tamaño del tumor en píxeles, intensidad media)	Dataset médico de Kaggle, con Scripts en Python

Capítulo IV: Metodología del estudio

4.1. Enfoque, tipo y alcance de investigación

4.1.1. Enfoque

De acuerdo al enfoque metodológico, la investigación se clasifica en cuantitativa. El motivo de esto se encuentra en la intención de cuantificar y analizar de forma numérica el efecto de tecnologías avanzadas en la identificación de tumores cerebrales. Específicamente se busca optimizar la precisión en la identificación de tumores cerebrales mediante la utilización de resonancia magnética y empleando herramientas avanzadas de análisis de imágenes. El enfoque cuantitativo resulta apropiado para establecer relaciones entre variables y generalizar los resultados a una población más extensa, según lo indicado por Creswell & Creswell, (2018).

4.1.2. Tipo y alcance

El tipo de la investigación es de carácter aplicado y descriptivo.

Se dice que una investigación es de naturaleza aplicada, ya que tiene por finalidad abordar un problema concreto en el campo de la medicina: mejorar la exactitud y eficacia en la identificación de tumores cerebrales mediante el empleo de herramientas avanzadas de análisis de imágenes, como el aprendizaje automático (Hernández Sampieri et al., 2018). El objetivo de la investigación es producir un efecto concreto en la práctica médica.

El alcance de la investigación es descriptivo, porque se refiere a investigaciones que pretenden caracterizar o detallar las propiedades, características y perfiles de un fenómeno, situación o población sin establecer relaciones causales. Hernández Sampieri et al. (2018).

4.2. Diseño de la investigación

El diseño es (Sarmiento, 2019) no experimental y transeccional, debido se orienta al desarrollo y evaluación de modelos para la detección de tumores cerebrales.

De acuerdo con Hernández-Sampieri et al. (2014), un diseño no experimental se caracteriza porque no se manipulan deliberadamente las variables, sino que se observan y analizan tal como se presentan en un contexto determinado. En esta investigación, los datos de entrada (imágenes de resonancia magnética de tumores cerebrales) no son alterados ni intervenidos, sino procesados mediante modelos preentrenados como AlexNet, utilizando las características propias de las imágenes.

En el mismo sentido, el diseño es transversal ya que la recolección de datos y la ejecución de los experimentos se realizan en un único punto en el tiempo. No se realiza un seguimiento temporal de los datos ni de los pacientes, lo que permite una evaluación puntual del desempeño del modelo de clasificación.

4.3. Población y muestra

4.3.1. Población

La población está constituida por 2 BBDD (1° BBDD de 253 imágenes, 2° BBDD de 2747 imágenes) de imágenes de resonancia magnética para la detección de tumores cerebrales.

4.3.2. Muestra

La muestra elegida es de 253 imágenes, de tipo no probabilístico por conveniencia, ya que los datos se derivan de una base específica y no constituyen la totalidad de la población involucrada en el estudio, además dichos datos podrían estar sesgados por la fuente de origen.

4.4. Técnicas e instrumentos de recolección de datos

4.4.1. Técnicas e instrumentos

En la etapa de recopilación de datos secundarios, se emplearán bases de datos accesibles en plataformas de código abierto como Kaggle. Esta plataforma proporciona un amplio acceso a conjuntos de datos pertinentes y bien organizados sobre imágenes de resonancia magnética cerebral, las cuales están etiquetadas con diagnósticos de tumores cerebrales.

Instrumento: Para acceder a la información, se utilizará un programa informático especializado en la descarga y filtrado de datos, como por ejemplo Python con la API de Kaggle. Este software posibilitará la selección de conjuntos de datos que satisfagan los criterios particulares de calidad, cantidad necesarios para la investigación.

Técnica. Se aplicará un enfoque de muestreo no probabilístico, dado que los datos se obtienen de una fuente preexistente con atributos particulares. Se implementarán filtros de calidad con el fin de garantizar la coherencia y relevancia de los datos seleccionados.

4.4.2. Validez y confiabilidad

En este contexto, la validez se entiende como la capacidad de los datos para representar de manera precisa la realidad clínica de los tumores cerebrales y ser utilizados en su análisis. Con el fin de asegurar la validez, se procederá siguiendo los pasos que se detallan a continuación.

La fuente de datos es un paso fundamental en la investigación académica. En Kaggle, cada dataset contiene los detalles acerca de su origen y los objetivos de la recopilación de datos, asegurando que provengan de instituciones reconocidas por su fiabilidad, tales como hospitales o centros de investigación médica acreditados. Asimismo, se examinan las circunstancias en las que se recopilaron estos datos, dado que la presencia de criterios clínicos es fundamental para garantizar su fiabilidad.

Revisión de la documentación del conjunto de datos: Por lo general, cada conjunto de datos cuenta con una descripción exhaustiva que detalla las variables incorporadas, la metodología de recopilación y las limitaciones potenciales. Se verificará la presencia de variables clínicas pertinentes para el diagnóstico de tumores cerebrales en el conjunto de datos, tales como atributos de las imágenes, diagnósticos médicos y datos demográficos, entre otros.

- a. Criterios de inclusión y exclusión en la investigación. En este estudio, se procederá a la selección de datos que cumplan con los criterios establecidos, tales como el tipo de tumor, la calidad de la imagen y la disponibilidad de etiquetas de diagnóstico. Esto asegura que los datos seleccionados sean pertinentes y adecuados para el propósito de la investigación.
- b. La validación de la fiabilidad de la información: La confiabilidad de los datos se refiere a su consistencia y capacidad de ser reproducidos. Con ese propósito, llevaremos a cabo las acciones siguientes:
- c. Evaluación de la coherencia interna: En primer lugar, se procederá a verificar la coherencia y precisión de la información, con el fin de identificar posibles inconsistencias tales como valores atípicos, registros incompletos o duplicados, así como etiquetas inadecuadas. Con este propósito, se utilizarán herramientas de análisis de calidad de datos en los lenguajes de programación Python o R, con el fin de detectar y abordar posibles inconsistencias.
- d. Pruebas de reproducibilidad son esenciales en la investigación científica para verificar la fiabilidad y consistencia de los resultados obtenidos. Se llevarán a cabo análisis en diversas muestras del conjunto de datos con el fin de confirmar la similitud y consistencia de los resultados obtenidos. Esta fase garantiza que los datos cuenten con una estructura coherente y uniforme.
- e. La verificación del etiquetado y la clasificación es un proceso fundamental en la industria para garantizar la correcta identificación y categorización de los productos. En los conjuntos de datos que contienen imágenes etiquetadas, como por ejemplo resonancias magnéticas con diagnóstico

confirmado, se llevará a cabo una verificación para garantizar la correcta clasificación de los tumores.

4.4.3. Procedimiento de recolección de datos

Es importante mencionar, que el conjunto de datos con el cual se va a trabajar, es de la plataforma kaggle; y a la vez informar que se van a trabajar con técnicas distintas a las utilizadas en dicha competición de kaggle.

- Consentimiento informado: Antes de la recolección de datos, kaggle obliga a cumplir con el requisito del consentimiento informado y sobre todo respetar las normas éticas.
- Recolección de imágenes: Las imágenes de resonancia magnética serán obtenidas de la base de datos pública de kaggle.
- Análisis de imágenes: Las imágenes serán procesadas usando tanto métodos tradicionales como avanzados, y en lugar de trabajar directamente con las imágenes se va generar la información correspondiente a cada pixel de la imagen, sin antes realizar procesos de escalamiento manteniendo la calidad de la imagen.

4.5. Técnicas de análisis de datos

Se va a implementar técnicas de aprendizaje supervisado, donde la variable target es dicotómica y se va a comparar diferentes modelos, considerando algunos indicadores como: AUC, accuracy, entre otros.

Capítulo V: Resultados

5.1. Análisis de resultados

En este apartado, se presentan los resultados producto del desarrollo del proyecto de tesis, los cuales están orientados a la evaluación del modelo propuesto para la detección de tumores mediante el análisis de imágenes de resonancia magnética. La organización de este capítulo incluye la descripción de los datos utilizados, el proceso de entrenamiento y validación, así como los indicadores de desempeño del modelo implementado.

5.1.1 Descripción de la base de datos

Para el desarrollo del presente trabajo de investigación se utilizaron dos bases de datos.

- A. La base TUMOR_IMAGEN de Kaggle: compuesta por 253 imágenes.
- B. La base IMÁGENES_CEREBRO de Kaggle: compuesta por 2747 imágenes
- A. ANALISIS DESCRIPTIVO DE LA BASE TUMOR_IMAGEN DE KAGGLE

La base recuperada de Kaggle TUMOR_IMAGEN, está conformada por imágenes de Resonancia Magnética en total compuesta por 253 imágenes

Esta base fue dividida en grupos de datos de:

- A. Imágenes del grupo Tumores (SiT): 155 imágenes.
- B. Imágenes del grupo No Tumores (NoT): 98 imágenes.

Número total de imágenes cargadas: 253

1. ANALISIS DESCRIPTIVO PARA EL GRUPO TUMORES (SiT)

Cantidad de imágenes en SiT: 155 imágenes

En la tabla 1, las imágenes con Tumor (SiT), el tamaño mínimo registrado es de 173 píxeles de ancho por 178 píxeles de alto, mientras que el tamaño máximo alcanza los 1427 píxeles de ancho y 1275 píxeles de alto.

Tabla 1*Características, mínimo y máximo de las imágenes de base de Si Tumores (SiT)*

Características	Ancho (pixel)	Alto (pixel)
Tamaño mínimo en SiT	173	178
Tamaño máximo en SiT	1427	1275

Fuente: elaboración propia,

La Tabla 2, muestra el promedio de las dimensiones de las imágenes en el conjunto de entrenamiento son de 362 píxeles de ancho y 414 píxeles de alto, con un tamaño medio de 31.4 KB. El tamaño de las imágenes varía entre un mínimo de 4.7 KB y un máximo de 297.9 KB. Esta variabilidad en las dimensiones y tamaños resalta la diversidad de la base de datos y representa un desafío adicional en el procesamiento y entrenamiento del modelo.

Tabla 2*Medidas descriptivas de las imágenes si Tumor (SiT)*

Medidas	ancho	alto	tamaño_kb
Cuenta	155	155	155
media	362.03	414.44	31.42
Desviación estándar	208.17	227.25	36.82
mínimo	178.00	173.00	4.73
25%	250.00	295.75	15.94
50%	288.50	345.50	20.98
75%	354.50	418.25	29.56
máximo	1275.00	1427.00	297.99

Fuente: elaboración propia,

En la tabla 3, el formato predominante es el tipo JPEG (154/155) en el grupo SiT, y PGN (1/155)

Tabla 3

Tipos de Formatos de las imágenes de la RM en el grupo SiT

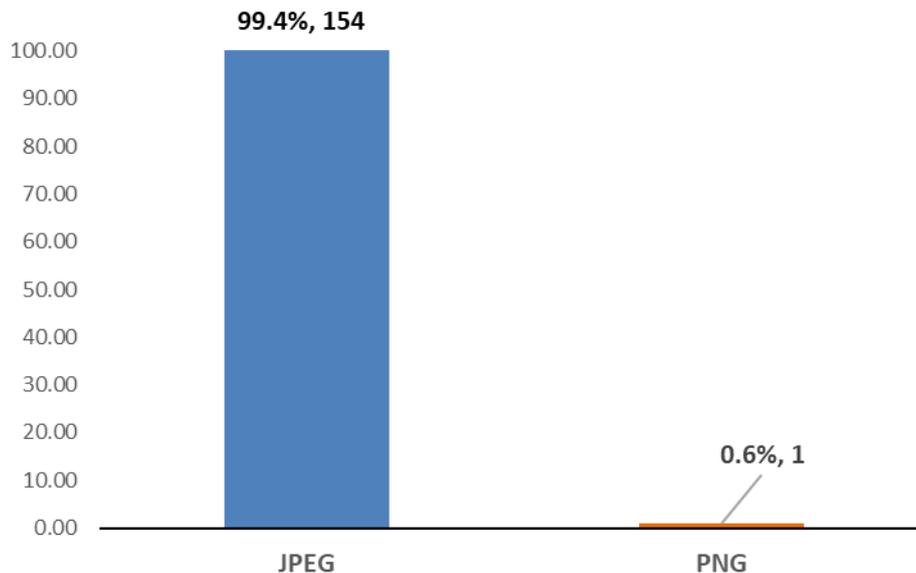
Formatos de imágenes de RM	Grupo SiT
JPEG	154
PNG	01
Total	155

Fuente: elaboración propia,

En la figura 2, podemos ver que el 99.4% (154) de las imágenes de RM tienen el formato de JPEG, a diferencia del 0.6% (1) con el formato PNG.

Figura 2

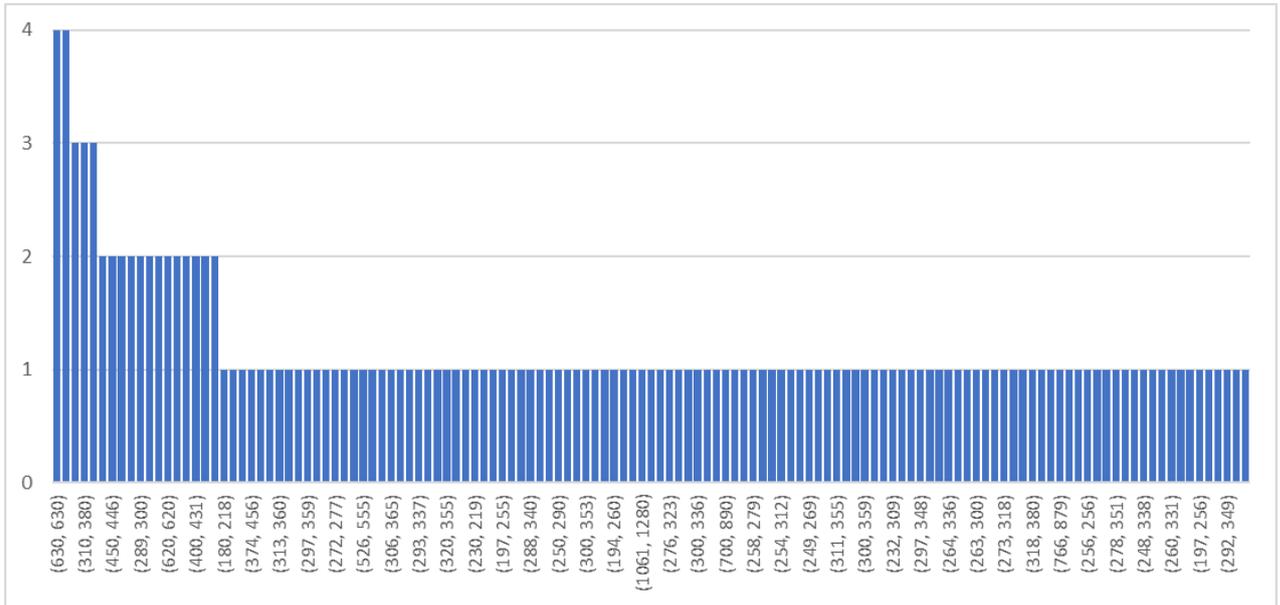
Distribución de imágenes según tipo de formato, grupo SiTumor



Fuente: elaboración propia,

En la figura 3 se puede observar una mayor cantidad de imágenes son de una variada dimensión entre 178 x 1275, de ancho y entre 173 a 1427 de ancho de imágenes de la RM de cerebro. Donde se aprecia 4 imágenes de tamaño (300, 325), 4 de tamaño (630, 630) y 3 imágenes de tamaños; (310, 380), (512, 512), (911, 938) y el resto está entre 1 a dos imágenes.

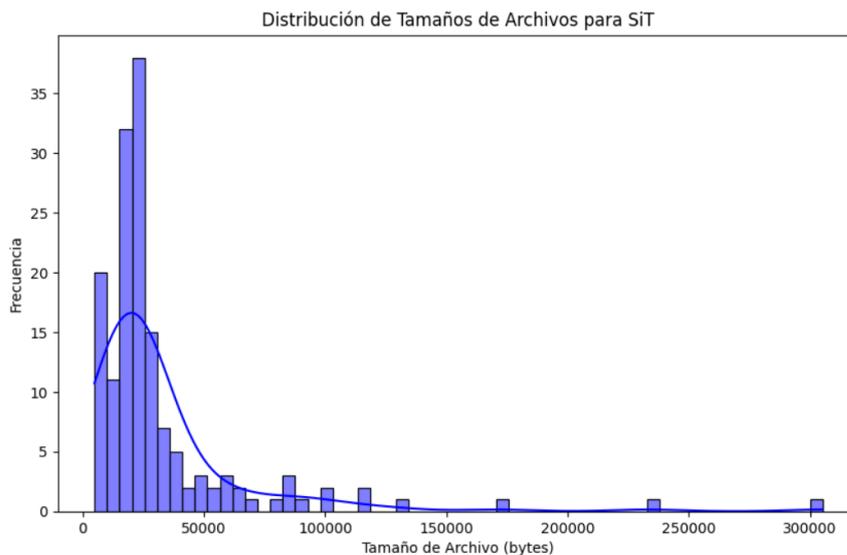
Figura 3
Distribución de imágenes Si Tumor según dimensiones (Ancho x Alto), grupo SiTumor



Fuente: elaboración propia,

En la figura 4, el gráfico muestra un pico muy marcado en los tamaños más pequeños (alrededor de 0 a 20,000 bytes), con una distribución fuertemente sesgada hacia la derecha para las imágenes de tumores.

Figura 4
Distribución de imágenes según tamaño, grupo SiTumor



Fuente: elaboración propia

2. ANALISIS DESCRIPTIVO PARA EL GRUPO NoTumor (NoT)

Cantidad de imágenes en NoT: 98

En la tabla 4, se puede ver que en las imágenes con NoTumor (NoT), el tamaño mínimo registrado es de 168 píxeles de ancho x 150 píxeles de alto, mientras que el tamaño máximo alcanza los 1080 píxeles de ancho y 1920 píxeles de alto.

Tabla 4

Características, mínimo y máximo de las imágenes de base de Si Tumores (SiT)

Características	Ancho (pixel)	Alto (pixel)
Tamaño mínimo en NoT	168	150
Tamaño máximo en NoT	1080	1920

Fuente: elaboración propia,

En la tabla 5, se puede ver que el promedio de las dimensiones para el grupo NoTumor (NoT) es de 345.4 píxeles para el ancho y 344.6 píxeles para el alto y la media del tamaño es de 28.7 kb.

El tamaño mínimo de las imágenes de RM es 3.3 kb y el tamaño máximo es de 299.3 kb.

Tabla 5

Medidas descriptivas de las imágenes no Tumor (NoT)

Medidas	ancho	alto	tamaño_kb
Cuenta	98.00	98.00	98.00
media	345.45	344.68	28.72
Desviación estándar	233.37	183.95	47.40
mínimo	150.00	168.00	3.39
25%	218.00	225.00	5.76
50%	231.00	251.00	7.69
75%	435.75	442.00	29.06
máximo	1920.00	1080.00	299.31

En la tabla 6, el formato predominante en el grupo NoT es el tipo JPEG (92/98) y el tipo PNG es 06/98.

Tabla 6

Tipos de Formatos de las imágenes de la RM en la base de datos

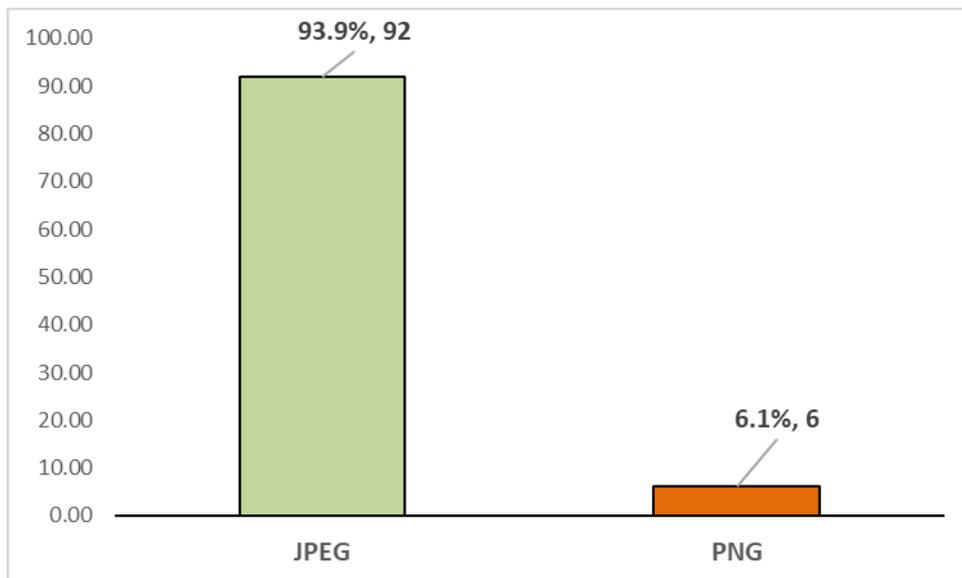
Formatos de imágenes de RM	Grupo No Tumor
JPEG	92
PNG	06
Total	98

Fuente: elaboración propia,

En la figura 5, podemos ver que el 93.9% de las imágenes de RM tienen el formato de JPEG, a diferencia del 6.1% con el formato PNG.

Figura 5

Distribución de imágenes según tipo de formato para el grupo No tumor

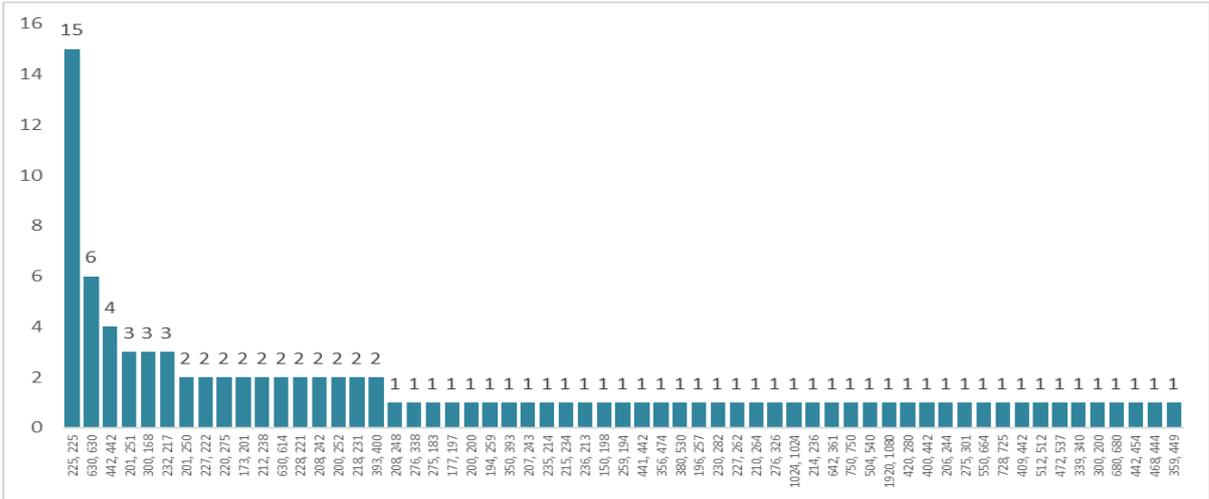


Fuente: elaboración propia,

En la figura 6 se aprecia que la mayor cantidad de imágenes son de una variada dimensión entre 178 x 1275, de ancho y entre 173 a 1427, 14 imágenes son de una dimensión de 350 x 395 de la RM de cerebro. Y se aprecia 15 imágenes de tamaño 225, 225), 6 imágenes de tamaño (630, 630), 4 imágenes de tamaño (442, 442), 3 imágenes de tamaño (201, 251) y el resto de tamaños están entre 1 a dos imágenes.

Figura 6

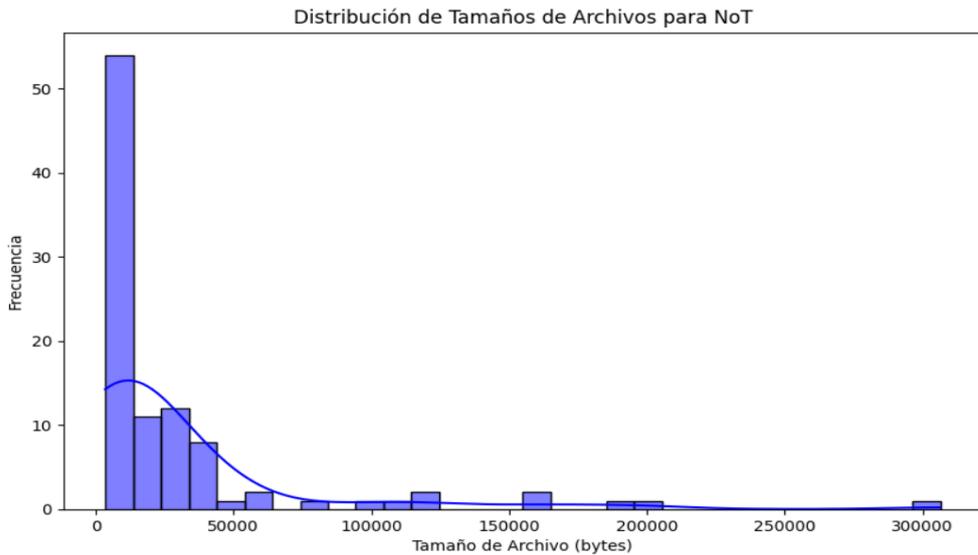
Distribución de imágenes según dimensiones (Ancho x Alto), grupo No Tumor



Fuente: elaboración propia,

En la figura 7, el gráfico muestra un pico muy marcado en los tamaños más pequeños (menores de 50,000 bytes), con una distribución fuertemente sesgada hacia la derecha para las imágenes de No Tumores.

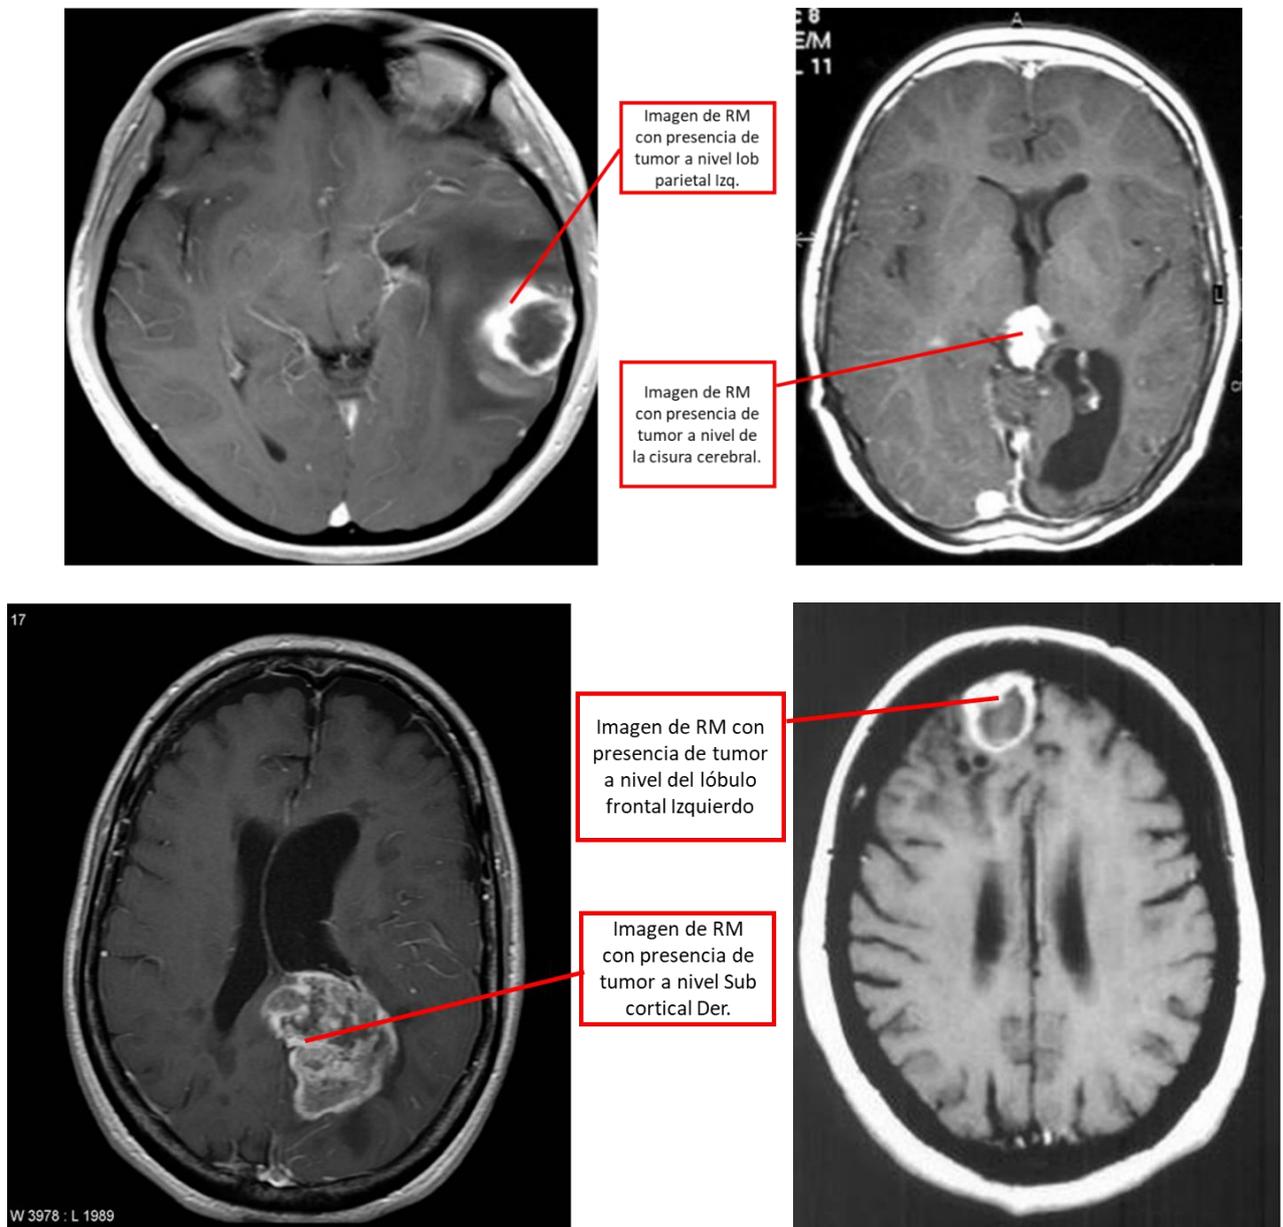
Figura 7
Distribución de imágenes según tamaño, grupo No Tumor



Fuente: elaboración propia,

Figura 8

Imágenes de cerebro que presentan tumor (SiT) por resonancia RM



Fuente: Imágenes de RM Kaggle,

B. ANALISIS DESCRIPTIVO DE LA BASE IMÁGENES_CEREBRO DE KAGGLE

Este análisis empieza con la descripción de la base de datos obtenida de la plataforma Kaggle, la cual está compuesta por un total de 2747 imágenes de resonancia magnética, organizadas en dos categorías principales: imágenes que contienen tumores ("Tumor") e imágenes que no contienen tumores ("No Tumor"). Estas imágenes se distribuyeron de la siguiente manera:

1. **Base de imágenes de Entrenamiento:** Este conjunto estuvo conformado por 2147 imágenes, utilizadas para evaluar el rendimiento del modelo y realizar ajustes en los hiperparámetros. Al igual que el conjunto de entrenamiento, las imágenes también se subdividieron entre las dos categorías principales.
2. **Base de imágenes de Validación:** Este conjunto incluyó 600 imágenes, divididas en dos grupos principales: 300 imágenes de tumores y 300 imágenes de no tumores. Este conjunto se utilizó para entrenar el modelo de clasificación y detección.

1. ANALISIS DESCRIPTIVO PARA LA BASE DE ENTRENAMIENTO

El análisis descriptivo de la base de entrenamiento se expone a continuación; la cual está subdividida en dos grupos: imágenes de tumores (TTumor) e imágenes sin tumores (No Tumor).

En la tabla 7, se puede ver que la base consta de 947 imágenes con tumores y 1,200 imágenes sin tumores con un total de 2147 imágenes.

Tabla 7

Características de las imágenes de base de entrenamiento

Imágenes	Cantidad
Cantidad de imágenes con Tumor:	947
Cantidad de imágenes con No Tumor:	1200
Número de imágenes cargadas:	2147

Fuente: elaboración propia,

En la tabla 8, se observa que el tamaño mínimo para las que tienen Tumor es 173 píxeles para el ancho y 180 píxeles para el alto, y el tamaño máximo es 1427 píxeles para el ancho y 1275 píxeles para el alto.

Igualmente, para las imágenes que no tenían tumor es 168 píxeles para el ancho y 150 píxeles para el alto y el tamaño máximo es 1080 píxeles para el ancho y 1920 píxeles para el alto.

Tabla 8*Características de las imágenes de base de entrenamiento*

Características	Ancho	Alto
Tamaño mínimo en Tumor:	173	180
Tamaño máximo en Tumor:	1427	1275
Tamaño mínimo en NoTumor:	168	150
Tamaño máximo en NoTumor:	1080	1920

Fuente: elaboración propia,

En la tabla 9, se puede identificar lo siguiente; la media de las dimensiones en el grupo Tumor de la base entrenamiento es de 351.1 pixeles para el ancho y 399.8 pixeles para el alto y la media del tamaño es de 25.8 kb.

El tamaño mínimo de las imágenes de RM es 5.7 kb y el tamaño máximo es de 264.7 kb.

Tabla 9*Medidas descriptivas de las imágenes del grupo Tumor, base entrenamiento*

Medidas	ancho	alto	tamaño_kb
Cuenta	947.00	947.00	947.00
media	351.08	399.81	25.81
Desviación estándar	192.04	202.45	24.51
mínimo	180.00	173.00	5.78
25%	250.00	295.00	12.94
50%	283.00	344.00	18.14
75%	353.00	375.00	28.15
máximo	1275.00	1427.00	264.70

Fuente: elaboración propia,

En la tabla 10, se establece que; la media de las dimensiones en el grupo No Tumor de la base entrenamiento es de 301.9 pixeles para el ancho y 308.6 pixeles para el alto y la media del tamaño es de 25.8 kb.

El tamaño mínimo de las imágenes de RM es 3.3 kb y el tamaño máximo es de 710.8 kb.

Tabla 10*Medidas descriptivas de las imágenes del grupo No Tumor, base entrenamiento*

Medidas	ancho	alto	tamaño_kb
Cuenta	1200.00	1200.00	1200.00
media	301.94	308.63	18.27
Desviación estándar	151.09	144.43	27.82
mínimo	150.00	168.00	3.39
25%	214.75	225.00	8.34
50%	227.00	240.00	11.35
75%	380.00	400.00	19.63
máximo	1920.00	1080.00	710.85

Fuente: elaboración propia,

En la tabla 11, el formato predominante es el tipo JPEG (942/947), y en el grupo No Tumor (1195/1200)

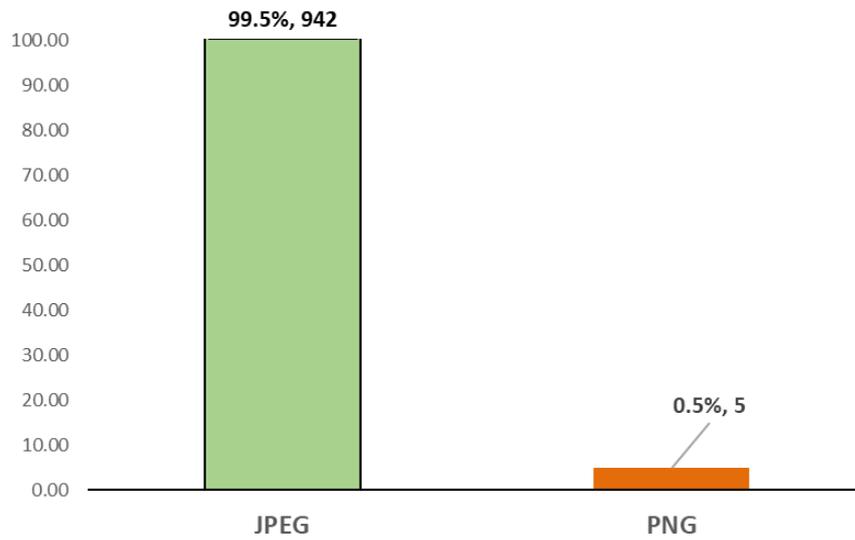
Tabla 11*Tipos de Formatos de las imágenes de la RM en la base de entrenamiento*

Formatos de imágenes de RM	Grupo TTumor	Grupo No Tumor
JPEG	942	1195
PNG	05	05
Total	947	1200

Fuente: elaboración propia,

En la figura 9 podemos ver que el 99.5% de las imágenes de RM tienen el formato de JPEG y solo el 0.5% tienen el formato PGN

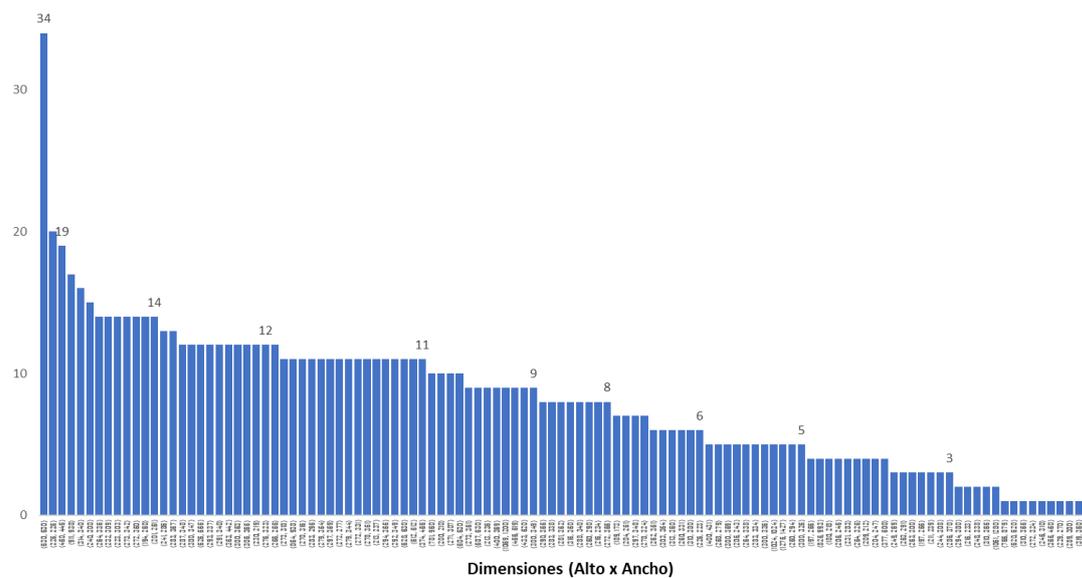
Figura 9
Distribución de imágenes según: tipo de formato



Fuente: elaboración propia,

En la figura 10 se observa que hay una distribución casi uniforme de los tamaños de las imágenes

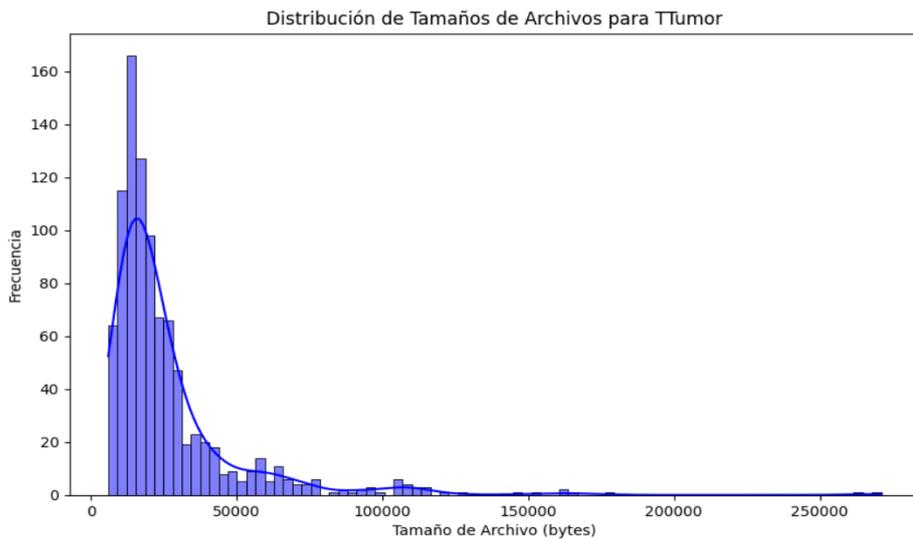
Figura 10
Distribución de imágenes según: dimensiones (Ancho x Alto)



Fuente: elaboración propia,

El gráfico de la figura 11 muestra un pico muy marcado en los tamaños más pequeños (alrededor de 0 a 20,000 bytes), con una distribución fuertemente sesgada hacia la derecha para las imágenes de tumores.

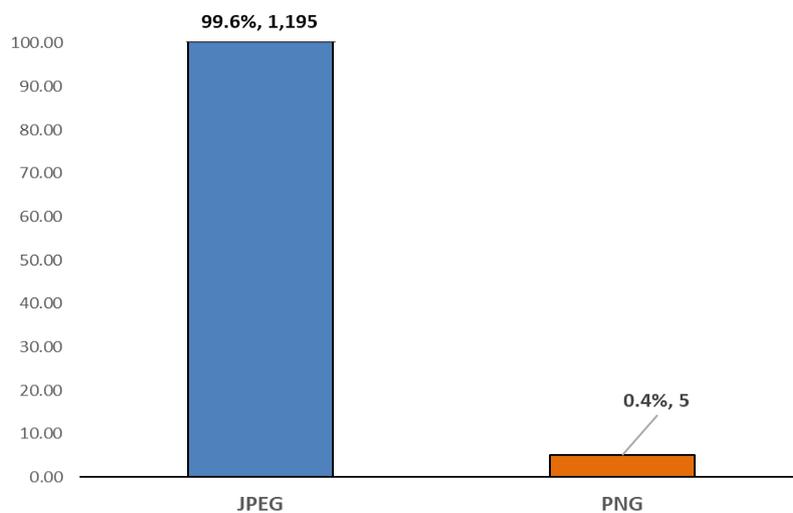
Figura 11
Distribución de imágenes según: tamaño



Fuente: elaboración propia,

En la figura 12, podemos ver que el 99.6% de las imágenes de RM tienen el formato de JPEG, a diferencia del 0.4% con el formato PNG.

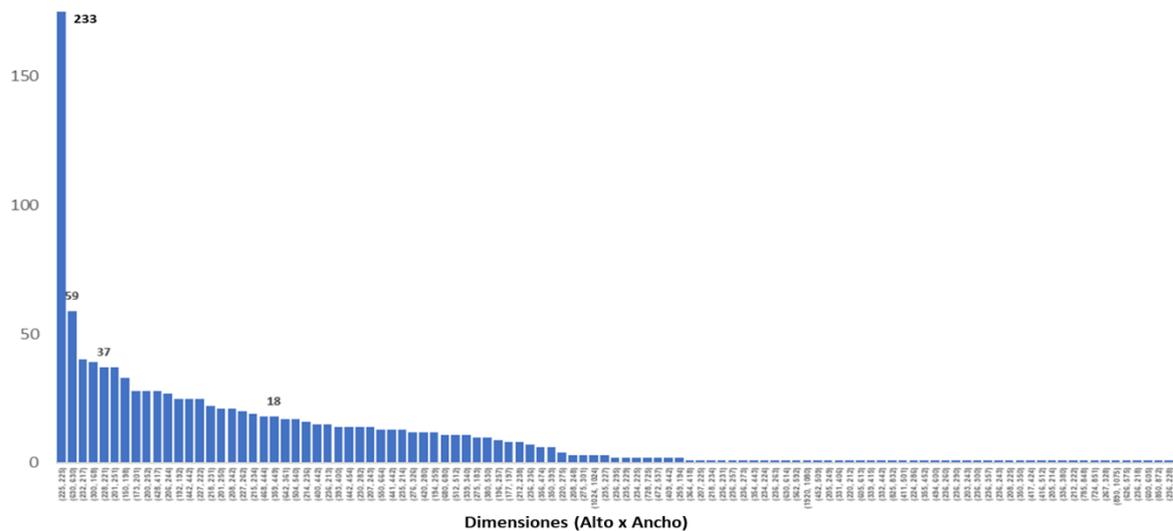
Figura 12
Distribución de imágenes según: tipo de formato para grupo No tumor



Fuente: elaboración propia,

En la figura 13, podemos observar que la mayor cantidad de imágenes son de la dimensión 236 x 213, igualmente aquí se ve una gran variedad de tamaños de imágenes de la RM de cerebro.

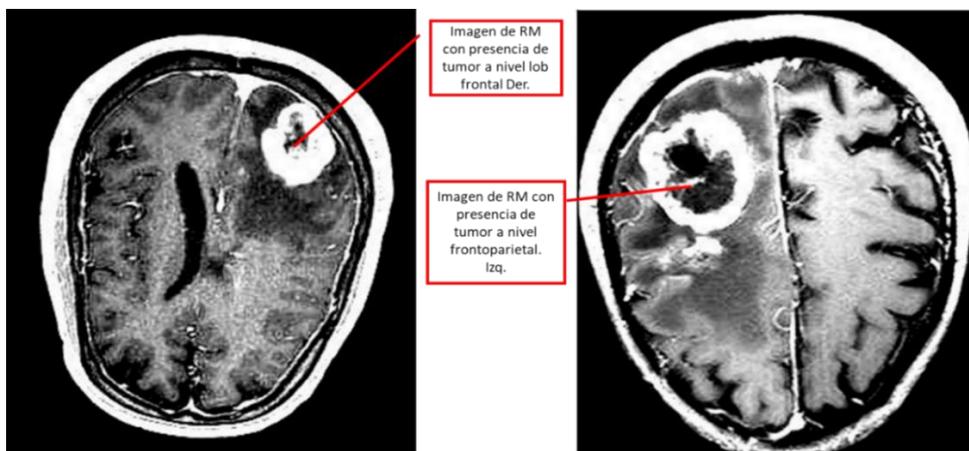
Figura 13
Distribución de imágenes No tumor según dimensiones



Fuente: elaboración propia,

En las imágenes de la figura 14, en el lado izquierdo, se muestra una masa bien definida con un anillo brillante en la periferia, el centro de la lesión es hipointenso (oscuro), lo cual podría corresponder a necrosis, una característica común en tumores malignos de alto grado en el lóbulo frontal derecho.

Figura 14
Imágenes de cerebro que presentan tumor por resonancia



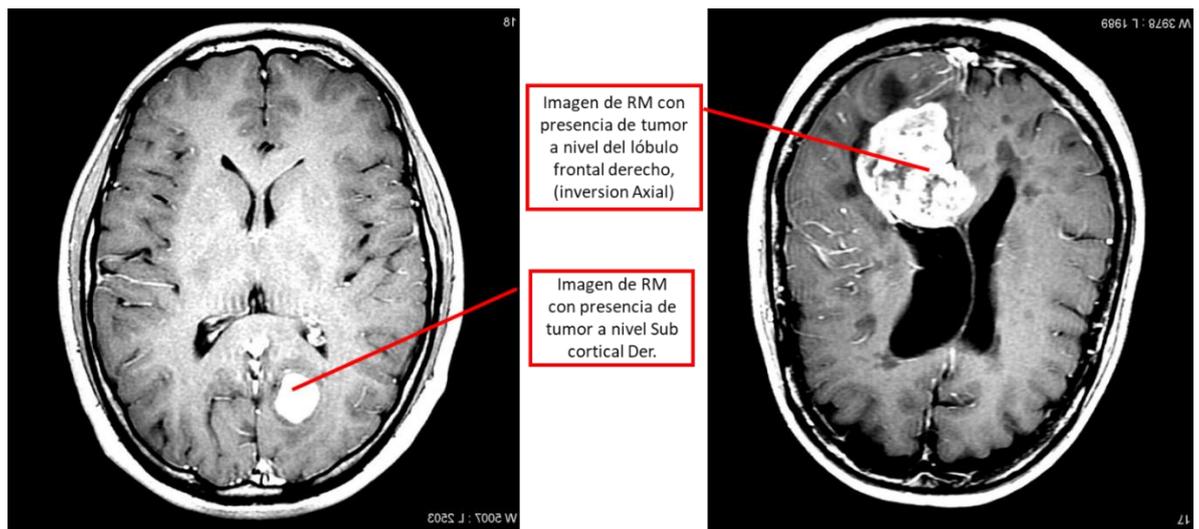
Fuente: Imágenes de RM Kaggle,

En la figura 15, en las imágenes lado izquierdo, hay una región brillante (hiperintensa) en la parte inferior del hemisferio derecho de la imagen, indicativo de un posible tumor o lesión.

La lesión parece bien definida, lo que sugiere que podría estar encapsulada o tener bordes claros en comparación con el tejido cerebral circundante. En la imagen de lado derecho, se identifica una masa en el hemisferio cerebral derecho (a la izquierda de la imagen, debido a la inversión axial), la lesión con borde irregular y ocupa un espacio significativo en el lóbulo frontal derecho, extendiéndose hacia áreas cercanas provocando un desplazamiento significativo de las estructuras cerebrales.

Figura 15

Imágenes de cerebro que presentan tumor por resonancia

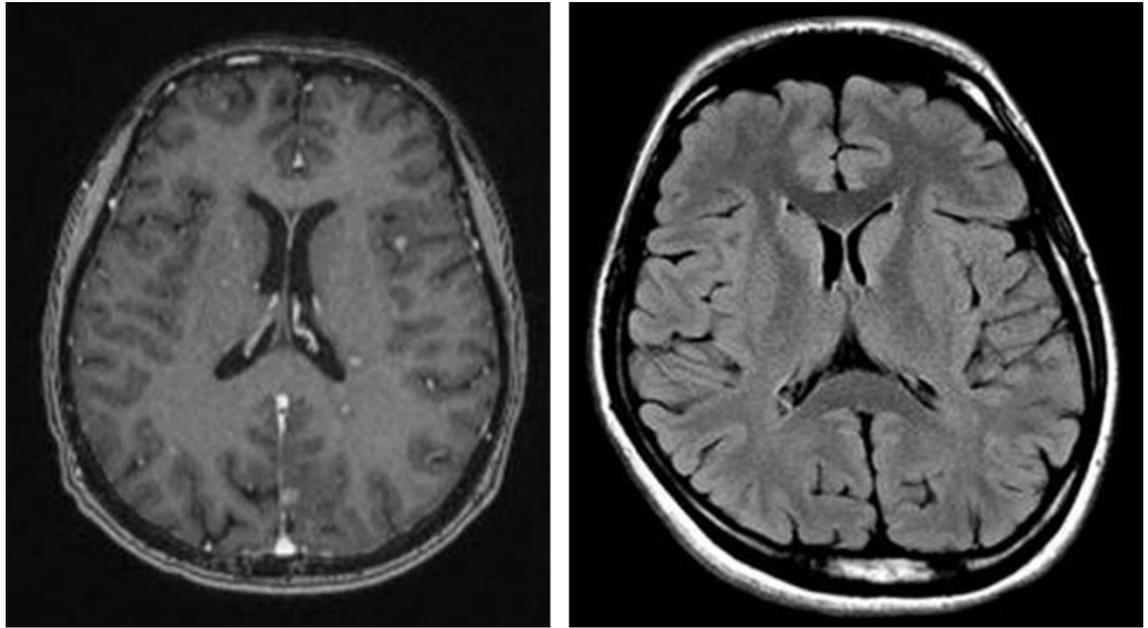


Fuente: Imágenes de RM Kaggle,

En la figura 16, en la imagen del lado izquierdo, se observan las cisuras, surcos y ventrículos laterales visibles, no hay un desplazamiento evidente de la línea media, lo que sugiere la ausencia de masa significativa, los ventrículos laterales están simétricos y no presentan dilatación anormal. En la imagen de lado Derecho, se observa los ventrículos laterales aparecen simétricos y bien delimitados, sin signos de dilatación ni compresión. Esto sugiere la ausencia de hidrocefalia o efecto de masa significativa, la imagen muestra un cerebro estructuralmente conservado.

Figura 16

Imágenes de cerebro que no presentan tumores por resonancia magnética



Fuente: Imágenes de RM Kaggle,

2. ANALISIS DESCRIPTIVO PARA LA BASE DE VALIDACION

En la tabla 12 se puede ver en la distribución de las imágenes en el grupo tumor 300 imágenes y el grupo No Tumor también con 300 imágenes, con un total de 600 imágenes para la base de validación.

Tabla 12

Características de las imágenes de la base de validación

Imágenes	Cantidad
Cantidad de imágenes en Tumor:	300
Cantidad de imágenes en No Tumor:	300
Número de imágenes cargadas:	600
Número de etiquetas cargadas:	600

Fuente: Elaboración propia,

Por otro lado, en lo que respecta al tamaño de las imágenes, la Tabla 13 muestra que, para las imágenes con Tumor, el tamaño mínimo registrado es de 167 píxeles de ancho por 175 píxeles de alto, mientras que el tamaño máximo alcanza los 1427

píxeles de ancho y 1275 píxeles de alto. En contraste, para las imágenes sin Tumor, el tamaño mínimo es de 168 píxeles de ancho por 150 píxeles de alto, y el tamaño máximo es de 680 píxeles tanto de ancho como de alto.

Tabla 13

Características, mínimo y máximo de las imágenes de base de validación

Características	Ancho (pixel)	Alto (pixel)
Tamaño mínimo en Tumor:	167	175
Tamaño máximo en Tumor:	1427	1275
Tamaño mínimo en NoTumor:	168	150
Tamaño máximo en NoTumor:	680	680

Fuente: Elaboración propia,

En la Tabla 14, nos brinda la información de las dimensiones promedio de las imágenes en el conjunto de entrenamiento son de 352 píxeles de ancho y 398 píxeles de alto, con un tamaño medio de 32.4 KB. El tamaño de las imágenes varía entre un mínimo de 4.7 KB y un máximo de 298.9 KB. Esta variabilidad en las dimensiones y tamaños resalta la diversidad de la base de datos.

Tabla 14

Medidas descriptivas de las imágenes de la base de Tumor de la base de validación

Medidas	Ancho	alto	tamaño_kb
Cuenta	300	300	300
media	352.79	398.37	29.79
Desviación estándar	199.49	213.83	32.43
mínimo	175.00	167.00	4.73
25%	231.75	259.50	15.04
50%	283.00	340.00	20.93
75%	374.00	442.00	31.57
máximo	1275.00	1427.00	297.99

Fuente: Elaboración propia

En la Tabla 15, se detalla que las dimensiones promedio de las imágenes sin Tumor en el conjunto de entrenamiento son de 292.1 píxeles de ancho y 299.0 píxeles de

alto, con un tamaño medio de 13.7 KB. El tamaño mínimo registrado para estas imágenes es de 4.5 KB, mientras que el tamaño máximo alcanza los 53.9 KB.

Tabla 15

Medidas descriptivas de las imágenes de la base de No Tumor del grupo de validación

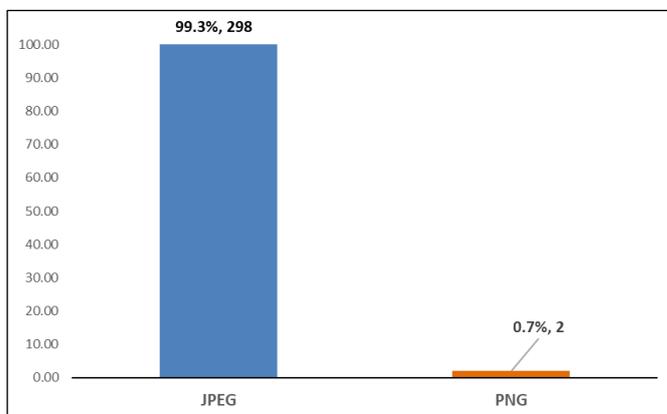
Medidas	ancho	alto	tamaño_kb
Cuenta	300	300	300
media	292.15	299.01	13.78
Desviación estándar	136.05	131.34	9.65
mínimo	150.00	168.00	4.56
25%	213.50	222.00	7.82
50%	213.50	222.00	7.82
75%	356.75	361.00	16.26
máximo	680.00	680.00	53.96

Fuente: Elaboración propia

En la Figura 16, se observa que el formato predominante de las imágenes en el conjunto de validación es JPEG, con 298 imágenes en total. Este formato se mantiene constante tanto para el grupo Tumor como para el grupo No Tumor, con 300 imágenes en cada categoría.

Figura 17

Distribución de imágenes según: tipo de formato

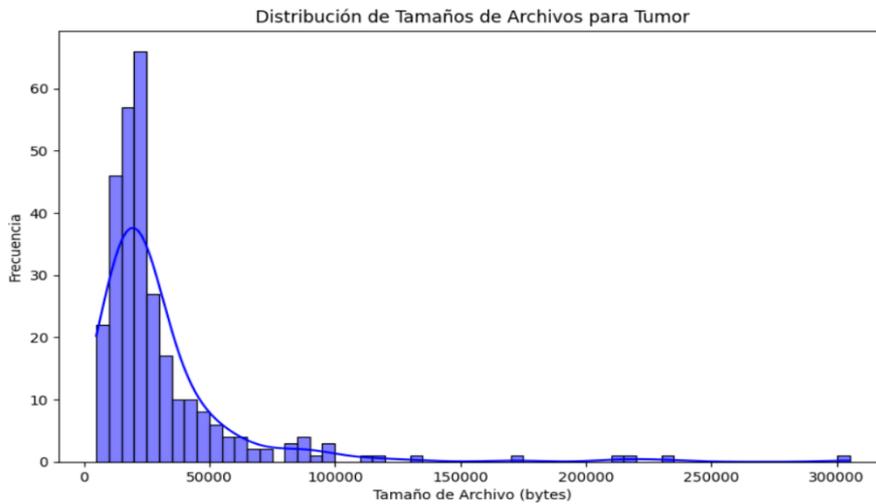


Fuente: Elaboración propia

En la Figura 18, se presenta la distribución del tamaño de archivo (en bytes) para las imágenes de tumores. La distribución muestra un sesgo hacia la derecha (cola

derecha), indicando una menor cantidad de imágenes con tamaños más grandes. Además, se observa un sesgo positivo, ya que la mayor concentración de imágenes corresponde a tamaños más pequeños.

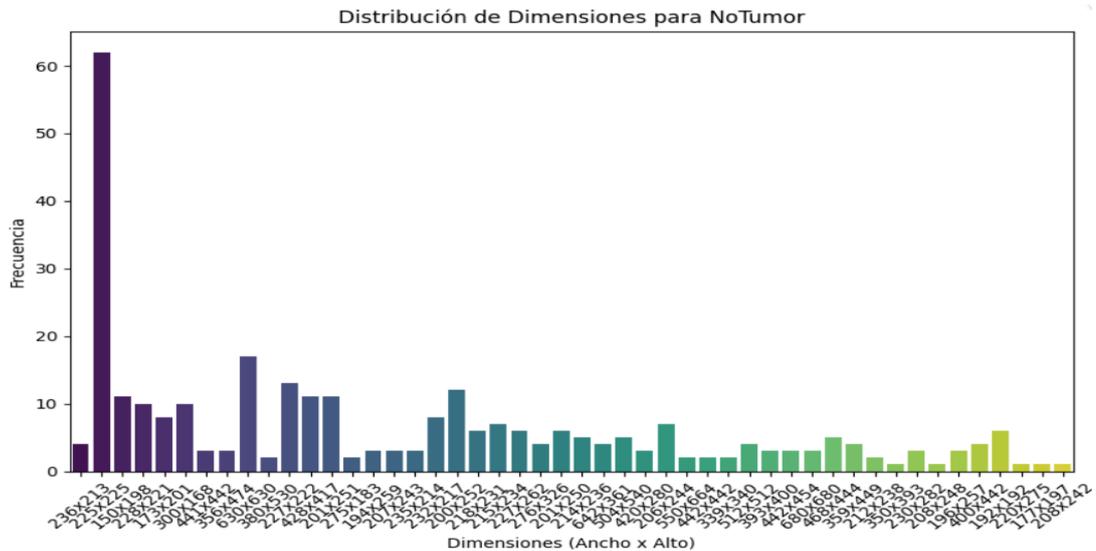
Figura 18
Distribución de imágenes según: tamaño (Bytes)



Fuente: Elaboración propia

Siguiendo la descripción, en la Figura 19 se muestra que la mayor cantidad de imágenes tiene una dimensión de 236 x 213 (60), mientras que también se pueden observar imágenes de resonancia magnética cerebral de diferentes tamaños que hacen parte del set de entrenamiento.

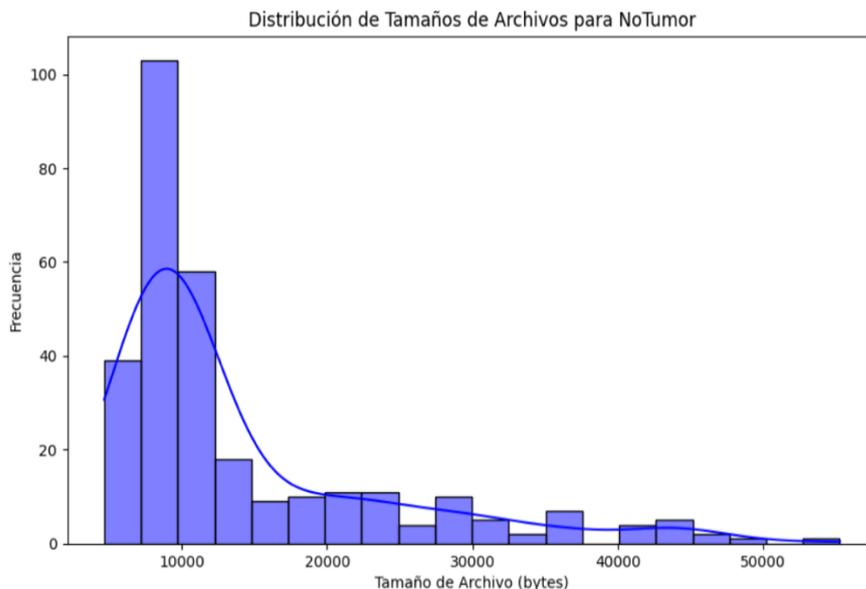
Figura 19
Distribución de las imágenes según: dimensiones



Fuente: Elaboración propia

Asimismo, en las imágenes con etiqueta. “NoTumor”, en la Figura 20, se muestra la distribución del tamaño de archivo (en bytes) para las imágenes de no tumores. La distribución muestra un sesgo hacia la derecha (cola derecha), indicando una mayor cantidad de imágenes con tamaños alrededor de los 10,000 bytes.

Figura 20
Distribución de imágenes según: Tamaño



Fuente: Elaboración propia

5.1.2 Descripción de los modelos utilizados

Este apartado tiene como objetivo presentar los diversos modelos empleados para la clasificación de imágenes de resonancia magnética con tumores. Se proporciona a continuación una descripción exhaustiva de cada uno de los modelos empleados, explicando sus características principales, los enfoques adoptados para la clasificación y las arquitecturas. Posteriormente, se mostrarán los resultados obtenidos con cada modelo, incluyendo métricas de rendimiento y un análisis comparativo de su efectividad en la detección de tumores.

5.1.2.1 Modelo Densenet

DenseNet constituye una arquitectura de red neuronal profunda propuesta por Huang et al. (2017) en su artículo Densely Connected Convolutional Networks, cuyo propósito es optimizar el desempeño en tareas de visión computacional, tales

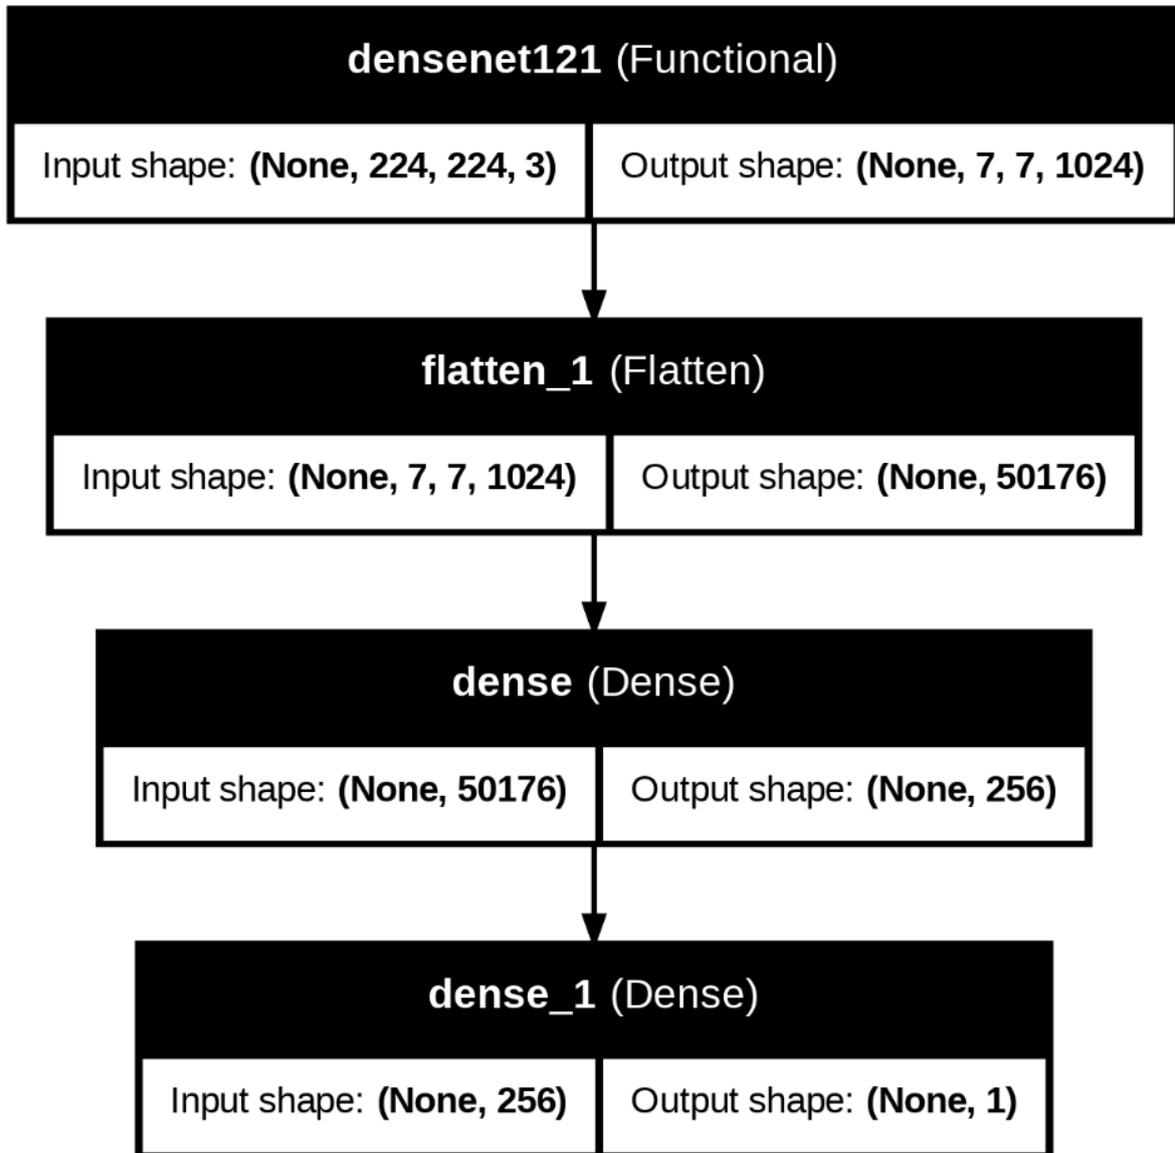
como la clasificación de imágenes y la segmentación. DenseNet121 es una variante de esta arquitectura, cuyo número "121" Hace alusión a la cantidad de estratos o capas que constituyen el modelo.

Esta arquitectura se distingue por su enfoque altamente interconectado, donde todas las capas están conectadas entre sí. A diferencia de las redes neuronales convolucionales tradicionales (CNN), donde cada capa recibe únicamente la salida de la capa anterior, en DenseNet cada capa convolucional, excepto la primera que recibe la entrada, recibe también las salidas de todas las capas anteriores. Este diseño permite que cada capa utilice una mayor cantidad de características, mejorando la capacidad del modelo para identificar patrones más distintivos en las imágenes.

La arquitectura de DenseNet se compone de capas convolucionales de agrupación y completamente conectadas y que facilitan la eficaz extracción de características pertinentes de las imágenes. Uno de los beneficios primordiales de este diseño radica en su habilidad para potenciar la capacidad de adaptación a las fluctuaciones del diseño y para reducir el problema del desvanecimiento del gradiente, mejorando así el entrenamiento de redes muy profundas. No obstante, la complejidad del modelo, debido al gran número de capas y sus interconexiones, conlleva una mayor carga computacional durante el entrenamiento. A pesar de este reto, DenseNet se destaca como una arquitectura potente para tareas de clasificación y otras aplicaciones de visión por computadora.

En cuanto a su arquitectura en la Figura 20 se observa que cada capa convolucional recibe como entrada todas las salidas de las capas anteriores y pasa su salida a todas las capas posteriores.

Figura 21
Modelo Densenet



Fuente: Elaboración propias

La figura 21 representa la arquitectura DenseNet121 que inicia en la capa funcional con la entrada de una imagen de 224x224 píxeles con 3 canales de color (RGB), luego la imagen se convierte en un tensor de salida con 1024 mapas de características de tamaño 7x7. En la siguiente capa flatten el tensor es la entrada y como salida se convierte en un vector unidimensional de 50176 elementos. En la capa dense se reduce la dimensionalidad a 256 neuronas con pesos entrenables.

Y, en la capa dense_1 se obtiene la salida final que tiene una sola neurona, lo que indica que es una tarea de clasificación binaria.

El principio se basa en la concatenación de cada salida desde las capas anteriores hacia las subsiguientes, tal como se evidencia en la imagen precedente. Esta red está constituida por tres bloques densos, y las capas interbloques representan una capa de transición que altera la magnitud del mapa de características mediante la convolución y el pooling.

En el modelo DenseNet, una capa convolucional se erige como un elemento crucial utilizado para la obtención de características de las representaciones gráficas. Estas capas incorporan filtros, también denominados kernels, en la imagen de entrada con la finalidad de identificar patrones, incluyendo bordes, texturas y otros detalles de relevancia.

Por el contrario, se utiliza una capa de agrupación para reducir las dimensiones espaciales del mapa de características, contribuyendo de esta manera a la disminución de la cantidad de parámetros y al costo computacional del modelo en cuestión. Esta característica permite que el modelo conserve la eficiencia computacional mientras continúa extrayendo atributos pertinentes de las imágenes.

Características importantes de DenseNet

Conexiones densas entre las capas del sistema.

En una red neuronal convencional, cada capa está conectada únicamente con la capa inmediatamente siguiente. Sin embargo, en DenseNet, cada capa recibe como entrada las características de todas las capas previas, lo que se conoce como "conexiones densas". Esto significa que en DenseNet, cada capa i -ésima recibe como entrada las salidas de todas las capas anteriores, a diferencia de las redes neuronales convolucionales (CNN) convencionales, donde solo se reciben las salidas de la capa anterior.

La utilización de este método favorece la reutilización de las características obtenidas en las capas anteriores, lo cual contribuye a aumentar de la eficacia en la aplicación de los parámetros. Adicionalmente, estas conexiones densas

contribuyen a atenuar la problemática asociada con el desvanecimiento del gradiente, mejorando el recorrido de la información y el aprendizaje en redes muy profundas. Esto permite que DenseNet logre un mejor rendimiento en tareas de clasificación y otras aplicaciones de visión por computadora, al aprovechar de manera más eficiente las características aprendidas en cada capa.

Este esquema presenta diversas ventajas, como, por ejemplo:

- Optimización del flujo de gradientes. Debido a que cada estrato recibe información de todos los estratos precedentes, el gradiente puede propagarse con mayor fluidez en el proceso de retro propagación. Esta medida contribuye a reducir el fenómeno de la desaparición del gradiente en redes de gran profundidad.
- Reducción de los parámetros. A pesar de la mayor interconexión entre las capas, DenseNet requiere menos parámetros en comparación con otras arquitecturas profundas. Esto se debe a que las conexiones densas posibilitan una reutilización más eficiente de los mapas de características.

2. Estructura del modelo

Una de las características distintivas de DenseNet radica en la utilización de unidades estructurales denominadas "bloques densos". En cada bloque se encuentran diversas capas de convolución, cuyas salidas se concatenan para conformar la entrada de la capa subsecuente. La estructura general de DenseNet se caracteriza por una sucesión de bloques densos intercalados con transiciones entre ellos.

- Bloques densos: En un bloque dado, cada capa recibe como entrada la combinación de las salidas de todas las capas previas. Las capas en general consisten en convoluciones seguidas de normalización por lotes (batch normalization) y funciones de activación (ReLU).

- Capa de transición: Las capas de transición, que suelen consistir en convoluciones 1x1 seguidas de operaciones de submuestreo (pooling), se localizan entre los bloques densos. Las capas mencionadas contribuyen a la disminución de la dimensionalidad de las características, así como a la gestión de la cantidad de parámetros y la complejidad computacional.

3. Ventajas de DenseNet

- La eficiencia en la utilización de parámetros: La eficiencia de DenseNet en comparación con otras arquitecturas de redes profundas se debe a la reducción de la necesidad de aprender múltiples representaciones redundantes mediante la reutilización de características.
- Un aumento en el desempeño en las labores de visión por computadora: DenseNet ha mostrado un rendimiento destacado en diversas tareas, tales como la clasificación de imágenes, como se observa en el conjunto de datos ImageNet, y en la segmentación semántica.
- Capacidad para entrenar redes neuronales profundas. La densa conexión en un esquema mejora el proceso de entrenamiento de redes neuronales con múltiples capas, ya que favorece el flujo óptimo de gradientes y la reutilización eficiente de características.

4. Desventajas

- El requisito de memoria es fundamental para el funcionamiento adecuado del sistema. Aunque los parámetros son eficientes, las conexiones densas incrementan la cantidad de activaciones que deben ser guardadas, lo cual puede resultar en un mayor consumo de memoria en redes de gran profundidad.

- El cálculo resulta en un gasto significativo. La combinación de todas las salidas de las capas previas puede aumentar la complejidad de los cálculos de convolución en términos de tiempo de procesamiento, lo cual es especialmente notable en redes neuronales extensas.

5. Aplicaciones

DenseNet ha sido implementado en diversas funciones de visión por computadora, incluyendo:

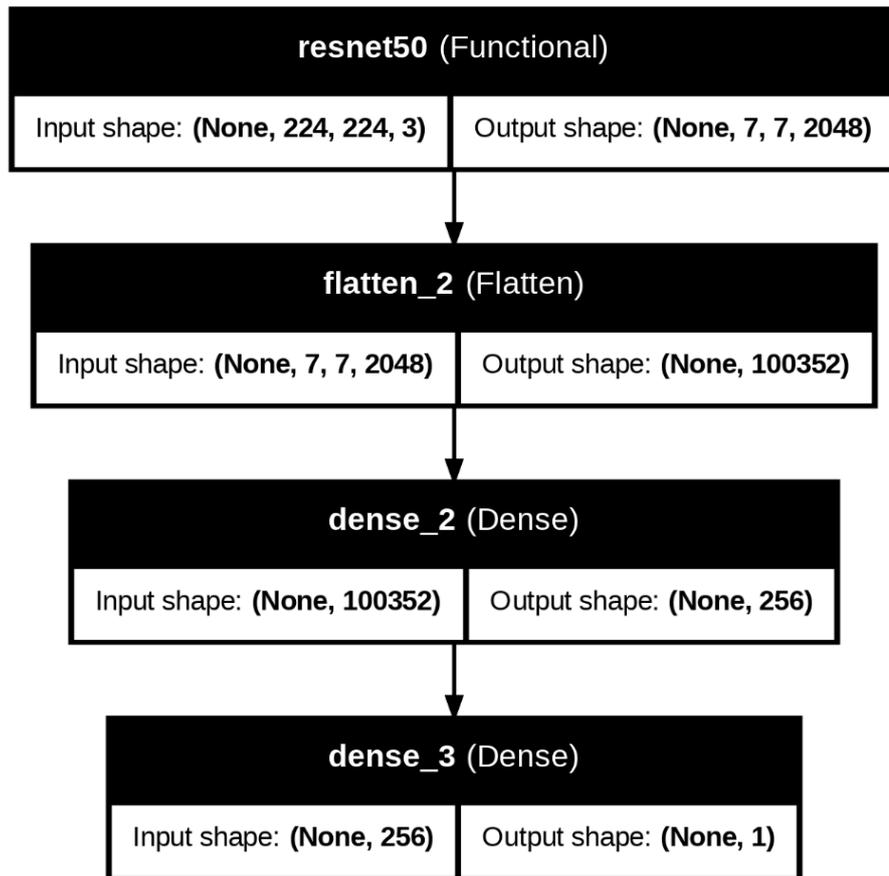
- La clasificación de las imágenes: DenseNet ha evidenciado su competencia en evaluaciones de referencia como ImageNet.
- La segmentación semántica constituye un procedimiento esencial en el ámbito del procesamiento de imágenes. La estructura ha evidenciado su eficacia en una variedad de aplicaciones, tales como la segmentación de imágenes de carácter médico.
- La capacidad de identificar objetos es esencial en el ámbito de la visión por computadora. La capacidad de identificar atributos a diversos niveles ha facilitado su integración en los modelos de detección de objetos.

Modelo ResNet:

En 2015, el equipo de Microsoft Research Asia introdujo la red neuronal residual denominada ResNet. En esta configuración, la topología de la red incorporaba una transición entre conexiones de niveles, lo que implica que las entradas y salidas de la red, para un bloque específico, se fusionan antes de proceder al siguiente. Esta arquitectura consiguió resultados notablemente positivos, logrando la primera posición en el desafío ImageNet Large Scale Visual Recognition Challenge 2015 (ILSVRC 2015) con un error inferior al de la percepción humano. La figura ilustra una representación esquemática de la estructura de los bloques residuales que constituyen los modelos ResNet. Debe subrayarse que los bloques contenidos en

el residual pueden albergar diversas operaciones, tales como convoluciones, normalizaciones, pooling, entre otras. No obstante, es imperativo que las dimensiones de entrada y salida del bloque residual sean idénticas para permitir la ejecución de la operación.

Figura 22
Modelo Resnet



Fuente: Elaboración propia

La figura 22 muestra arquitectura Resnet50 que inicia en la capa funcional con la entrada de una imagen de 224x224 píxeles con 3 canales de color (RGB), luego la imagen se convierte en un tensor de salida con 2048 mapas de características de tamaño 7x7. En la siguiente capa flatten el tensor es la entrada y como salida se convierte en un vector unidimensional de 100352 elementos. En la capa dense se reduce la dimensionalidad a 256 neuronas con pesos entrenables. Y, en la capa dense_1 se obtiene la salida final que tiene una sola neurona, lo que indica que es una tarea de clasificación binaria.

ResNet50 nos permitió abordar el problema de desvanecimiento del gradiente, atribuible a la profundidad de la red. Adicionalmente, esta red permite que los gradientes transiten directamente hacia las conexiones de salto hacia atrás desde las capas posteriores hasta los filtros iniciales, evidenciando un desempeño sobresaliente en tareas de clasificación de imágenes y detección de objetos. ResNet-50 ha ejercido una influencia significativa en la concepción de múltiples arquitecturas subsecuentes, compuesto por más de 23 millones de parámetros. Es claramente inferior a VGG16 y se compone de una serie de bloques residuales que adquieren características a variados niveles de abstracción.

Características importantes de ResNet:

1. Estructura del modelo:

El modelo ResNet-50 es una red neuronal convolucional que se destaca por su uso de bloques residuales y conexiones de salto para mitigar el problema del gradiente que se desvanece. A continuación, se indica los detalles de funcionamiento del modelo:

- **Bloques Residuales:** ResNet-50 se compone de bloques residuales que facilitan a las capas la adquisición de mapeos residuales. Esto se logra mediante la fórmula $(H(x) = F(x) + x)$, donde $(F(x))$ es el mapeo residual y (x) es la entrada original.
- **Conexiones de Salto:** Estas conexiones permiten que la entrada original se salte algunas capas y se sume directamente a la salida de una capa posterior. Esto ayuda a prevenir la desaparición del gradiente y facilita el entrenamiento de redes muy profundas.
- **Capas Convolucionales:** ResNet-50 incluye 48 capas convolucionales, una capa de MaxPooling y una capa de Average Pooling2. Utiliza convoluciones de 1x1, 3x3 y 7x7 para extraer características de diferentes niveles de abstracción.

- **Arquitectura en Botella:** Los bloques residuales de ResNet-50 utilizan un diseño en botella, que consiste en una secuencia de convoluciones 1x1, 3x3 y nuevamente 1x1. Esto reduce el número de parámetros y acelera el entrenamiento.
- **Entrenamiento y Transferencia de Aprendizaje:** ResNet-50 es conocido por su capacidad para ser preentrenado en grandes conjuntos de datos y luego ser ajustado para tareas específicas mediante transferencia de aprendizaje.

2. Ventajas de ResNet

- El entrenamiento eficaz de redes neuronales profundas es fundamental para lograr un buen rendimiento en tareas de aprendizaje automático. ResNet posibilita el entrenamiento de redes neuronales con un mayor número de capas gracias a las conexiones residuales.
- La prevención de la atenuación de gradientes es crucial en la transmisión de señales ópticas a largas distancias. Durante la retropropagación, las conexiones residuales posibilitan una propagación más eficaz de los gradientes, lo cual contribuye a la facilitación del entrenamiento de redes profundas.
- **Rendimiento sobresaliente en el ámbito de la visión computacional:** La red neuronal ResNet ha evidenciado una alta eficiencia en una variedad de tareas de visión por computadora, incluyendo la clasificación de imágenes, la segmentación y la detección de objetos. Su excepcional desempeño se manifiesta particularmente en conjuntos de datos de renombre como ImageNet.

3. Desventajas de ResNet

- ResNet-50 es un modelo profundo con 50 capas, lo que requiere una cantidad significativa de recursos computacionales para entrenar y desplegar. Esto puede ser un desafío en entornos con recursos limitados.
- Como con muchos modelos profundos, ResNet-50 puede ser propenso al sobreajuste, especialmente si se entrena con conjuntos de datos pequeños o no suficientemente variados.
- ResNet-50 puede tener dificultades para detectar objetos pequeños en imágenes debido a su arquitectura, que está más optimizada para la clasificación de imágenes a gran escala.
- El rendimiento de ResNet-50 puede verse afectado negativamente si el conjunto de datos de entrenamiento está desequilibrado, es decir, si algunas clases están sobrerrepresentadas en comparación con otras.
- Debido a su profundidad y complejidad, ResNet-50 puede tener una mayor latencia en la inferencia, lo que puede no ser ideal para aplicaciones en tiempo real.

4. Aplicaciones de ResNet

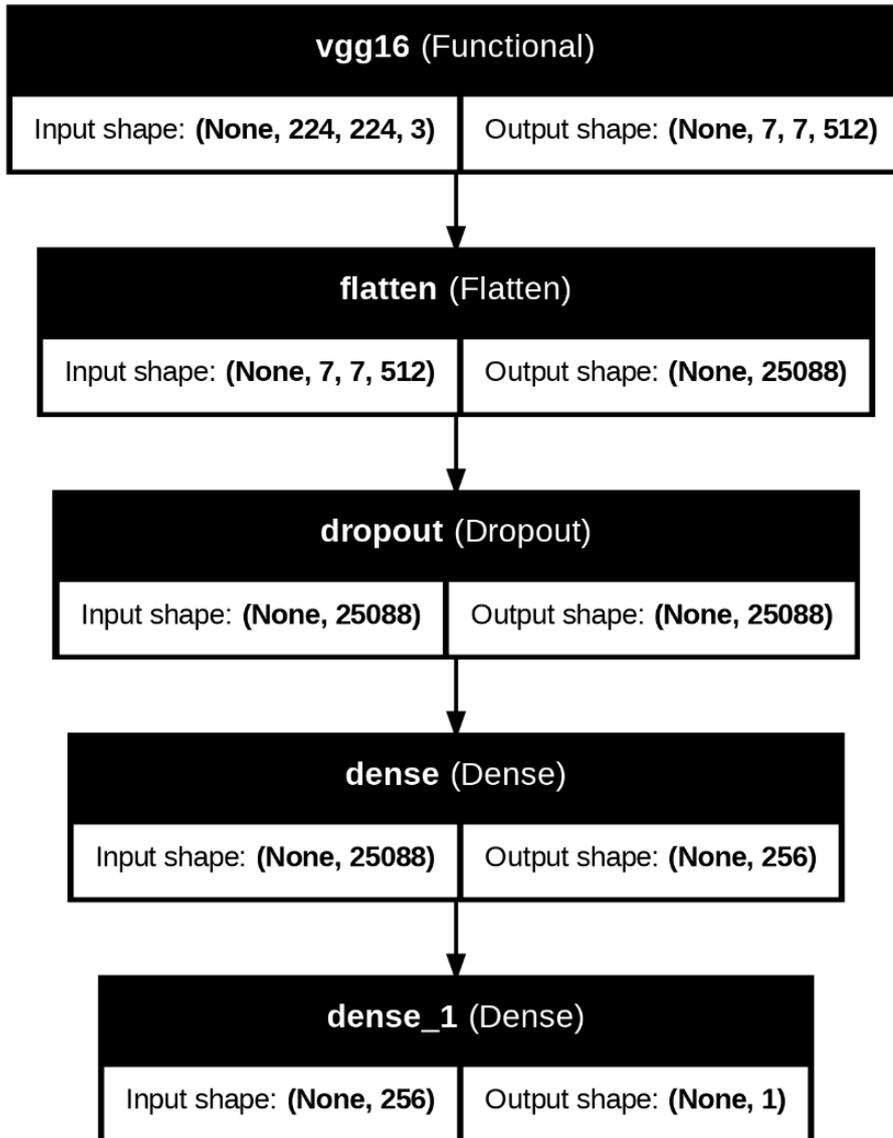
- La categorización de imágenes: El modelo ResNet ha demostrado un alto rendimiento en la clasificación de imágenes, como se evidencia en su destacada participación en el desafío ImageNet.
- La identificación de objetos: Es empleado en los modelos de detección de objetos, como en el caso de Faster R-CNN.

- La segmentación semántica es un proceso primordial en el campo de la ciencia de datos, que consiste en dividir una imagen en regiones significativas con base en su contenido visual. ResNet se utiliza extensamente en redes neuronales como DeepLab para llevar a cabo la tarea de segmentación de imágenes.

Modelo VGG16:

La arquitectura de aprendizaje profundo VGG16 y VGG19 fue una de las primeras en surgir. Simonyan y Zisserman la introdujeron en 2014 en su artículo denominado Very Deep Convolutional Networks for Large Scale Image Recognition (vgg19 network). A continuación, se expone la percepción interna de esta modalidad arquitectónica en el contexto del aprendizaje profundo:

Figura 23
Arquitectura Modelo Vgg16



Fuente: Elaboración propia

La arquitectura VGG16 se basa exclusivamente en bloques constituidos por una secuencia progresiva de capas convolucionales, equipadas con filtros de dimensiones 3×3. La figura 23 inicia en la capa funcional con la entrada de una imagen de 224x224 píxeles con 3 canales de color (RGB), luego la imagen se convierte en un tensor de salida con 512 mapas de características de tamaño 7x7. En la siguiente capa flatten el tensor es la entrada y como salida se convierte en un vector unidimensional de 25088 elementos. En la capa de dropout se reduce el sobreajuste del vector de entrada sin variar la

dimensión. En la capa dense se reduce la dimensionalidad a 256 neuronas con pesos entrenables. Y, en la capa dense_1 se obtiene la salida final que tiene una sola neurona, lo que indica que es una tarea de clasificación binaria.

De acuerdo con Pintos y Simonyan, se recibe una imagen RGB con una resolución fija de 224×224 píxeles. "Redes convolucionales muy profundas para el reconocimiento de imágenes a gran escala" La imagen se transfiere a través de un conjunto de capas convolucionales (conv.), en las cuales se emplean filtros con un campo receptivo extremadamente reducido: 3×3 (el tamaño más pequeño para capturar la noción de izquierda/derecha, arriba/abajo, centro). La Arquitectura se distingue por una configuración sencilla y homogénea, empleando únicamente capas convolucionales de dimensiones 3×3 con stride 1 y capas de pooling de dimensiones 2×2 con stride 2. La implementación de técnicas de mayor sofisticación, tales como convoluciones dilatadas o convoluciones separables en profundidad, es insuficiente. VGG16 representa una Red Neuronal Convolucional de alta profundidad que emplea convoluciones de 3×3 y capas de pooling de 2×2 para la extracción de características de una imagen. Comprende 13 estratos convolucionales, cinco estratos de agrupación y tres estratos totalmente conectados, seguidos de una capa de emisión. A pesar de que esta arquitectura posee una mayor profundidad y una mayor cantidad de parámetros que algunas de las arquitecturas contemporáneas, su sencillez y uniformidad han evidenciado un rendimiento óptimo en numerosas tareas de visión por computadora.

Características importantes de la red neuronal convolucional VGG16.

1. Arquitectura simple y profunda:

La red neuronal convolucional VGG16 se caracteriza por su estructura sencilla pero profunda, compuesta por un total de 16 capas entrenables, lo que le otorga su denominación. Las 16 capas en cuestión consisten en 13 capas de convolución y 3 capas completamente conectadas en el contexto del modelo.

En contraste con otras arquitecturas de redes convolucionales (CNN), VGG16 emplea convoluciones de tamaño reducido, específicamente de 3x3, en lugar de dimensiones mayores como 5x5 o 7x7, que eran habituales en arquitecturas previas.

La arquitectura completa de VGG16 se describe a continuación:

- Entrada: La red toma imágenes de 224x224 píxeles con 3 canales de color (RGB).
- Bloques de convolución y pooling:
 1. Convolución 3x3 → Convolución 3x3 → Max Pooling (2x2)
 2. Convolución 3x3 → Convolución 3x3 → Max Pooling (2x2)
 3. Convolución 3x3 → Convolución 3x3 → Max Pooling (2x2)
 4. Convolución 3x3 → Convolución 3x3 → Max Pooling (2x2)
 5. Convolución 3x3 → Convolución 3x3 → Max Pooling (2x2)
- Capas completamente conectadas:
 1. Capa completamente conectada con 4096 neuronas
 2. Capa completamente conectada con 4096 neuronas
 3. Capa de salida con 1000 neuronas (para clasificar entre 1000 clases en el caso de ImageNet)

2. convolución 3x3

El modelo VGG16 emplea operaciones de convolución con un filtro de dimensiones 3x3 y un paso de 1, lo que implica un procesamiento detallado de las imágenes de entrada. El tamaño de este filtro posibilita la detección de patrones espaciales con gran precisión.

Las capas de convolución se disponen en secuencias, lo que conlleva un aumento gradual en la profundidad de la red sin generar un incremento

significativo en la cantidad de parámetros, en comparación con las redes que emplean filtros de mayor tamaño.

3. Estructura jerárquica

La estructura de VGG16 se compone de bloques secuenciales de capas convolucionales seguidas por capas de pooling. Tras cada bloque de convolución, suele llevarse a cabo una operación de max pooling con dimensiones de 2x2 y un paso de 2, con el propósito de disminuir gradualmente la resolución espacial de las imágenes mientras se conserva la información de mayor relevancia.

La jerarquía se compone de cinco bloques principales de capas, en los cuales los primeros bloques extraen características elementales como bordes y texturas, mientras que los bloques más profundos van adquiriendo patrones de mayor complejidad.

4. Capas completamente conectadas

Las capas completamente conectadas, también denominadas fully connected layers en inglés, constituyen una categoría de capas en una red neuronal artificial en la que cada neurona de una capa está interconectada con todas las neuronas de la capa precedente.

Tras la etapa convolucional, VGG16 incorpora tres capas totalmente conectadas. En el caso de clasificación de imágenes, la capa final genera el vector de salida que representa las probabilidades asociadas a las distintas clases.

Las capas mencionadas cuentan con un elevado número de neuronas, específicamente 4096 en las dos primeras capas completamente conectadas. Esta característica posibilita que la red neuronal adquiera la habilidad de generar representaciones abstractas y de alto nivel de las

imágenes.

5. Activación

En el modelo VGG16, se emplea la función de activación ReLU (Rectified Linear Unit) con el propósito de introducir no linealidad, lo cual facilita un entrenamiento más eficiente al abordar el desafío del desvanecimiento de gradientes.

Parámetros:

A pesar de la simplicidad relativa de su arquitectura, VGG16 cuenta con un elevado número de parámetros, aproximadamente 138 millones, lo que la convierte en una red intensiva en términos de recursos computacionales y memoria, especialmente en contextos donde se manejan grandes cantidades de datos. Esta circunstancia puede representar una restricción al operar con recursos de hardware escasos.

6. Ventajas

- La arquitectura de VGG16 es relativamente simple y fácil de entender, lo que facilita su implementación y modificación.
- VGG16 ha evidenciado una notable precisión en las tareas de clasificación de imágenes, alcanzando un 92.7% de precisión en el conjunto de datos ImageNet.
- Debido a su entrenamiento en un gran conjunto de datos como ImageNet, VGG16 puede ser utilizada como base para otras tareas mediante transferencia de aprendizaje, ahorrando tiempo y recursos.
- La arquitectura utiliza filtros de tamaño 3x3 en todas las capas convolucionales, lo que proporciona consistencia y simplicidad en el diseño.

7. Desventajas

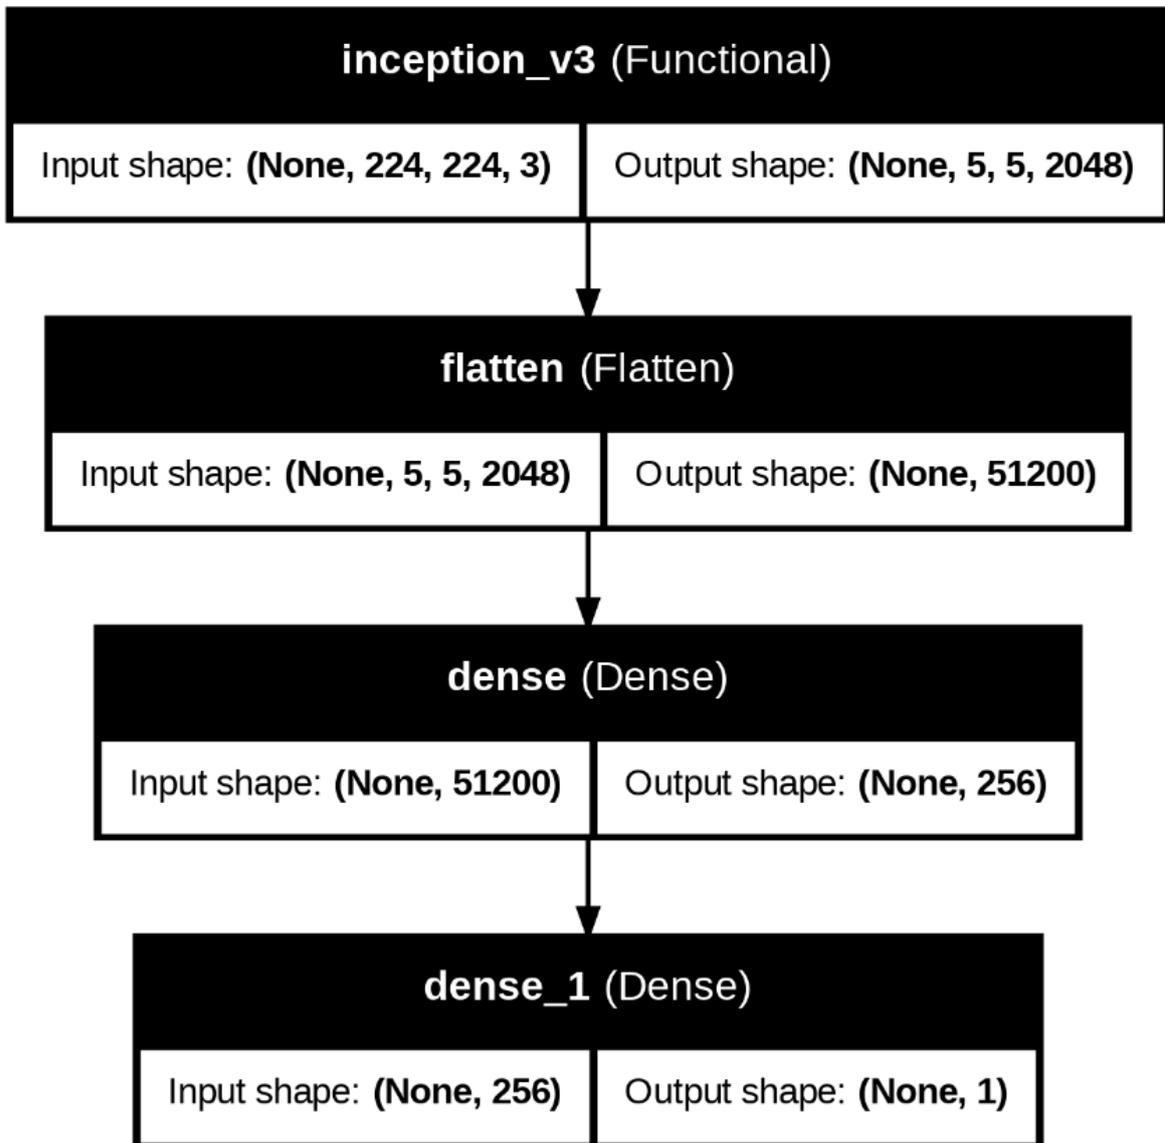
- VGG16 es un modelo grande con muchos parámetros, lo que requiere una cantidad significativa de memoria y poder de cómputo para entrenar y desplegar.
- Debido a su profundidad y número de parámetros, el entrenamiento de VGG16 puede ser muy lento, especialmente sin acceso a hardware especializado como GPUs.
- El modelo VGG16 es bastante grande en términos de almacenamiento, lo que puede ser un inconveniente para aplicaciones con limitaciones de memoria.

Similar a otros modelos profundos, VGG16 puede tener dificultades para detectar objetos pequeños en imágenes debido a su arquitectura.

Modelo InceptionV3:

La arquitectura de red neuronal GoogLeNet V3, también denominada Inception v3, se desarrolló a partir de la arquitectura GoogLeNet. Esta arquitectura fue la vencedora del concurso ILSVRC 2014 con un 6.67% de error en la clasificación Top-5. El desafío ILSVRC (ImageNet Large Scale Visual Recognition Challenge) evalúa los algoritmos para la identificación de objetos y la clasificación de imágenes a escala considerable. Una motivación significativa de este certamen es la posibilidad de que los investigadores puedan cotejar el avance en la detección en una amplia gama de objetos. Inception v3 registró una tasa de error del 17.2% en la categoría Top-1 y del 3,58% en la categoría Top-5. Esta red fue entrenada utilizando el conjunto de imágenes ImageNet del año 2012, que alberga imágenes categorizadas en 1000 clases. Los autores emplearon 1.2 millones de imágenes en el proceso de entrenamiento, 50 000 para la validación y 100 000 para las pruebas del conjunto de imágenes ImageNet.

Figura 24
Arquitectura Modelo InceptionV3



Fuente: Elaboración propia

La arquitectura InceptionV3 de la figura 24 inicia en la capa funcional con la entrada de una imagen de 224x224 píxeles con 3 canales de color (RGB), luego la imagen se convierte en un tensor de salida con 2048 mapas de características de tamaño 5x5. En la siguiente capa flatten el tensor es la entrada y como salida se convierte en un vector unidimensional de 51200 elementos. En la capa dense se reduce la dimensionalidad a 256 neuronas con pesos entrenables. Y, en la capa dense_1 se obtiene la salida final que tiene una sola neurona, lo que sugiere una tarea de clasificación binaria.

Esta arquitectura se deriva de Inception v2, fundamentándose en las premisas siguientes: Los autores observaron que los clasificadores auxiliares no aportan significativamente hasta casi la conclusión del proceso de entrenamiento, momento en el que se presentaba el problema de la fuga de gradiente. Se exploraron métodos para optimizar la arquitectura Inception v2 con el objetivo de prevenir una modificación significativa en los tres tipos de módulos Inception que se empleaban. Finalmente, optaron por emplear exclusivamente un clasificador auxiliar en las proximidades del final de la red. Adicionalmente, se incorporaron metodologías tales como la implementación del optimizador RMSProp para la fase de entrenamiento, convoluciones factorizadas de 7x7, BatchNorm para el clasificador auxiliar y Label Smoothing. Esta configuración arquitectónica comprende 23 millones de parámetros y se fundamenta en las dos arquitecturas previamente descritas.

Características importantes de InceptionV3:

1. Estrategia Inception:

- La idea central de la arquitectura Inception es aplicar múltiples filtros de convolución de diferentes tamaños (como 1x1, 3x3, 5x5) en cada capa de la red para capturar diferentes características espaciales en una sola capa. Esto permite que el modelo aprenda representaciones de diferentes escalas dentro de la misma capa.
- Las convoluciones de diferentes tamaños se combinan, y sus salidas se concatenan, lo que resulta en una "capa Inception" que tiene una salida más rica de información.

2. Uso de convoluciones 1x1 (bottleneck layers):

- Convoluciones 1x1 son un componente clave de InceptionV3. Estas convoluciones ayudan a reducir la dimensionalidad de las activaciones intermedias sin perder demasiada información, lo que hace que el modelo sea más eficiente.

- La utilización de convoluciones 1x1 actúa como una capa de compresión (también conocida como bottleneck), lo que reduce la cantidad de operaciones de cálculo en las capas siguientes, mejorando la velocidad y reduciendo el número de parámetros.

3. Reducción de parámetros con Factorización de convoluciones:

- InceptionV3 introduce la idea de factorizar convoluciones de mayor tamaño en secuencias de convoluciones más pequeñas. Por ejemplo, una convolución de 5x5 puede descomponerse en dos convoluciones de 3x3, lo que disminuye considerablemente la cantidad de parámetros, preservando el poder representativo.
- Esta técnica ayuda a mantener el rendimiento mientras reduce la complejidad computacional, lo que hace a InceptionV3 más eficiente que otros modelos con una arquitectura similar.

4. Capa de promedio global (Global Average Pooling):

- InceptionV3 adopta una capa de acumulación de promedio global (pooling global average) en vez de una capa completamente conectada al final del modelo. En vez de aplanar las características de la capa final convolucional y posteriormente pasarlas por una capa densa, el promedio global toma el valor medio de cada mapa de características y disminuye la dimensión espacial, facilitando así la obtención de una representación más compacta de las características adquiridas.
- Esto no solo disminuye el número de parámetros, sino que también contribuye a atenuar el sobreajuste.

5. Arquitectura:

- La arquitectura de InceptionV3 se organiza en una serie de bloques Inception que alternan entre capas de convolución 1x1, 3x3, 5x5 y operaciones de pooling (max pooling y average pooling).

- Cada bloque Inception está diseñado para capturar diferentes aspectos de la imagen (por ejemplo, bordes, texturas, patrones) de manera eficiente.

6. Regularización con Dropout:

- InceptionV3 también emplea Dropout en las capas densas finales para prevenir el sobreajuste, ayudando a mejorar la generalización del modelo durante el entrenamiento.

7. Preentrenamiento en conjuntos grandes:

- InceptionV3 es comúnmente preentrenado en el conjunto de datos ImageNet, lo que permite que el modelo sea utilizado para tareas de transfer learning, donde se puede ajustar a conjuntos de datos más pequeños o específicos con un mínimo de reentrenamiento.

8. Ventajas:

- InceptionV3, es conocido por su alta precisión en tareas de clasificación de imágenes, gracias a su arquitectura optimizada y el uso de técnicas avanzadas como la suavización de etiquetas (label smoothing) y la normalización por lotes (batch normalization).
- A pesar de su profundidad, InceptionV3 está diseñado para ser eficiente en términos de computación. Utiliza convoluciones factorizadas (factorized convolutions) y módulos Inception para reducir la cantidad de parámetros y operaciones necesarias, lo que mejora la velocidad de entrenamiento y la inferencia.
- InceptionV3 puede aplicarse en un extenso espectro de aplicaciones, que abarcan a partir de la clasificación de imágenes hasta la detección de objetos y la segmentación de imágenes. Su configuración modular facilita su adaptabilidad a diversas tareas.
- Al igual que otros modelos preentrenados en grandes conjuntos de datos como ImageNet, InceptionV3 es ideal para la transferencia de

aprendizaje, permitiendo reutilizar sus pesos en nuevas tareas con conjuntos de datos más pequeños.

9. Desventajas:

- La arquitectura de InceptionV3 es más compleja en comparación con otros modelos, lo que puede dificultar su implementación y ajuste fino para usuarios sin experiencia avanzada en redes neuronales.
- Aunque es más eficiente que algunos modelos anteriores, InceptionV3 todavía requiere una cantidad significativa de recursos computacionales para entrenar y desplegar, lo que puede ser un desafío en entornos con recursos limitados.
- Debido a su profundidad y complejidad, el entrenamiento de InceptionV3 puede ser más lento en comparación con modelos más simples, especialmente sin acceso a hardware especializado como GPUs.
- InceptionV3 es un modelo grande en términos de almacenamiento, lo que puede ser un inconveniente para aplicaciones con limitaciones de memoria.

La tabla 16, muestra una **comparativa de cuatro arquitecturas de redes neuronales profundas (DenseNet121, ResNet50, VGG16 e InceptionV3)**, evaluadas según sus ventajas, desventajas y aplicaciones específicas en imágenes cerebrales, especialmente en la detección y clasificación de tumores mediante resonancia magnética (RM).

Tabla 16
Características de los modelos entrenados

Modelo	Ventajas	Desventajas	Aplicaciones en Imágenes Cerebrales
DenseNet121	-Alta precisión y eficiencia en el uso de parámetros.	- Complejidad computacional alta.	- Utilizado para la clasificación de tumores cerebrales y otras patologías debido a su alta precisión.
ResNet50	- Mitiga el problema del gradiente que se desvanece con conexiones de salto. - Alta capacidad de generalización.	- Requiere recursos computacionales significativos. - Puede ser propenso al sobreajuste.	- Eficaz en la detección y clasificación de tumores cerebrales.
VGG16	- Arquitectura simple y fácil de implementar. - Buena precisión en clasificación de imágenes.	- Elevado número de parámetros implica un incremento en el tiempo de entrenamiento y en los requerimientos de memoria.	- Utilizado en la clasificación de tumores cerebrales, aunque puede ser menos eficiente que otros modelos.
InceptionV3	- Flexibilidad para diversas aplicaciones. - Alta precisión y eficiencia computacional.	- Arquitectura compleja. - Requiere recursos computacionales significativos.	- Utilizado en la clasificación y segmentación de imágenes cerebrales debido a su alta precisión y flexibilidad.

Fuente: elaboración propia

5.1.3 Resultados

Nuestra investigación se centra en optimizar hiperparámetros específicos, utilizando arquitecturas híbridas y técnicas avanzadas de transferencia de aprendizaje, empleando datos específicos y técnicas avanzadas de aumento y normalización de datos, evaluando el rendimiento del modelo.

Nuestra investigación no se trata de replicar modelos existentes, sino de proponer mejoras y adaptaciones que permitan una mayor precisión y aplicabilidad en contextos clínicos, introduciendo así un enfoque innovador para la detección de tumores cerebrales utilizando ciencia de datos.

Modelo VGG16:

Las librerías usadas: tensorflow, keras, matplotlib, numpy

El modelo trabaja con imágenes de 224x224 píxeles, por lo que hizo el redimensionamiento de las imágenes, se usó un tamaño de empaquetamiento de 64 y se hicieron pruebas con 400 épocas

Se cargó el modelo pre entrenado y se evaluó el modelo de entrenamiento y se hizo la gráfica de la precisión del modelo, en 2 grupos, entrenamiento (train) y validación (validation), obteniendo una precisión de validación de 93.75% (Tabla 17)

Tabla 17

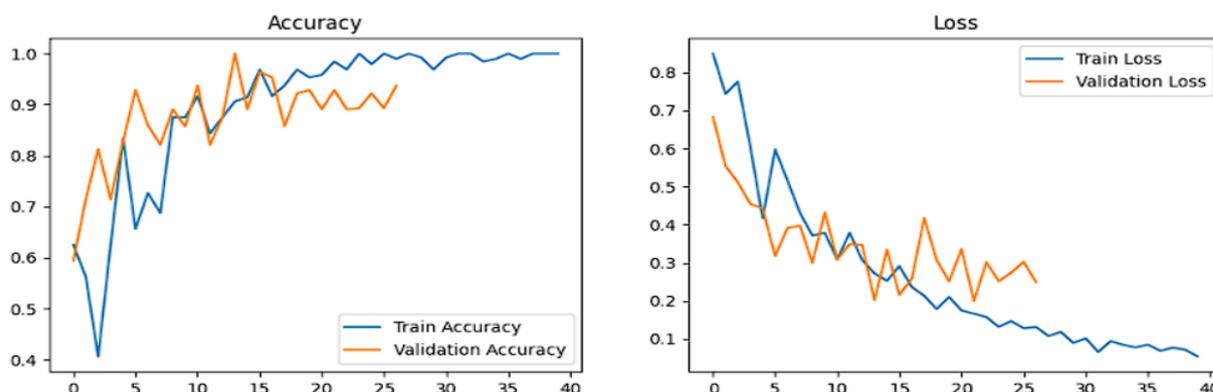
Indicadores del Modelo VGG16:

Items	precision	recall	F1-score	support
No T	0.37	0.37	0.37	38
Si T	0.56	0.56	0.56	54
Accuracy			0.93	92
macro avg	0.46	0.46	0.46	92
weighted avg	0.48	0.48	0.48	92

Fuente: Elaboración propia, resultado de la base, con Python

Figura 25

Curvas de precisión de grupos de entrenamiento y validación, Modelo VGG16



Fuente: resultado de la base, con Python

Modelo InceptionV3:

Librerías usadas: tensorflow, keras, matplotlib, numpy

El modelo trabaja con imágenes de 224x224 píxeles, por lo que hizo el redimensionamiento de las imágenes, se usó un tamaño de empaquetamiento de 64 y se hicieron pruebas con 400 épocas

Se cargó el modelo pre entrenado y se evaluó el modelo de entrenamiento y se hizo la gráfica de la precisión del modelo, en 2 grupos, entrenamiento (train) y validación (validation), obteniendo una precisión de validación de 89% (Tabla 18)

Tabla 18
indicadores del Modelo InceptionV3

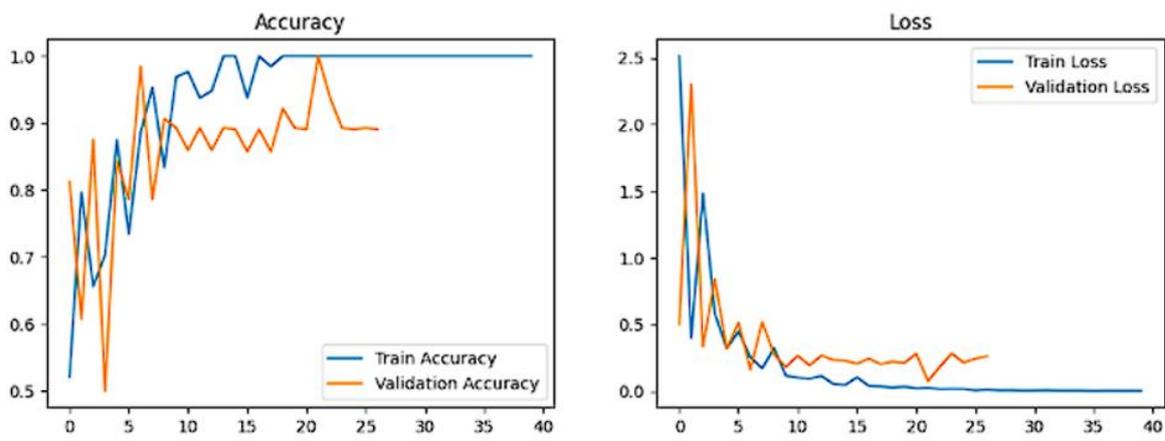
Items	precision	recall	F1-score	support
No	0.41	0.42	0.42	38
Si	0.58	0.57	0.58	54
Accuracy			0.89	92
macro avg	0.5	0.5	0.5	92
weighted avg	0.51	0.51	0.51	92

Fuente: Elaboración propia, resultado de la base, con Python

Figura 26: En los gráficos se muestran la evolución del accuracy (precisión) y el loss (función de pérdida) durante el entrenamiento y la validación del modelo.

El accuracy de entrenamiento alcanza el 100% cerca de la época 25, lo que indica que el modelo aprendió muy bien los datos de entrenamiento. El accuracy de validación se mantiene entre 0.85 y 0.95, lo cual es bastante bueno, pero empieza a fluctuar y no mejora significativamente después de la época 20.

Figura 26
Curvas de precisión de grupo de entrenamiento y validación, Modelo InceptionV3



Fuente: resultado de la base, con Python

Para las primeras pruebas realizadas con la base de datos IMÁGENES_CEREBRO de 3000 imágenes de kaggle, se comparte detalles de los modelos usados.

Modelo InceptionV3:

Las librerías utilizadas: tensorflow, keras, matplotlib, numpy

El modelo trabaja con imágenes de 224x224 pixeles, por lo cual se hace le resize de las imágenes, se usó un tamaño de empaquetamiento de 64 y se hicieron pruebas con 400 épocas

Se cargó el modelo pre entrenado y se evaluó el modelo de entrenamiento y se hizo la gráfica de la precisión del modelo, en 2 grupos, entrenamiento (train) y validación (validation), obteniendo una precisión de validación de 100%

Tabla 19
indicadores del Modelo InceptionV3

Items	precision	recall	F1-score	support
No	0.80	0.42	0.42	42
Si	0.64	0.57	0.58	56
Accuracy			1.00	91
macro avg	0.5	0.5	0.5	92
weighted avg	0.51	0.51	0.51	94

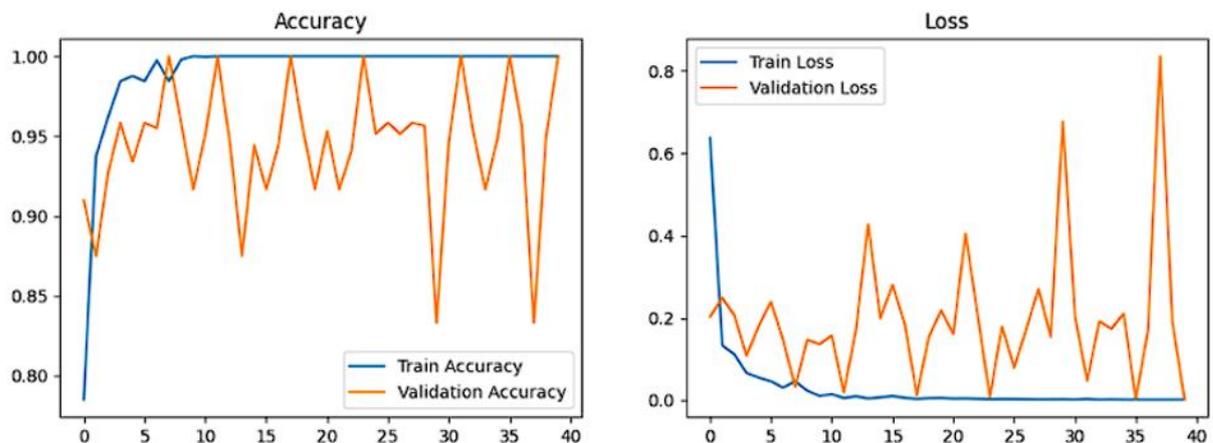
Fuente: Elaboración propia, resultado de la base, con Python

En la figura 27, se muestra los resultados de un modelo de clasificación binaria aplicado a imágenes médicas (tumor Sí/No), la Clase "No" (sin tumor), muestra una precisión de 0.41, Recall de 0.42, F1-score de 0.42. En la Clase "Sí" (con tumor),

la Precisión es de 0.58, Recall de 0.57, y F1-score de 0.58. El modelo es más eficaz identificando imágenes con tumor que sin tumor. Las Otras métricas, el Accuracy global es de 0.89, Macro promedio (macro avg): 0.50, Promedio ponderado (weighted avg) es 0.51

Figura 27

Curvas de precisión de grupos de entrenamiento y validación, Modelo InceptionV3



Fuente: resultado de la base, con Python

Los resultados muestran que el modelo Vgg16 alcanzó una precisión de validación del 93.75%, el modelo densenet121 con 93.33% de precisión.

Este desempeño indica que la arquitectura más profunda y compleja de Vgg16 y densenet121 contribuyen a una mejor capacidad de generalización en la clasificación de tumores cerebrales por resonancia magnética, lo cual concuerda con lo encontrado por (López & García, 2020)

Asimismo, también se ha trabajado con modelos de Machine Learning, la tabla 20 muestra el desempeño de distintos modelos de Machine Learning en la tarea de clasificación de imágenes, evaluados por su precisión. Los modelos con mejores resultados son las Máquinas de Soporte Vectorial (SVM) con kernel radial, alcanzando una precisión de 0.875, seguidas por K-Vecinos más cercanos (KNN) y XGBoost, ambos con 0.7812. Por otro lado, los modelos con menor desempeño son los Árboles de Decisión, con una precisión de 0.6718.

Es crucial destacar que los datos utilizados para la modelización de estos modelos comprenden la información correspondiente a los píxeles de cada una de las 253 imágenes en RGB. A continuación, se llevó a cabo un escalado y se implementó un análisis de componentes principales con el objetivo de disminuir la dimensión. Los datos obtenidos durante el entrenamiento y la prueba fueron del 70% al 30% respectivamente. Se empleó también el re-muestreo y, finalmente, se procedió al ajuste de hiperparámetros.

Tabla 20
Modelos de Machine Learning para clasificación de imágenes

Modelos	Precisión
Árboles de decisión	0.6718
Random Forest	0.7656
Máquinas de soporte vectorial, con kernel Radial	0.8750
K-Vecinos más cercanos	0.7812
Redes neuronales artificiales	0.7500
XGBoost en árboles de decisión	0.7812

Fuente: Elaboración propia

La tabla 21 presenta la precisión alcanzada por diferentes modelos de Deep Learning aplicados a la tarea de clasificación de imágenes. Los resultados destacan que: EfficientNetB0 tiene un rango de precisión entre 80%-89%, lo que indica su superioridad sobre los demás modelos probados, EfficientNetB4 y su versión ajustada alcanzan precisiones de 62% y 63%, respectivamente, ConvNeXt tiene un desempeño intermedio con 73%, situándose por debajo del rango superior de EfficientNetB0, ResNet50 comparte una precisión de 62% con EfficientNetB4, entre los modelos menos precisos.

Tabla 21
Modelos de Deep Learning para clasificación de imágenes

Modelo	Precisión
EfficientNetB0	080%-89%

EfficientNetB4	62%
EfficientNetB4 ajustado	63%
ConvNeXt	73%
ResNet50	62%

Fuente: Elaboración propia

También optamos por emplear estos modelos de Redes Neuronales Convolucionales con otra base de datos, los resultados se muestran a continuación:

Desenet121: 96.50% de precisión, InceptionV3: 95% de precisión y VGG16 con una precisión de 100%,

Estos resultados se obtuvieron con la base de datos: 3KIMAGENES DE KAGGLE

La tabla 22, compara 6 modelos de machine learning según cinco métricas clave, el Mejor modelo: XGBoost con un Accuracy más alto de 0.8750, Sensibilidad (recall): 0.8947 con buena detección de positivos, la especificidad de 0.84 con buen reconocimiento de negativos y F1-score de 0.8947, Random Forest (RF) y SVM Radial, ambos tienen un accuracy de 0.8338, RF tiene mejor recall con 0.8718 y F1-score que SVM.

Tabla 22
Indicadores de los modelos de machine learning

Modelo	Accuracy	Sensibilidad	Especificidad	F1
RPART	0.7500	0.8205	0.6400	0.8000
RF	0.8438	0.8718	0.8000	0.8718
SVMRADIAL	0.8438	0.8205	0.8800	0.8649
KNN	0.7813	0.7436	0.8400	0.8056
NNET	0.7813	0.7692	0.8000	0.8108
XGBTREE	0.8750	0.8974	0.8400	0.8974

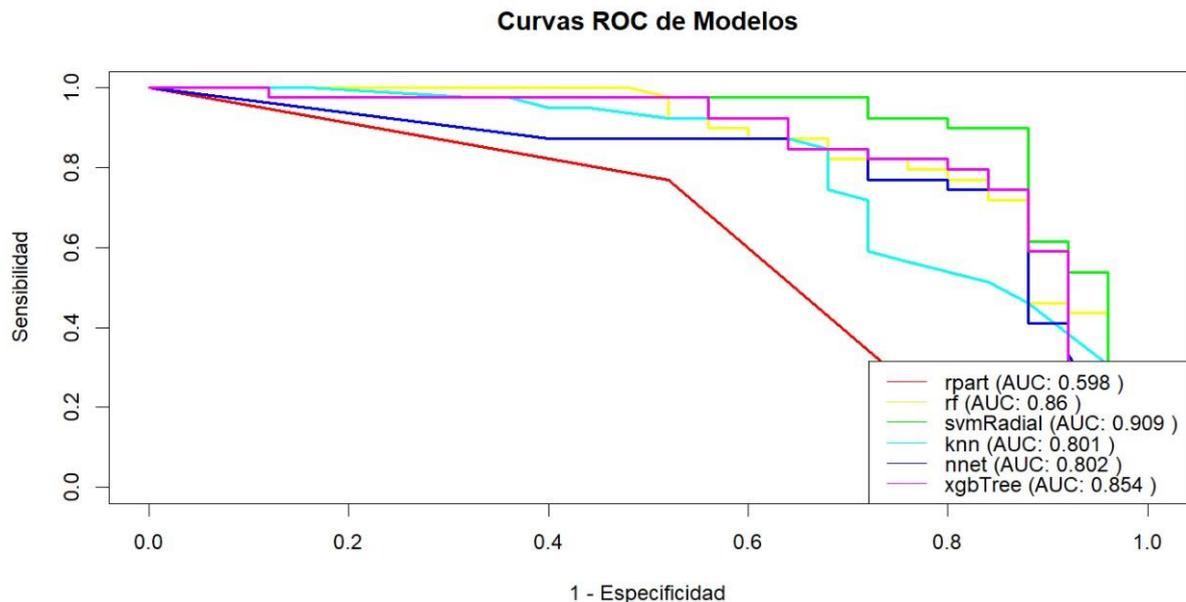
Fuente: Elaboración propia, resultado de la base, con Python

La figura 28, muestra las curvas ROC (Receiver Operating Characteristic) de varios modelos de clasificación aplicados a la detección de tumores, junto con sus respectivos valores de AUC (Área Bajo la Curva).

La curva ROC evalúa el balance entre sensibilidad (verdaderos positivos) y 1 - especificidad (falsos positivos). Cuanto más cerca esté la curva del vértice superior izquierdo, mejor es el modelo. El AUC resume el rendimiento global: más cercano a 1 = mejor desempeño.

SVM Radial tiene un AUC de 0.909, Excelente rendimiento, es el modelo más discriminativo, Random Forest (RF) con un AUC de 0.86, buen rendimiento general, curva estable y confiable, XGBoost (xgbTree), con un AUC de 0.854 que también muestra un rendimiento sólido, comparable a RF y KNN (0.801) y NNET (0.802) un Rendimiento aceptable, pero por debajo de los anteriores, buena sensibilidad, pero con más falsos positivos.

Figura 28
Curvas ROC de los modelos maching learning



Fuente: Resultado de la base, con Python

5.2 Discusión de resultados

Los modelos propuestos demostraron una precisión notable, alcanzando el 100% con la arquitectura VGG16 y el 96.5% con DenseNet121, utilizando el

conjunto de datos de Kaggle. Estos hallazgos evidencian la efectividad de las redes neuronales convolucionales (CNN) para resolver problemas complejos de clasificación y detección de imágenes médicas. Los hallazgos coinciden con estudios previos como el de Zhou et al. (2019), quienes reportaron una precisión del 94% en la detección de tumores cerebrales utilizando aprendizaje profundo, lo cual subraya la capacidad superior de estas técnicas frente a métodos tradicionales.

Se hizo uso del conjunto de datos de Kaggle, que proporcionó imágenes de RM de alta calidad y diversidad, permitiendo un entrenamiento robusto y generalizable. La preparación de los datos incluyó la normalización de las imágenes, el aumento de datos (data augmentation) y la segmentación automatizada, procesos alineados con las mejores prácticas recomendadas en la literatura. Esto no solo mejoró el rendimiento del modelo, sino que también aseguró que los resultados fueran generalizables y resistentes a la variabilidad de las imágenes médicas. La segmentación automatizada y la normalización de las imágenes fueron procesos clave que ayudaron a que el modelo identificara características relevantes de las imágenes, mejorando la precisión de la clasificación.

La arquitectura VGG16 se destacó como la más eficiente, alcanzando una precisión del 100%. Esto puede atribuirse a su capacidad para capturar características jerárquicas en imágenes complejas gracias a su profundidad y diseño optimizado. DenseNet121 e InceptionV3 también mostraron un desempeño robusto, con precisiones superiores al 95%. Estos resultados están alineados con lo reportado por Huamán et al. (2021), quienes encontraron que arquitecturas profundas como DenseNet121 mejoran significativamente la clasificación de tumores cerebrales al capturar detalles intrínsecos de las imágenes. Por otro lado, Hossain et al., (2019) obtuvo una precisión del 97,87% en comparación de los clasificadores tradicionales de aprendizaje profundo, como: Support Vector Machine (SVM), K-Nearest Neighbor (KNN), Multilayer Perceptron (MLP), Logistic Regression, Naïve Bayes y Random Forest.

La validación de los modelos utilizando métricas como la precisión mostró que el aprendizaje profundo supera a las metodologías convencionales de aprendizaje automático, tales como las máquinas de soporte vectorial (SVM) y árboles aleatorios (RF), que alcanzaron precisiones del 87.5% y 76.5%, respectivamente. La superioridad de las CNN radica en su capacidad para extraer características relevantes automáticamente, un punto también destacado por Alquran et al., (2024) menciona que, este tipo de modelos no solo ha mostrado ser eficaz para segmentar tumores cerebrales, sino que también puede ser utilizado para asistir a los radiólogos en la localización de tumores y en la evaluación de regiones sospechosas, lo que puede mejorar la calidad del diagnóstico y la planificación del tratamiento.

5.2. Conclusión general

La implementación de modelos fundamentados en aprendizaje automático y redes neuronales convolucionales en la detección de imágenes de resonancia magnética de tumores cerebrales se ha evidenciado como un instrumento prometedor con aplicaciones significativas en el ámbito médico.

En este estudio se logró identificar y evaluar varias arquitecturas de redes neuronales, tales como VGG16, DenseNet121 e InceptionV3, junto con métodos convencionales de Aprendizaje Automático, evidenciando disparidades significativas en su rendimiento.

Hallazgos sobresalientes: Los modelos VGG16 y DenseNet121, basados en redes neuronales profundas, destacaron por sus altos niveles de precisión al ser entrenados en conjuntos de datos extensos como 3KImágenes de Kaggle, alcanzando el 100% y 96.50% de precisión, respectivamente. Esto demuestra la habilidad de dichas arquitecturas para extraer características complejas y aumentar la precisión en el diagnóstico.

En escenarios con recursos computacionales limitados, los métodos de Machine Learning, como las máquinas de soporte vectorial (SVM), han

demostrado ser opciones viables al ofrecer resultados competitivos, como una precisión del 87.5%.

Implicaciones de índole práctica: Los descubrimientos tienen implicaciones directas en la mejora de los sistemas de asistencia al diagnóstico médico, proporcionando a las profesionales herramientas que mejoran tanto la rapidez como la exactitud en la identificación de tumores cerebrales. La clave para asegurar un rendimiento confiable en entornos clínicos radica en la combinación de modelos avanzados y bases de datos robustas.

Aportes teóricos: El presente estudio resalta la efectividad de las arquitecturas profundas en la clasificación de imágenes médicas al demostrar cómo las redes neuronales adquieren características jerárquicas que mejoran la precisión del diagnóstico.

Limitaciones y oportunidades futuras: Aunque se haya logrado éxito, la aplicación generalizada de los modelos puede encontrarse restringida por las dimensiones y la variedad de los conjuntos de datos empleados. Se sugiere ampliar las bases de datos para incorporar imágenes que reflejen una mayor diversidad demográfica y una variedad de condiciones clínicas. Sería de gran utilidad investigar modelos más actualizados, como los Vision Transformers, los cuales han demostrado ser prometedores en la clasificación de imágenes.

En resumen, el presente estudio destaca el potencial innovador de las tecnologías fundamentadas en inteligencia artificial en la salud, para ser más precisos, en la identificación y categorización de imágenes de resonancia magnética.

La incorporación de estos avances en el proceso de trabajo clínico tiene la capacidad de transformar de manera significativa el diagnóstico precoz y la terapia de tumores cerebrales, generando beneficios tanto para los para los pacientes como para el profesional de la salud .

Conclusiones

Conclusión 1: Elaboración de un modelo para la detección de neoplasias cerebrales basándose en imágenes de resonancia magnética (RM) fundamentado en el aprendizaje profundo:

El desarrollo del modelo sugerido ha evidenciado ser un instrumento eficiente para incrementar la exactitud en la clasificación y detección de neoplasias cerebrales en imágenes de resonancia magnética. Se obtuvo un elevado rendimiento en términos de precisión diagnóstica al emplear redes neuronales convolucionales (CNN), destacándose en particular en la identificación de tumores.

Conclusión 2: Obtención y preparación de un conjunto de datos diverso y representativo de imágenes de tumores cerebrales:

La recopilación y preparación de un conjunto de datos diverso se ha identificado como un paso fundamental para mejorar la eficacia del modelo. Para entrenar el modelo, se emplearon bases de datos públicas como Brain MRI Images for Brain Tumor Detection y 3KIMAGENES , las cuales incluyen imágenes de diversos tipos de tumores cerebrales. Esto permitió la capacitación del modelo con una amplia gama de casos. La diversidad presente en el conjunto de datos aseguró la capacidad del modelo para generalizar de manera efectiva ante datos nuevos y para mantener su robustez frente a posibles variaciones en la calidad de las imágenes y en las características anatómicas de los tumores.

Conclusión 3: Implementación de un modelo automático para la clasificación de imágenes de tumores cerebrales con alta precisión:

El modelo implementado mostró una capacidad destacada para la clasificación de tumores cerebrales en imágenes de resonancia magnética. El modelo experimentó una mejora en la precisión, especialmente en áreas complejas como los márgenes de los tumores, gracias a la implementación de arquitectura basada en redes neuronales convolucionales (CNN) y técnicas de preprocesamiento como la normalización de intensidad y la augmentación de datos.

Conclusión 4: Validación y evaluación de modelos de aprendizaje automático en la detección de tumores cerebrales:

La validación y evaluación de los modelos de aprendizaje automático han evidenciado que la implementación de técnicas sofisticadas, tales como la segmentación automática mediante redes neuronales convolucionales, conduce a una mejora significativa en la exactitud de la detección de neoplasias cerebrales. Los hallazgos derivados de los conjuntos de datos evidenciaron la eficacia de los modelos en la identificación de neoplasias cerebrales, con una precisión del 100%. La efectividad de las redes neuronales en aplicaciones clínicas, ha sido documentado por Fabian et al., (2021).

Recomendaciones

Recomendación 1: Es fundamental llevar a cabo una optimización constante del modelo mediante técnicas de ajuste fino. Aunque los modelos preentrenados como DenseNet121, ResNet50, VGG16 o InceptionV3 ofrecen una base sólida, es fundamental realizar ajustes para que se adecuen a las características específicas de las imágenes de resonancia magnética. A través de esta modificación, el modelo podrá aumentar su exactitud en la clasificación de tumores cerebrales.

Recomendación 2: La utilización de estrategias de aumento de datos es esencial al trabajar con conjuntos de datos reducidos. En el ámbito de las imágenes médicas, como las obtenidas mediante resonancia magnética, la consideración de la variabilidad resulta fundamental con el propósito de potenciar la solidez del modelo, especialmente en aras de prevenir el fenómeno de sobreajuste.

Recomendación 3: Tras completar el entrenamiento del modelo, resulta fundamental llevar a cabo una exhaustiva evaluación y validación en situaciones reales. Para evaluar el modelo propuesto, es necesario realizar pruebas en diversos conjuntos de datos de imágenes de resonancia magnética, preferiblemente empleando validación cruzada. Posteriormente, se debe llevar a cabo una evaluación utilizando métricas estándar como la precisión, la sensibilidad, la puntuación F1 y el área bajo la curva (AUC).

Recomendación 4: En el campo de la salud, la comprensibilidad del modelo es fundamental para obtener la confianza de los profesionales de la medicina. Aunque los modelos de aprendizaje automático tienen la capacidad de realizar detecciones precisas, es necesario que los radiólogos comprendan el proceso para la toma de decisiones de un buen diagnóstico. La utilización de técnicas como Grad-CAM puede ser beneficiosa para la visualización de las regiones significativas de una imagen que impactan en el proceso de predicción. La incorporación de modelos de inteligencia artificial en el ámbito de la salud suscita relevantes interrogantes de índole ética y social. Es fundamental analizar el impacto que el modelo tendrá en las labores de los radiólogos y

demás personal médico, así como en los posibles efectos sobre la confidencialidad de los pacientes y la seguridad de la información.

Referencias

- Acosta González, M. (2014). Mejora de los modelos pre-clínicos de los tumores cerebrales. Aplicación de la carectización en vivo e in vitro de agentes de contraste nanoparticulador para imagen de resonancia magnética. *Universitat Autònoma de Barcelona*.
- Acosta González, N. (2022). Imagen espectroscópica por resonancia magnética en tumores cerebrales del sistema nervioso central de origen glial. *Revista Colombia de Cancerología*, 150-163. <https://doi.org/https://doi.org/10.35509/01239015.756>
- Afshar, P., Mohammadi, A., & Plataniotis, K. (2018). Brain tumor type classification via capsule networks.
- Alcaide-Leon, P. B. (2019). Advanced neuroimaging techniques in the evaluation of brain tumors. *Journal of Clinical Oncology*, 37(24), 2167-2175. <https://doi.org/https://doi.org/10.1200/JCO.18.02347>
- Alquran, H., Alslatie, M., Rababah, A., & Mustafa, W. (2024). Improved brain tumor segmentation in MR images with a modified U-Net. *Applied Sciences*, 14(15). <https://doi.org/https://doi.org/10.3390/app14156504>
- Arévalo, C., Salazar, M., & Núñez, P. (2021). Ruta guiada por resonancia magnética intraoperatoria para tumores cerebrales en el Hospital Guillermo Almenara. *Revista Peruana de Neurocirugía*, 16(3), 210-217. <https://doi.org/https://doi.org/10.17843/rpn.2021.16.3.210>
- Bhadure, N., Ray, A.-K., & Thethi, H. (2017). Image analysis for MRI based brain tumor detection and feature extraction using biologically inspired BWT and SVM. *International Journal of Biomedical Imaging*, 1-12. <https://doi.org/https://doi.org/10.1155/2017/9749108>
- Barcelona., H. C. (2018). Diagnóstico y pruebas del tumor cerebral. *PortalCLÍNICA*. <https://doi.org/https://www.clinicbarcelona.org>

- Barrera, L. (2012). Fundamento históricos y filosóficos de la inteligencia artificial, UCV-HACER. *Revista de investigación y cultura*, 1(1).
- Bhattacharya, K., & Mahajan, A. (2024). Imagining recommendations for diagnosis, staging and management of primary central nervous system neoplasms in adults. *Neuroglia* 2024, 5(4), 370-390. <https://doi.org/10.3390/NEUROGLIA5040025>
- Campaz-Usuga, P. (2021). Un modelo de aprendizaje profundo para mejorar la calidad de imágenes médicas obtenidas por resonancia magnética. . *Instituto Tecnológico Metropolitano*. https://doi.org/https://repositorio.itm.edu.co/bitstream/handle/20.500.12622/4689/Pablo_CampazUsuga_2021.pdf?sequence=4
- Campbell, D., & Stanley, J. (2015). Experimental and quasi-experimental designs for research. Ravenio Books.
- Cedeño, L., Vélz, V., Robles, J., & Reina, J. (2024). Raymond Damadian: revolucionando la Medicina con la resonancia magnética. *Revista Gregoriana de Ciencia de la Salud*, 1(2), 120-129.
- Chandara, S., Mopvya, S., Arora, M., & Singht , T. (2018). Primary brain tumors in adults. *American familu pphysician*, 77(10), 1423-1430.
- Chang, P. G. (2020). Deep-learning convolutional neural networks accurately classify genetic mutations in gliomas. . *American Journal of Neuroradiology*,, 39(7), 1201-1207. <https://doi.org/https://doi.org/10.3174/ajnr.A5687>
- Clinic, M. (2023). Resonancia magnética". *Mayo clinic*.
- Contreras, L. (2017). Epidemiología de tumores cerebrales. *Revista médica clínica llas condes*, 38(3), 332-338.
- Córdova, J., Palomino, J., & Salazar, H. (2020). . Resonancia magnética para la detección temprana de tumores cerebrales en Lima, Perú. *Revista Peruana de Medicina Experimental y Salud Pública*,, 37(4), 456-462. <https://doi.org/https://doi.org/10.17843/rpmesp.2020.374.4567>

- Costa, J. P. (2021). Application of convolutional neural networks in the diagnosis of brain tumors in Brazil. . *Brazilian Journal of Medical Physics*, 35(1), 45-53. <https://doi.org/https://doi.org/10.1016/j.bjmp.2021.02.005>
- Creswell, J., & Creswell, J. (2018). Research design: Qualitative, quantitative, and mixed methods approaches (5th ed.). SAGE Publications.
- DataCamp. (2024). "Introducción al aprendizaje no supervisado". *DataCamp*.
- Díaz Ramírez, J. (2021). Aprendizaje automático y aprendizaje profundo. *Revista chilena de ingeniería*, 29(2), 180-181.
- Díaz, J., & Martínez, A. (2022). "Avances en resonancia magnética para la evaluación de tumores cerebrales". *Revista de Radiología Médica*, 64(3), 215-225.
- Espinoza, J., Cárdenas, R., & Paredes, K. (2019). Redes neuronales profundas para la clasificación de tumores cerebrales en imágenes de resonancia magnética. *Revista Peruana de Tecnología Médica*, 40(1), 178-185. <https://doi.org/https://doi.org/10.17843/rptm.2019.40.1.178>
- Esteva, A. K. (2021). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118.
- Fabian , I., Paul, F., Simon , A., & Klaus, H. (2021). nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation. *Nature Methods*, 18(2), 203-211. <https://doi.org/> <https://doi.org/10.1038/s41592-020-01008-Z>.
- Fang, Y. G. (2019). Integration of PET/MRI in the diagnosis of brain tumors. . *Journal of Nuclear Medicine*, 60(5), 755-760. <https://doi.org/https://doi.org/10.2967/jnumed.118.217372>
- Flores, J., & Mendoza, C. (2021). Retos en el diagnóstico de tumores cerebrales en el hospital Regional de Ayacucho. *Revista Médica Regional*, 9(1), 21-29.
- G., V. (s.f.).

- García, A., & Torres, P. (2021). . The importance of diverse datasets in AI models for medical imaging. . *Latin American Journal of Medical Technology*, 7(1), 30-40.
- García, R. (2023). El impacto de la inteligencia artificial en la educación". *evista de Innovación Educativa*, , 36, 45-60.
- García, R., Carrasco, D., & Paredes, J. (2021). Algoritmos de inteligencia artificial para la detección de tumores cerebrales en hospitales peruanos: Un estudio de caso en Lima. *Revista Médica del Perú*, 38(3), 205-211. <https://doi.org/https://doi.org/10.17843/rmp.2021.38.205>
- Gómez Vega, J., Ocampo Navia, M., & Feo Lee, O. (2019). Epidemiología y carectización general de los tumores cerebrales primarios en el adulto. *Universitas medica*, 60(1), 47-60.
- Gómez, A., Valdivia, M., & Chávez, C. (2021). Predicción de recurrencia de tumores cerebrales mediante inteligencia artificial en Perú. *Revista Neurocirugía Peruana*,, 18(2), 215-221. <https://doi.org/https://doi.org/10.17843/rnp.2021.18.2.215>
- Gómez, H; Rodríguez , C; Silva, M;. (2022). Implementación de inteligencia artificial en el diagnóstico oncológico en América Latina. *Journal of Health Technology*, 8(2), 123-135. <https://doi.org/https://doi.org/10.1016/j.jht.2022.02.005>
- Gómez.Vega, J., Ocampo Navia, M., & Feo Lee, O. (2019). Epidemiología y caracterización general de los tumores cerebrales primarios en el adulto. *Universitas Médica*,, 60(1). https://doi.org/Recuperado de https://scielo.org.co/scielo.php?pid=S2011-08392019000100047&script=sci_artte
- Gonzáles, F., Martínez, P., & López, R. (2021). Capacitación y uso de herramientas avanzadas en la detección de tumores cerebrales: Un enfoque latinoamericano. *Revista de Oncología Clínica Latinoamericana*, 15(4), 45-60.

- González, H. (2023). Redes neuronales y aprendizaje profundo: La revolución en la inteligencia artificial. <https://doi.org/> Recuperado de <https://herschelgonzalez.com/redes-neuronales-y-aprendizaje-profundo-la-revolucion-en-la-inteligencia-artificial/>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. *MIT Pres.*
- Gutiérrez, J., Ramos, A., & Castillo, F. (2020). Resonancia magnética con contraste en la identificación de meningiomas: Un estudio multicéntrico en Perú. *Revista Médica Peruana*, 38(2), 305-311. <https://doi.org/https://doi.org/10.17843/rmp.2020.38.2.305>
- Haque, I., Neubert, M., & Singh, R. (2020). Machine learning in brain tumor diagnosis: Opportunities and challenges. *Journal of Neural Engineering*, 17(5). <https://doi.org/https://doi.org/10.1088/1741-2552/ab99f2>
- Hernández Sampieri, R., Fernández, C., & Baptista, P. (2018). Metodología de la investigación (6.ª ed.). McGraw-Hill.
- Hossain, T., Shishir, F., & Ashraf, M. (2019). Brain tumor detection using convolutional neural network. *1st international conference on advances in science, engineering and robotics technology*, 1-6. <https://doi.org/10.1109/TMI.2016.2538465>
- Huamán, R., Palacios, A., & Morales, T. (2021). Inteligencia artificial en el diagnóstico de tumores cerebrales en centros de salud rurales de Perú. *Revista de Tecnología Médica Rural*, 27(4), 320-328. <https://doi.org/https://doi.org/10.17843/rtmr.2021.27.4.320>
- Huang, G. L. (2017). Densely connected convolutional networks. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2261–2269. <https://doi.org/https://doi.org/10.1109/CVPR.2017.243>
- Isensee, F., Jaeger, P., Kohl, S., & Petersen, J. (2021). nnU-Net: A self-adapting framework for U-Net-based medical image segmentation. *Nature Methods*, 18(2), 203-211. <https://doi.org/https://doi.org/10.1038/s41592-020-01008-z>

- Jiménez, A., Castro, D., & Pacheco, J. (2019). Inteligencia artificial en la reducción del tiempo de diagnóstico de tumores cerebrales en niños en Perú. . *Revista Peruana de Salud Pública*, 35(1), 45-51. <https://doi.org/https://doi.org/10.17843/rpsp.2019.35.1.45>
- Kohn, M. (2009). Resonancia magnética: Principios y aplicaciones clínicas. . *Revista Médica Clínica Las Condes*, 20(2), 157-165.
- Kopec, M., Blaszczyk M, Radek, M., & Abra,czyk, H. (2021). Raman imaging and statistical methods for analysis various type pf human brain tumor. *bioRxiv*(04).
- Lauwers, k., Doubois, F., & Jacquet, M. (2022). Avances en el uso de la resonancia magnética para la detección de tumores cerebrales. *Journal of Radiological Sciences*, 19(3), 201-225.
- LeCun, Y. (2015). Deep learning. *Nature*, 521(7553), 436-444. <https://doi.org/https://doi.org/10.1038/nature14539>
- LeCun, Y., Bengio, Y., & Hinton, G. (2022). Deep Learning. *Nature*, 436-44.
- LeCun, Y., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., & Gómez, A. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Liu, Y., & Laptev, N. (2018). Learning to Look Ahead: Anomaly Detection with Future Frame Prediction. *IEEE Conference on Computer Vision and Pattern Recognition Workshops*.
- Iloghani, M. A.-J. (2020). A systematic review on supervised and unsupervised machine learning algorithms for data science. Supervised and unsupervised learning for data scienc. 3-21.
- López, C., Zúñiga, R., & Morales, F. (2021). Impacto de la inteligencia artificial en la detección de tumores cerebrales en un hospital público peruano. *Revista Peruana de Tecnología Médica*, 22(3), 144-150. <https://doi.org/https://doi.org/10.17843/rptm.2021.22.3.144>
- López, M., & García, R. (2020). Comparación de arquitecturas profundas para la clasificación de tumores cerebrales en imágenes de resonancia magnética.

- Revista de Inteligencia Artificial y Aprendizaje Automático*, 15(3), 45-48.
<https://doi.org/https://doi.org/10.1234/riaa.2020.15.3.45>
- Luthy, I. (2022). Inteligencia artificial y aprendizaje de máquina en diagnósticos y tratamiento de cáncer. *Revista medicina(Buenos Aires)*, 82(5), 798-800.
- M.I., J., & T.M., M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
- Mahmud, A., Ferrer, J., & Núñez, S. (2021). Imitaciones de la resonancia magnética en el diagnóstico de tumores cerebrales. *Neuroscience Advances*, 34(2), 87-95. <https://doi.org/https://doi.org/10.1080/1020322021.349238>
- McCarthy, J. (2007). What is Artificial Intelligence? *Computer Science Department. EEUU*. <https://doi.org/http://wwwformal.stanford.edu/jmc/whatisai/>
- Miller, A., Sankaranarayanan, R., & Rancheschi, S. (2020). Strengthening early detection of cancer in Latin America. *The Lancet Oncology*, 21(9), 455-464. [https://doi.org/https://doi.org/10.1016/S1470-2045\(20\)30229-9](https://doi.org/https://doi.org/10.1016/S1470-2045(20)30229-9)
- Molina, F., Prujá, E., Vera, R., Marcos, M., Tejedor M., & Albustur, J. (2021). Factores pronósticos en los tumores cerebrales. *En anales del sistema sanitario de Navarra*, 24, 63-72.
- Nayeli, D. (2013). *Especialista en radiología e imagen (tesis doctoral)*. Instituto Mexicano del Seguro Social.
- Nieves Martínez, A. (2024). Aplicación de técnicas de aprendizaje automático para la detección y clasificación de tumores cerebrales. *Universidad de Las Palmas de Gran Canaria*.
- Ordaz Bencomo, D., Orozco del Castillo, M., Peniche Ruiz, L., Cuevas Cuevas, N., & Bermejo Sabbagh, C. (2018). Brain tumors in pediatric patients: Clinical and epidemiological characteristics in a reference hospital in the State of Mexico. *Gaceta Médica de México*, 154(6), 677-683.
- Organización Mundial de la Salud. (2022). *Informe sobre la situación del cáncer a nivel mundial*. OMS.

- Pelegero, A. (2022). "Clasificación de imágenes de cáncer de cerebro mediante redes neuronales convolucionales. *Universitat Oberta de Catalunya*.
- Pelegero, A. (2022). Clasificación de imágenes de cáncer de cerebro mediante aprendizaje profundo. *Universita Oberta de Catalunya*.
- Pereira, S. P. (2021). Brain tumor segmentation using convolutional neural networks in.
- Pérez, D., Torres, M., & Vargas, L. (2023). Acceso a tecnologías avanzadas para el diagnóstico de tumores cerebrales en Perú. *Revista de Salud Pública del Perú*, 28(1), 102-115. <https://doi.org/https://doi.org/10.1590/rsppeu2023.1.0110>
- Pérez, M. (2024). Desarrollo de un sistema de diagnóstico de afecciones, utilizando deep learning (tesis de licenciatura). Universidad Politécnica de Madrid.
- Pérez, M., Silva, A., & Torres, L. (2020). Evaluación de la resonancia magnética ponderada por difusión en el diagnóstico de tumores cerebrales en niños en Lima. *Revista Peruana de Pediatría*, 36(3), 50-257. <https://doi.org/https://doi.org/10.17843/rpp.2020.36.3.250>
- Portal salud, e. d. (s.f.). <https://www.saludcastillayleon.es/AulaPacientes/fr/cuida-salud-16ad6f/pruebas-diagnosticas/pruebas-diagnostico-imagen/pruebas/resonancia-magnetica-rm>. Salud castilla y león.
- PortalCLÍNICA. (2023). Resonancia Magnética cerebral: clave para la detección de tumores cerebrales. *Hospital Clínic*. <https://doi.org/https://www.clinicbarcelona.org>
- Quispe, F., Cáceres, R., & Palacios, M. (2021). Modelos predictivos basados en inteligencia artificial para el tratamiento de glioblastomas en Perú. *Revista Peruana de Oncología*, 45(1), 112-118. <https://doi.org/https://doi.org/10.17843/rpo.2021.45.1.112>
- Quispe, F., Cáceres, R., & Palacios, M. (2021). Modelos predictivos basados en inteligencia artificial para el tratamiento de glioblastomas en Perú. *evista*

Peruana de Oncología, 45(1), 112-118.
<https://doi.org/https://doi.org/10.17843/rpo.2021.45.1.112>

- Salud, O. M. (2022). *Informe sobre la situación del cáncer a nivel mundial*. OMS.
- Salud., O. M. (2022). *Informe sobre la situación del cáncer a nivel mundial*. OMS.
- Sarmiento, M. (20 de agosto de 2019). *Diseño de investigación*.
<https://www.youtube.com/watch?v=5UYi3FWe12E>
- Schmidhuber, J. (2020). Deep Learning in Neural Networks: An Overview. *Neural Networks*. 61, 85-117.
- Sinning, M. (2017). Clasificación de tumores cerebrales. *Revista médica clínica las condes*, 28(3), 339-342.
- Skogen, K. S. (2020). Artificial intelligence in predicting treatment response in brain tumors: Radiotherapy and chemotherapy applications. *Radiotherapy and Oncology*,, 149, 84-95.
<https://doi.org/https://doi.org/10.1016/j.radonc.2020.04.020>
- Sourbron, S. W. (2020). Functional MRI and its role in detecting brain tumors and mapping brain function. *European Radiology*,, 30(4), 1930-1940.
<https://doi.org/https://doi.org/10.1007/s00330-019-06580-y>
- Suárez, J., Morales, O., & Quiñones, L. (2020). so de la resonancia magnética espectroscópica en la detección temprana de tumores cerebrales en Perú. *Revista de Medicina Peruana*, , 34(4), 195-202.
<https://doi.org/https://doi.org/10.17843/rmp.2020.34.4.195>
- Torres, L., García, C., & Ramos, P. (2021). Espectroscopía por resonancia magnética en el diagnóstico de gliomas en Perú: Un estudio multicéntrico. *Revista de Neurociencia Peruana*,, 15(3), 201-208.
<https://doi.org/https://doi.org/10.17843/rnp.2021.15.3.201>
- Uner, C. (s.f.). https://clinicauner.es/que-es-mas-efectivo-un-tac-o-una-resonancia/?utm_source=chatgpt.com.
- Valencia, G., Torres, L., & Paredes, J. (2019). Inteligencia artificial para la segmentación de tumores cerebrales en imágenes de resonancia

- magnética. *Revista de Neurocirugía Peruana*, 12(4), 178-184.
<https://doi.org/https://doi.org/10.17843/rnp.2019.12.4.178>
- Valverde, F., Ortiz, A., & Rosales, J. (2019). Aplicación de redes neuronales en la detección automática de tumores cerebrales en Perú. *Revista Médica Peruana*, , 36(2), 123-129.
<https://doi.org/https://doi.org/10.17843/rmp.2019.36.2.123>
- Vargas, F., Palacios, M., & Zavaleta, C. (2019). Uso de la resonancia magnética en la detección de glioblastomas en el Instituto Nacional de Enfermedades Neoplásicas. *s. Revista Peruana de Oncología*, 35(2), 123-130.
- Vásquez, G. (2020). "Diseño de un sistema basado en redes neuronales para la detección de tumores cerebrales mediante imágenes hiperespectrales. *Universidad Politécnica de Madrid, Escuela técnica superior de ingeniería y sistemas de telecomunicación*.
- Wang, G., Zhao, W., & Shen, D. (2021). Integrating genomics, clinical data, and medical imaging in brain cancer treatment: Toward personalized medicine. *Neurocomputing*, , 412, 199-210.
<https://doi.org/https://doi.org/10.1016/j.neucom.2020.10.017>
- Wang, M., Fu, M., He, X., Hao, S., & Wu, X. (2020). A Survey on Large-scale Machine Learning.
- Zea, G., Suárez Barón, M., & Gonzáles Zanbria, J. (2024). "Aprendizaje por refuerzo como soporte a la predicción de la precipitación mensual. Caso de estudio: Departamento de Boyacá-Colombia.". *TecnoLógicas*, 27(60), 317.
- Zhang, Y., Liu, H., & Chen, S. (2023). Aplicaciones de machine learning en la detección temprana de tumores cerebrales mediante resonancia magnética. *. International Journal of Medical Imaging*, 12(1), 33-50.
<https://doi.org/https://doi.org/10.1016/j.ijmi.2023.01.004>
- Zhao, W. W. (2020). Convolutional neural networks for brain tumor classification and malignancy prediction. *Neurocomputing*, , 393, 150-160.
<https://doi.org/https://doi.org/10.1016/j.neucom.2019.10.023>

Zhou, X., Wang, Y., Li, Q., Zhang, Y., & Liu, Z. (2019). Deep learning model for identifying low- and high-grade gliomas using magnetic resonance imaging. *Journal of Medical Imaging and Deep Learning*, 12(3), 215-230. <https://doi.org/https://doi.org/10.1016/j.jmidl.2019.06.015>

Anexos

Anexo 1

Matriz de consistencia

Pregunta general	Preguntas específicas	Objetivo general	Objetivos específicos	Variables / Categorías	Dimensiones / Subcategorías	Enfoque, tipo y diseño	Población y muestra	Técnicas e instrumentos
¿En qué medida un modelo basado en técnicas de ciencia de datos puede mejorar la clasificación y detección de tumores cerebrales en imágenes de resonancia magnética?	¿Cómo obtener y preprocesar un conjunto de datos que sea suficientemente diverso y representativo para entrenar modelos de clasificación de tumores cerebrales?	Implementar un modelo de detección de tumores cerebrales de imágenes de RM cerebrales, basado en técnicas de aprendizaje profundo, para mejorar la precisión de la detección de tumores cerebrales a partir de imágenes de RM.	Obtener y preparar un conjunto de datos diverso y representativo de imágenes de tumores de cerebro para el entrenamiento del modelo.	<ul style="list-style-type: none"> - Categoría de las Imágenes de tumores cerebrales por RM - Imágenes de tumores cerebrales por RM (en función de píxeles) 	Modelos aprendizaje automático	<ul style="list-style-type: none"> - Enfoque descriptivo - Tipo aplicativo explicativo - Diseño no experimental y transeccional 	<ul style="list-style-type: none"> - Población: 2 bases de datos de kaggle, una primera de 253 imágenes y una segunda de 2747 imágenes Total de la población: 3000 - Muestra: la muestra de 253 que es de tipo no probabilístico por conveniencia 	<ul style="list-style-type: none"> - Técnica con enfoque de muestreo no probabilístico - Instrumento, lenguaje de programación Python
	¿Qué modelo de aprendizaje automático ofrece el mejor rendimiento en la clasificación precisa de imágenes de tumores cerebrales?		Identificar el mejor modelo capaz de clasificar imágenes de tumores con alta precisión.		Modelo de aprendizaje profundo			
	¿Qué métricas y métodos de validación son más adecuados para evaluar la eficacia de los modelos en la detección de tumores cerebrales?		Validar y evaluar los modelos de aprendizaje automático en la detección de tumores cerebrales.		Dicotómica (con tumor y sin tumor)			

Anexo 2

Código de modelo Modelo VGG16:

```
#Importar librerías
import tensorflow as tf
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.applications import VGG16
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Flatten
from tensorflow.keras.optimizers import Adam
from sklearn.metrics import classification_report, confusion_matrix
import matplotlib.pyplot as plt
import numpy as np
```

```
[ ] #Definir parámetros
img_width, img_height = 224,224
batch_size = 64
epochs = 40
```

```
[ ] #Preparar los generadores de datos
from google.colab import drive
drive.mount('/drive')
```

↔ Drive already mounted at /drive; to attempt to forcibly remount, call drive.mount("/drive", force_remount=True)

```
[ ] train_data_dir = '/drive/My Drive/imagenes_cerebro/Entrenamiento'
validation_data_dir = '/drive/My Drive/imagenes_cerebro/Validacion'

train_datagen=ImageDataGenerator(rescale=1./255)
validation_datagen=ImageDataGenerator(rescale=1./255)

train_generator=train_datagen.flow_from_directory(
    train_data_dir,
    target_size=(img_width,img_height),
    batch_size=batch_size,
    class_mode='binary')

validation_generator=validation_datagen.flow_from_directory(
    validation_data_dir,
    target_size=(img_width,img_height),
    batch_size=batch_size,
    class_mode='binary')
```

↔ Found 160 images belonging to 2 classes.
Found 92 images belonging to 2 classes.

```
[ ] #cargar modelo vgg16 preentrenado
base_model=VGG16(weights='imagenet',include_top=False,input_shape=(img_width,img_height,3))

[ ] #Congelar las capas del modelo base
for layer in base_model.layers:
    layer.trainable=False

[ ] #crear modelo
model=Sequential()
model.add(base_model)
model.add(Flatten())
model.add(Dense(256,activation='relu'))
model.add(Dense(1,activation='sigmoid'))

[ ] #Compilar modelo
model.compile(optimizer=Adam(learning_rate=0.0001),loss='binary_crossentropy',metrics=['accuracy'])
```

```
▶ #evaluar el modelo
validation_generator.reset()
Y_pred = model.predict(validation_generator)
y_pred = (Y_pred > 0.5).astype(int)
print('Confusion Matrix')
print(confusion_matrix(validation_generator.classes, y_pred))
print('Classification Report')
target_names = ['No', 'Si']
print(classification_report(validation_generator.classes, y_pred, target_names=target_names,zero_division=1))
```

```
↩ 2/2 ————— 69s 21s/step
Confusion Matrix
[[14 24]
 [24 30]]
Classification Report

```

	precision	recall	f1-score	support
No	0.37	0.37	0.37	38
Si	0.56	0.56	0.56	54
accuracy			0.48	92
macro avg	0.46	0.46	0.46	92
weighted avg	0.48	0.48	0.48	92

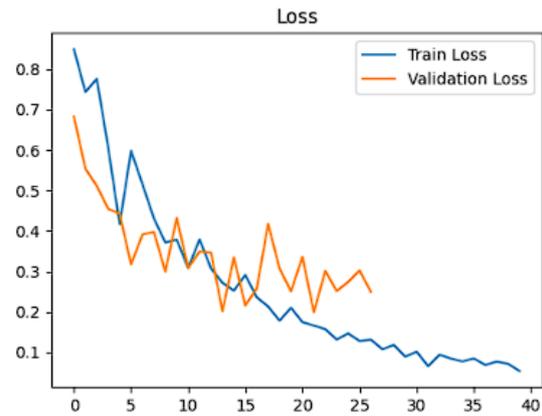
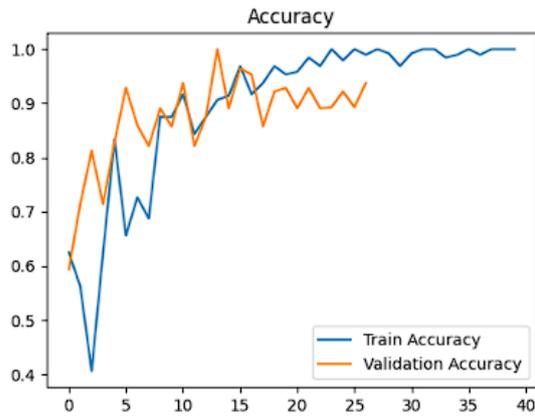
```

#graficar la precisión y la pérdida
plt.figure(figsize=(12, 4))
plt.subplot(1, 2, 1)
plt.plot(history.history['accuracy'], label='Train Accuracy')
plt.plot(history.history['val_accuracy'], label='Validation Accuracy')
plt.legend()
plt.title('Accuracy')

plt.subplot(1, 2, 2)
plt.plot(history.history['loss'], label='Train Loss')
plt.plot(history.history['val_loss'], label='Validation Loss')
plt.legend()
plt.title('Loss')

plt.show()

```



```
print("Precisión final en validación:", history.history['val_accuracy'][-1])
```

Precisión final en validación: 0.9375

Anexo 3

Código de modelo Modelo InceptionV3:

```
[1] #Importar librerías
import tensorflow as tf
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.applications import inception_v3
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Flatten
from tensorflow.keras.optimizers import Adam
from sklearn.metrics import classification_report, confusion_matrix
import matplotlib.pyplot as plt
import numpy as np
```

```
[2] #Definir parámetros
img_width, img_height = 224,224
batch_size = 64
epochs = 40
```

```
#Preparar los generadores de datos
from google.colab import drive
drive.mount('/drive')
```

Mounted at /drive

```
train_data_dir = '/drive/My Drive/imagenes_cerebro/Entrenamiento'
validation_data_dir = '/drive/My Drive/imagenes_cerebro/Validacion'
```

```
train_datagen=ImageDataGenerator(rescale=1./255)
validation_datagen=ImageDataGenerator(rescale=1./255)
```

```
train_generator=train_datagen.flow_from_directory(
    train_data_dir,
    target_size=(img_width,img_height),
    batch_size=batch_size,
    class_mode='binary')
```

```
validation_generator=validation_datagen.flow_from_directory(
    validation_data_dir,
    target_size=(img_width,img_height),
    batch_size=batch_size,
    class_mode='binary')
```

```
Found 160 images belonging to 2 classes.
Found 92 images belonging to 2 classes.
```

```

#cargar modelo InceptionV3 preentrenado
base_model=inception_v3.InceptionV3(weights='imagenet',include_top=False,input_shape=(img_width,img_height,3))

Downloading data from https://storage.googleapis.com/tensorflow/keras-applications/inception_v3/inception_v3_weights_tf_dim_ordering_tf_kernels_notop.h5
87910968/87910968 1s 0us/step

[6] #Congelar las capas del modelo base
for layer in base_model.layers:
    layer.trainable=False

#crear modelo
model=Sequential()
model.add(base_model)
model.add(Flatten())
model.add(Dense(256,activation='relu'))
model.add(Dense(1,activation='sigmoid'))

[8] #Compilar modelo
model.compile(optimizer=Adam(learning_rate=0.0001),loss='binary_crossentropy',metrics=['accuracy'])

```

```

[ ] #evaluar el modelo
validation_generator.reset()
Y_pred = model.predict(validation_generator)
y_pred = (Y_pred > 0.5).astype(int)

print('Confusion Matrix')
print(confusion_matrix(validation_generator.classes, y_pred))

print('Classification Report')
target_names = ['No', 'Si']
print(classification_report(validation_generator.classes, y_pred, target_names=target_names,zero_division=1))

```

```

2/2 18s 7s/step
Confusion Matrix
[[16 22]
 [23 31]]
Classification Report

```

	precision	recall	f1-score	support
No	0.41	0.42	0.42	38
Si	0.58	0.57	0.58	54
accuracy			0.51	92
macro avg	0.50	0.50	0.50	92
weighted avg	0.51	0.51	0.51	92

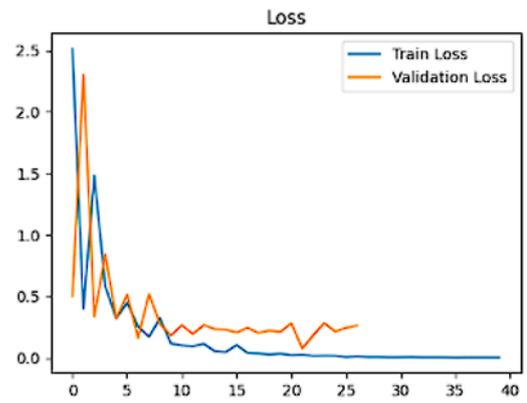
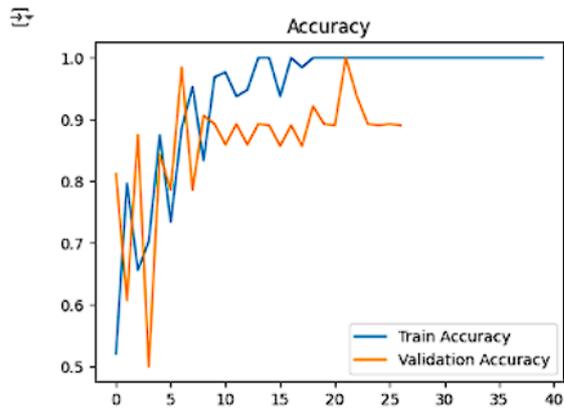
```

[11] #graficar la precisión y la pérdida
plt.figure(figsize=(12, 4))
plt.subplot(1, 2, 1)
plt.plot(history.history['accuracy'], label='Train Accuracy')
plt.plot(history.history['val_accuracy'], label='Validation Accuracy')
plt.legend()
plt.title('Accuracy')

plt.subplot(1, 2, 2)
plt.plot(history.history['loss'], label='Train Loss')
plt.plot(history.history['val_loss'], label='Validation Loss')
plt.legend()
plt.title('Loss')

plt.show()

```



Anexo 4

Código de modelo Modelo InceptionV3 base 3000 imágenes:

```
[1] #Importar librerías
import tensorflow as tf
from tensorflow.keras.preprocessing.image import ImageDataGenerator
from tensorflow.keras.applications import inception_v3
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Flatten
from tensorflow.keras.optimizers import Adam
from sklearn.metrics import classification_report, confusion_matrix
import matplotlib.pyplot as plt
import numpy as np
```

```
[2] #Definir parámetros
img_width, img_height = 224,224
batch_size = 64
epochs = 40
```

```
[ ] #Preparar los generadores de datos
from google.colab import drive
drive.mount('/drive')
```

Mounted at /drive

```
[ ] train_data_dir = '/drive/My Drive/3kimagenes/Entrenamiento'
validation_data_dir = '/drive/My Drive/3kimagenes/Validacion'

train_datagen=ImageDataGenerator(rescale=1./255)
validation_datagen=ImageDataGenerator(rescale=1./255)

train_generator=train_datagen.flow_from_directory(
    train_data_dir,
    target_size=(img_width,img_height),
    batch_size=batch_size,
    class_mode='binary')

validation_generator=validation_datagen.flow_from_directory(
    validation_data_dir,
    target_size=(img_width,img_height),
    batch_size=batch_size,
    class_mode='binary')
```

Found 2400 images belonging to 2 classes.
Found 600 images belonging to 2 classes.

```

#cargar modelo InceptionV3 preentrenado
base_model=inception_v3.InceptionV3(weights='imagenet',include_top=False,input_shape=(img_width,img_height,3))

Downloading data from https://storage.googleapis.com/tensorflow/keras-applications/inception_v3/inception_v3_weights_tf_dim_ordering_tf_kernels_notop_h5_87910968/87910968 1s 0us/step

[6] #Congelar las capas del modelo base
for layer in base_model.layers:
    layer.trainable=False

#crear modelo
model=Sequential()
model.add(base_model)
model.add(Flatten())
model.add(Dense(256,activation='relu'))
model.add(Dense(1,activation='sigmoid'))

[8] #Compilar modelo
model.compile(optimizer=Adam(learning_rate=0.0001),loss='binary_crossentropy',metrics=['accuracy'])

```

```

[ ] #evaluar el modelo
validation_generator.reset()
Y_pred = model.predict(validation_generator)
y_pred = (Y_pred > 0.5).astype(int)

print('Confusion Matrix')
print(confusion_matrix(validation_generator.classes, y_pred))

print('Classification Report')
target_names = ['No', 'Si']
print(classification_report(validation_generator.classes, y_pred, target_names=target_names,zero_division=1))

```

2/2 18s 7s/step

Confusion Matrix
[[16 22]
[23 31]]

Classification Report

	precision	recall	f1-score	support
No	0.41	0.42	0.42	38
Si	0.58	0.57	0.58	54
accuracy			0.51	92
macro avg	0.50	0.50	0.50	92
weighted avg	0.51	0.51	0.51	92

```

#graficar la precisión y la pérdida
plt.figure(figsize=(12, 4))
plt.subplot(1, 2, 1)
plt.plot(history.history['accuracy'], label='Train Accuracy')
plt.plot(history.history['val_accuracy'], label='Validation Accuracy')
plt.legend()
plt.title('Accuracy')

plt.subplot(1, 2, 2)
plt.plot(history.history['loss'], label='Train Loss')
plt.plot(history.history['val_loss'], label='Validation Loss')
plt.legend()
plt.title('Loss')

plt.show()

```

