



UNIVERSIDAD TECNOLÓGICA CENTROAMERICANA

FACULTAD DE INGENIERÍA

PROYECTO DE INVESTIGACIÓN

APLICACIÓN Y EVALUACIÓN DE ALGORITMOS DE CLASIFICACIÓN EN IMÁGENES DE
RESONANCIA MAGNÉTICA CEREBRAL PARA LA DETECCIÓN DE TUMORES.

PREVIO A LA OBTENCIÓN DEL TÍTULO

INGENIERÍA BIOMÉDICA

PRESENTADO POR:

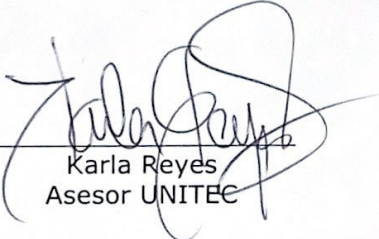
21851028 RAÚL ANDRÉS OSORTO MANZANARES

ASESOR: KARLA REYES

DICIEMBRE, 2023

HOJA DE FIRMAS


Los abajo firmantes damos fe, en nuestra posición de miembro de Terna, Asesor y jefe Académico y en el marco de nuestras responsabilidades adquiridas, que el presente documento cumple con los lineamientos exigidos por la Facultad de Ingeniería y los requerimientos académicos que la Universidad dispone dentro de los procesos de graduación.



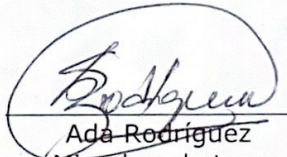
Karla Reyes
Asesor UNITEC



Manuel Gamero
Coordinador de terna



Erick Amaya
Miembro de terna



Ada Rodríguez
Miembro de terna



Reyna Valle

Jefe académico de Ing. Biomédica| UNITEC

EPÍGRAFE

"El verdadero signo de la inteligencia no es el conocimiento, sino la imaginación." - Albert Einstein

TABLA DE CONTENIDO

I. Resumen.....	XVIII
II. Introducción.....	XIX
III. Estado del Arte.....	XXI
3.1 Antecedentes.....	XXI
3.2 Problemática.....	39
3.3 Imagen integradora.....	40
3.4 Tabla de limitaciones.....	41
IV. Objetivo.....	44
4.1.1 Objetivo General.....	44
4.1.2 Objetivos Específicos.....	44
V. Método.....	45
5.1 Enfoque.....	45
5.2 Variables de Investigación.....	46
5.2.1 Variables dependientes:.....	46
5.2.2 Variables independientes:.....	47
5.3 Técnicas e Instrumentos Aplicados.....	48
5.3.1 Técnicas.....	48
5.3.2 Herramientas.....	52
5.4 Materiales.....	53
5.5 Metodología de estudio.....	55
5.5.1 Enfoque.....	55
5.5.2 Metodología de Validación.....	56
5.5.3 Creación de Conjunto de datos de Prueba y Validación.....	56
5.5.4 Matriz de Confusión.....	57
5.5.5 Análisis y Cálculos Numéricos.....	58
5.5.6 Cronograma de Actividades.....	58
5.5.7 Matriz Metodológica.....	60
5.5.8 Operacionalización de Variables.....	64
VI. Resultados y análisis.....	69

6.1	Incremento 1: Pruebas y Ajuste Fino para Modelos Preentrenados: EfficentNetBo, VGG16,ResNet50 E InceptionV3	69
1.1	Tabla -Comparativa de modelos EfficientNetB0 y VGG16 con un entrenamiento de 30 épocas.	72
6.2	Pruebas y Ajuste Fino para Modelos Pre-entrenados: InceptionV3 y Resnet 50 ..	77
6.3	Incremento 2: Creación de nueva base de datos	86
6.4	Incremento 3: Evaluación de Resultados de Red	87
6.5	Discusión de Resultados	87
6.5.1	Interpretación de datos y observaciones clave del Incremento 1	87
6.6	Análisis de datos de la validación	104
6.6.1	Interpretación de datos y observaciones clave del Incremento 2	106
6.6.2	Interpretación de datos y observaciones clave del Incremento 3	107
6.6.1	Posibles causas del descenso de la exactitud	113
7.6.3	Comparativa con los resultados del estado del arte	116
VII.	Conclusiones	117
VIII.	Agradecimientos.....	118
IX.	Referencias bibliográficas.....	119
X.	Anexos	123

ÍNDICE DE ILUSTRACIONES

Ilustración 1	Arquitectura del metodo propuesto	XXI
Ilustración 2	Tiempo que tarda cada proceso un paciente para ser diagnosticado en horas.....	40
Ilustración 3	Tiempo que tarda cada proceso un paciente para ser diagnosticado en horas.....	40
Ilustración 4	Arquitectura modelo VGG16.....	48
Ilustración 5	Arquitectura modelo InceptionV3.....	49
Ilustración 6	Arquitectura modelo ResNet50	50
Ilustración 7	Arquitectura Modelo EfficientNetB0	50
Ilustración 8	Imágenes de la base de datos.....	54
Ilustración 9	Imágenes divididas por clase	54
Ilustración 10	Imágenes divididas por categoría.....	55
Ilustración 11	Ejemplo Matriz de confusión incorrecta	57
Ilustración 12	Cantidad da pacientes distribuida por sexos	106

ÍNDICE DE TABLAS

Tabla 1	Diferentes arquitecturas y hiperparametros probados durante la investigacion.....	XXII
Tabla 2:	limitaciones	41
Tabla 3-	Metodología de Investigación.....	46
Tabla 4-	Operaciones con variables	64
Tabla 5-	Matriz de Observación de EfficientNetB0 con un entrenamiento de 30 épocas y un tamaño de lote de 64.....	90
Tabla 5-	Matriz de Observación de EfficientNetB0 con un entrenamiento de 30 épocas y un tamaño de lote de 64.....	93
Tabla 5-	Matriz de Observación de Resnet50 con un entrenamiento de 30 épocas y un tamaño de lote de 64.	97

Tabla 5- Matriz de Observación de InceptionV3 con un entrenamiento de 30 épocas y un tamaño de lote de 64.	101
Tabla 7- Numero de aciertos por clase.....	104
Tabla 8- numero de fallos.	104
Tabla 9- porcentaje de aciertos	105
Tabla 10- Precisión Entrenamiento vs testeo	105

ÍNDICE DE ECUACIONES

Ecuación 1	Exactitud	46
Ecuación 2	Precision.....	46
Ecuación 3	Sensibilidad	47
Ecuación 4	Puntaje F1	47

ÍNDICE DE ANEXOS

Anexo 1 Graficos de desempeño EfficientNetB0 epoca 12, lote 32.....	123
Anexo 2 Matriz de confusion EfficientNetB0 epoca 12, lote 32	123
Anexo 3 Graficos de desempeño EfficientNetB0 epoca 12, lote 64	124
Anexo 4 Matriz de confusion EfficientNetB0 epoca 12, lote 64	124
Anexo 5 Graficos de desempeño EfficientNetB0 epoca 12, lote 96	124
Anexo 6 Matriz de confusion EfficientNetB0 epoca 12, lote 96	125
Anexo 7 Graficos de desempeño EfficientNetB0 epoca 30, lote 32	125
Anexo 8 Matriz de confusion EfficientNetB0 epoca 30, lote 32	126
Anexo 9 Graficos de desempeño EfficientNetB0 epoca 30, lote 64	126
Anexo 10 Matriz de confusion EfficientNetB0 epoca 30, lote 64	127
Anexo 11 Graficos de desempeño EfficientNetB0 epoca 30, lote 96.....	127
Anexo 12 Matriz de confusion EfficientNetB0 epoca 30, lote 96	128
Anexo 13 Graficos de desempeño EfficientNetB0 epoca 50, lote 32.....	128

Anexo 14 Matriz de confusion EfficientNetB0 epoca 50, lote 32	129
Anexo 15 Graficos de desempeño EfficientNetB0 epoca 50, lote 64.....	129
Anexo 16 Matriz de confusion EfficientNetB0 epoca 50, lote 64	130
Anexo 17 Graficos de desempeño EfficientNetB0 epoca 50, lote 96.....	130
Anexo 18 Matriz de confusion EfficientNetB0 epoca 50, lote 96	131
Anexo 19 Graficos de desempeño VGG16 epoca 12, lote 32	131
Anexo 20 Matriz de confusion VGG16 epoca 12, lote 32	132
Anexo 21 Graficos de desempeño VGG16 epoca 12, lote 64	132
Anexo 22 Matriz de confusion VGG16 epoca 12, lote 64	133
Anexo 23 Graficos de desempeño VGG16 epoca 12, lote 96	133
Anexo 24 Matriz de confusion VGG16 epoca 12, lote 96	134
Anexo 25 Graficos de desempeño VGG16 epoca 30, lote 32	134
Anexo 26 Matriz de confusion VGG16 epoca 30, lote 32	135
Anexo 27 Graficos de desempeño VGG16 epoca 30, lote 64	135
Anexo 28 Matriz de confusion VGG16 epoca 30, lote 64	136
Anexo 29 Graficos de desempeño VGG16 epoca 30, lote 96	136
Anexo 30 Matriz de confusion VGG16 epoca 30, lote 96	137
Anexo 31 Graficos de desempeño VGG16 epoca 50, lote 32	137
Anexo 32 Matriz de confusion VGG16 epoca 50, lote 32	138
Anexo 33 Graficos de desempeño VGG16 epoca 50, lote 64	138
Anexo 34 Matriz de confusion VGG16 epoca 50, lote 64	139
Anexo 35 Graficos de desempeño VGG16 epoca 50, lote 96	139
Anexo 36 Matriz de confusion VGG16 epoca 50, lote 96	140
Anexo 37 Graficos de desempeño InceptionV3 epoca 12, lote 32.....	140
Anexo 38 Matriz de confusion InceptionV3 epoca 12, lote 32	141
Anexo 39 Graficos de desempeño InceptionV3 epoca 12, lote 64.....	142
Anexo 40 Matriz de confusion InceptionV3 epoca 12, lote 64	142

Anexo 41 Graficos de desempeño InceptionV3 epoca 12, lote 96.....	142
Anexo 42 Matriz de confusion InceptionV3 epoca 12, lote 96	143
Anexo 43 Graficos de desempeño InceptionV3 epoca 30, lote 32.....	143
Anexo 44 Matriz de confusion InceptionV3 epoca 30, lote 32	144
Anexo 45 Graficos de desempeño InceptionV3 epoca 30, lote 64.....	145
Anexo 46 Matriz de confusion InceptionV3 epoca 30, lote 64	145
Anexo 47 Graficos de desempeño InceptionV3 epoca 30, lote 96.....	146
Anexo 48 Matriz de confusion InceptionV3 epoca 30, lote 96	146
Anexo 49 Graficos de desempeño InceptionV3 epoca 50, lote 32.....	146
Anexo 50 Graficos de desempeño InceptionV3 epoca 50, lote 64.....	147
Anexo 51 Matriz de confusion InceptionV3 epoca 50, lote 64	147
Anexo 52 Graficos de desempeño InceptionV3 epoca 50, lote 96.....	148
Anexo 53 Matriz de confusion InceptionV3 epoca 50, lote 96	148
Anexo 54 Graficos de desempeño Resnet50 epoca 12, lote 32	149
Anexo 55 Matriz de confusion Resnet50 epoca 12, lote 32.....	149
Anexo 56 Graficos de desempeño Resnet50 epoca 12, lote 64	150
Anexo 57 Matriz de confusion Resnet50 epoca 12, lote 64.....	150
Anexo 58 Graficos de desempeño Resnet50 epoca 12, lote 96	151
Anexo 59 Matriz de confusion Resnet50 epoca 12, lote 96.....	151
Anexo 60 Graficos de desempeño Resnet50 epoca 30, lote 32	152
Anexo 61 Matriz de confusion Resnet50 epoca 30, lote 32.....	152
Anexo 62 Graficos de desempeño Resnet50 epoca 30, lote 64	153
Anexo 63 Matriz de confusion Resnet50 epoca 30, lote 64.....	153
Anexo 64 Graficos de desempeño Resnet50 epoca 30, lote 96	154
Anexo 65 Matriz de confusion Resnet50 epoca 30, lote 96.....	154
Anexo 66 Graficos de desempeño Resnet50 epoca 50, lote 32	155
Anexo 67 Matriz de confusion Resnet50 epoca 50, lote 32.....	155

Anexo 68 Graficos de desempeño Resnet50 epoca 50, lote 64	156
Anexo 69 Matriz de confusion Resnet50 epoca 50, lote 64.....	156
Anexo 70 Graficos de desempeño Resnet50 epoca 50, lote 96	157
Anexo 71 Matriz de confusion Resnet50 epoca 50, lote 96.....	157
Anexo 72 Prueba de inferencia clase no tumor.....	158
Anexo 73 Prueba de inferencia clase no tumor.....	159
Anexo 74 Prueba de inferencia clase no tumor.....	159
Anexo 75 Prueba de inferencia clase no tumor.....	160
Anexo 76 Prueba de inferencia clase no tumor.....	160
Anexo 77 Prueba de inferencia clase no tumor.....	161
Anexo 78 Prueba de inferencia clase no tumor.....	161
Anexo 79 Prueba de inferencia clase no tumor.....	162
Anexo 80 Prueba de inferencia clase no tumor.....	162
Anexo 81 Prueba de inferencia clase no tumor.....	163
Anexo 82 Prueba de inferencia clase no tumor.....	163
Anexo 83 Prueba de inferencia clase no tumor.....	164
Anexo 84 Prueba de inferencia clase no tumor.....	164
Anexo 85 Prueba de inferencia clase no tumor.....	165
Anexo 86 Prueba de inferencia clase no tumor.....	165
Anexo 87 Prueba de inferencia clase no tumor.....	166
Anexo 88 Prueba de inferencia clase no tumor.....	166
Anexo 89 Prueba de inferencia clase no tumor.....	167
Anexo 90 Prueba de inferencia clase no tumor.....	167
Anexo 91 Prueba de inferencia clase no tumor.....	167
Anexo 92 Prueba de inferencia clase no tumor.....	168
Anexo 93 Prueba de inferencia clase no tumor.....	168
Anexo 94 Prueba de inferencia clase no tumor.....	169

Anexo 95 Prueba de inferencia clase no tumor.....	169
Anexo 96 Prueba de inferencia clase no tumor.....	170
Anexo 97 Prueba de inferencia clase no tumor.....	170
Anexo 98 Prueba de inferencia clase no tumor.....	171
Anexo 99 Prueba de inferencia clase glioma	171
Anexo 100 Prueba de inferencia clase glioma	172
Anexo 101 Prueba de inferencia clase glioma	172
Anexo 102 Prueba de inferencia clase glioma	173
Anexo 103 Prueba de inferencia clase glioma	173
Anexo 104 Prueba de inferencia clase glioma	174
Anexo 105 Prueba de inferencia clase glioma	174
Anexo 106 Prueba de inferencia clase glioma	175
Anexo 107 Prueba de inferencia clase glioma	175
Anexo 108 Prueba de inferencia clase glioma	176
Anexo 109 Prueba de inferencia clase glioma	176
Anexo 110 Prueba de inferencia clase glioma	177
Anexo 111 Prueba de inferencia clase glioma	177
Anexo 112 Prueba de inferencia clase glioma	178
Anexo 113 Prueba de inferencia clase meningioma.....	178
Anexo 114 Prueba de inferencia clase meningioma.....	179
Anexo 115 Prueba de inferencia clase meningioma.....	179
Anexo 116 Prueba de inferencia clase meningioma.....	180
Anexo 117 Prueba de inferencia clase meningioma.....	180
Anexo 118 Prueba de inferencia clase meningioma.....	181
Anexo 119 Prueba de inferencia clase meningioma.....	181
Anexo 120 Prueba de inferencia clase meningioma.....	182
Anexo 121 Prueba de inferencia clase meningioma.....	182

Anexo 122 Prueba de inferencia clase meningioma.....	183
Anexo 123 Prueba de inferencia clase meningioma.....	183
Anexo 124 Prueba de inferencia clase meningioma.....	184
Anexo 125 Prueba de inferencia clase meningioma.....	184
Anexo 126 Prueba de inferencia clase meningioma.....	185
Anexo 127 Prueba de inferencia clase meningioma.....	185
Anexo 128 Prueba de inferencia clase meningioma.....	186
Anexo 129 Prueba de inferencia clase meningioma.....	186
Anexo 130 Prueba de inferencia clase meningioma.....	187
Anexo 131 Prueba de inferencia clase meningioma.....	187
Anexo 132 Prueba de inferencia clase meningioma.....	188
Anexo 133 Prueba de inferencia clase meningioma.....	188
Anexo 134 Prueba de inferencia clase meningioma.....	189
Anexo 135 Prueba de inferencia clase meningioma.....	189
Anexo 136 Prueba de inferencia clase meningioma.....	190
Anexo 137 Prueba de inferencia clase meningioma.....	190
Anexo 138 Prueba de inferencia clase meningioma.....	191
Anexo 139 Prueba de inferencia clase meningioma.....	191
Anexo 140 Prueba de inferencia clase meningioma.....	192
Anexo 141 Prueba de inferencia clase meningioma.....	192
Anexo 142 Prueba de inferencia clase meningioma.....	193
Anexo 143 Prueba de inferencia clase T pituitario.....	193
Anexo 144 Prueba de inferencia clase T pituitario.....	194
Anexo 145 Prueba de inferencia clase T pituitario.....	194
Anexo 146 Prueba de inferencia clase T pituitario.....	195
Anexo 147 Prueba de inferencia clase T pituitario.....	195
Anexo 148 Prueba de inferencia clase T pituitario.....	196

Anexo 149 Prueba de inferencia clase T pituitario.....	196
Anexo 150 Prueba de inferencia clase T pituitario.....	197
Anexo 151 Prueba de inferencia clase T pituitario.....	197
Anexo 152 Prueba de inferencia clase T pituitario.....	198
Anexo 153 Prueba de inferencia clase T pituitario.....	198
Anexo 154 Prueba de inferencia clase T pituitario.....	199
Anexo 155 Prueba de inferencia clase T pituitario.....	199
Anexo 156 Prueba de inferencia clase T pituitario.....	200
Anexo 157 Prueba de inferencia clase T pituitario.....	200
Anexo 158 Prueba de inferencia clase T pituitario.....	201
Anexo 159 Prueba de inferencia clase T pituitario.....	201
Anexo 160 Prueba de inferencia clase T pituitario.....	202
Anexo 161 Prueba de inferencia clase T pituitario.....	202
Anexo 162 Prueba de inferencia clase T pituitario.....	203
Anexo 163 Prueba de inferencia clase T pituitario.....	203
Anexo 164 Prueba de inferencia clase T pituitario.....	204
Anexo 165 Prueba de inferencia clase T pituitario.....	204
Anexo 166 Prueba de inferencia clase T pituitario.....	205
Anexo 167 Prueba de inferencia clase T pituitario.....	205
Anexo 168 Prueba de inferencia clase T pituitario.....	206
Anexo 169 Prueba de inferencia clase T pituitario.....	206
Anexo 170 Prueba de inferencia clase T pituitario.....	207
Anexo 171 Prueba de inferencia clase T pituitario.....	207
Anexo 172 Prueba de inferencia clase T pituitario.....	208
Anexo 173 Prueba de inferencia clase T pituitario.....	208

GLOSARIO

Capas de convolución son una parte fundamental de las redes neuronales convolucionales (CNN), utilizadas para extraer características de las imágenes. Estas capas aplican una serie de filtros a la entrada y producen mapas de características que resaltan patrones específicos en los datos, como bordes, texturas y formas. (*¿Qué son las redes neuronales convolucionales? | IBM, s. f.*)

Entropía cruzada es una medida utilizada en la teoría de la información y el aprendizaje automático para evaluar la diferencia entre dos distribuciones de probabilidad. En el contexto del aprendizaje automático, especialmente en la clasificación de problemas, la entropía cruzada se utiliza como una función de pérdida para evaluar la discrepancia entre la distribución de probabilidad predicha por el modelo y la distribución real de los datos. (KeepCoding, 2022)

Época en el contexto del aprendizaje automático y las redes neuronales, se refiere a una iteración completa de entrenamiento en la que se han procesado todos los ejemplos de entrenamiento disponibles. Durante una época, se envían todos los datos de entrenamiento a la red neuronal, y los pesos del modelo se ajustan en función de los errores de predicción.

Max-poolin es una técnica utilizada en redes neuronales convolucionales para reducir la dimensionalidad de las representaciones de las características y aumentar la eficiencia computacional. (*¿Qué es Epoch en Machine Learning? | Ciberseguridad, s. f.*)

Iteraciones de entrenamiento Es el número de veces que un modelo de aprendizaje automático recorre el conjunto de datos de entrenamiento completo durante el proceso de entrenamiento (*¿Qué es Epoch en Machine Learning? | Ciberseguridad, s. f.*)

Optimizador Es un algoritmo que ajusta los sesgos de la red neuronal y la Taza de aprendizaje. Ayudando a reducir la pérdida total y mejorando la precisión (Shah et al., 2022)

Pérdida Muestra que también se ajusta un algoritmo específico a los datos proporcionados para el aprendizaje automático (*Funciones de Pérdida en Aprendizaje Automático - Guía Completa, s. f.*)

LISTA DE SIGLAS

AI	INTELIGENCIA ARTIFICIAL
ANN	REDES NEURONALES ARTIFICIALES
CAD	SISTEMA DE AYUDA A LA DECISIÓN
CNN	RED NEURONAL CONVOLUCIONAL
DLS	DEEP LEARNING SISTEM
IRM	IMAGEN POR RESONANCIA MAGNÉTICA
SVM	MÁQUINAS DE SOPORTE VECTORIAL
TC	TOMOGRAFÍA COMPUTARIZADA
TL	APRENDIZAJE POR TRANSFERENCIA
RELU	RECTIFIED LINEAR UNIT

I. RESUMEN

Los tumores cerebrales son una de las enfermedades más peligrosas del sistema nervioso central, en este proyecto de investigación se busca mejorar y acelerar el proceso de detección de tumores cerebrales mediante el del aprendizaje profundo por transferencia con modelos preentrenados en imágenes de resonancia magnética (MRI) para clasificarlas en 4 diferentes clases mioma, meningioma, glioma y sin tumor. El aprendizaje profundo ha sido un área activa de investigación en los últimos años. El estudio adoptó un enfoque cuantitativo y tuvo un alcance exploratorio, además de un diseño experimental. La metodología utilizada se llevó a cabo de manera iterativa en cuatro fases sucesivas. En la primera etapa, se enfocaron en probar y ajustar el rendimiento del modelo VGG16, EfficienNetBo, resnet50 e InceptionV3. Posteriormente, en la segunda etapa, se estableció una base de datos de imágenes médicas de pacientes hondureños, y en la tercera etapa se realizaron de predicciones utilizando los modelos que mostraron un mejor rendimiento. Como resultado, se observó una exactitud promedio del modelo EfficienNetBO de 95%, una precisión promedio del 95%, una sensibilidad del 95% y un puntaje Fi 95% en la tercera etapa para los modelos evaluados. Se logró consolidar la creación de una base de datos local para futuras investigaciones y se validó el algoritmo de clasificación mediante predicciones de IRM de pacientes hondureños.

II. INTRODUCCIÓN

El cerebro, motor central de la experiencia humana, puede ser afectado por tumores cerebrales (TC), crecimientos anormales de células neurales y gliales (Rasheed et al., 2021). Estos tumores generan diversas complicaciones médicas, desde pérdida sensorial hasta convulsiones (Kibriya et al., 2022a). Pueden ser benignos o malignos; estos últimos son cancerosos, con capacidad de invadir tejidos y propagarse, un proceso llamado metástasis (Low et al., 2022). Gliomas, meningiomas y tumores hipofisarios son distintos tipos con orígenes celulares variados y tratamientos específicos (Rasheed et al., 2021). La detección temprana es vital para abordar estos tumores y mejorar las perspectivas de los pacientes. (Kominos et al., 2004)

En el periodo 2019-2023, Honduras reportó 27,145 casos de cáncer cerebral (*Entre 6,000 y 9,000 personas con cáncer se detectan cada año en Honduras, s. f.*). Aunque la biopsia es práctica estándar, su carácter invasivo presenta desafíos. La identificación precisa de tumores a través de métodos no invasivos como la MRI es más accesible. La detección de tumores varía según tamaño y ubicación; técnicas de imagen como resonancias magnéticas, tomografías o rayos X proporcionan detalles anatómicos y detectan masas o lesiones (Surawicz et al., 1998). La interpretación precisa de imágenes de MRI puede ser difícil debido a la incapacidad del ojo humano para distinguir entre tonos de gris y otros factores como fatiga del radiólogo o imágenes ruidosas. (*Error in Radiology - Clinical Radiology, s. f.*)

La inteligencia artificial (IA) y el aprendizaje automático son prometedores para el diagnóstico de tumores cerebrales (*An Efficient Method for Brain Tumor Detection Using Texture Features and SVM Classifier in MR Images, s. f.*). Estos sistemas automatizados pueden ayudar a evaluar la profundidad o tipo de tumor, reduciendo la necesidad de biopsias (Deepak & Ameer, 2019). El aprendizaje automático permite realizar tareas sin instrucciones explícitas, basándose en patrones, siendo el aprendizaje profundo atractivo por su capacidad de no requerir extracción manual de características.

El principal desafío de la implementación del aprendizaje profundo radica en la disponibilidad de bases de datos de imágenes de resonancia magnética; muchas personas no desean que se utilicen sus estudios radiológicos, incluso si

se mantienen anónimos(Willeminck et al., 2020). Varias investigaciones previas se han enfocado en clasificar tumores cerebrales utilizando diversas bases de datos de imágenes de resonancia magnética, ajustando parámetros y evaluando la precisión de los algoritmos de clasificación por lo que existen diversos enfoques y no se ha llegado a un consenso sobre cuál es la mejor forma de abordar la clasificación de tumores.

Se han logrado avances significativos en el área del aprendizaje profundo y la visión por computadora para realizar tareas muy precisas como la segmentación, detección y seguimiento de objetos. En esta investigación nos centraremos en la aplicación de redes neuronales convulsionales(CNN) para la clasificación de tumores cerebrales siendo utilizados los modelos preentrenados VGG16,InceptionV3, Resnet50 y EfficientNetB0.

Este proyecto de investigación plantea mejorar el rendimiento de un algoritmo de clasificación de imágenes de resonancia magnética del cerebro haciendo variaciones y entrenamiento con un banco de imágenes de resonancia magnética previamente. También, se cooperará con el Instituto Hondureño de Seguridad Social y dos hospitales de la zona industrial de Honduras para la invención de una base de datos de imágenes de resonancia magnética del cerebro para la validación del algoritmo y cualquier otro uso educativo.

La singularidad de esta investigación se manifiesta en la colaboración con el Instituto Hondureño de Seguridad Social y clínicas privadas, que ha permitido la formación de un conjunto de datos de validación compuesto por imágenes locales. Este acto no solo demuestra un compromiso profundo con la mejora de la representatividad de los datos en entornos clínicos hondureños, sino que también destaca la importancia de la creación de bases de datos específicas para la validación y el perfeccionamiento de algoritmos de aprendizaje profundo.

A lo largo de tres incrementos esenciales, desde la evaluación rigurosa de modelos hasta la implementación práctica del algoritmo, se evidencia cómo la creación de esta base de datos local ha sido la piedra angular del progreso técnico y científico. Este informe, por ende, no solo presenta avances en la eficacia de modelos de clasificación de tumores cerebrales, sino que también resalta la trascendencia de la creación de bases de datos específicas, subrayando la

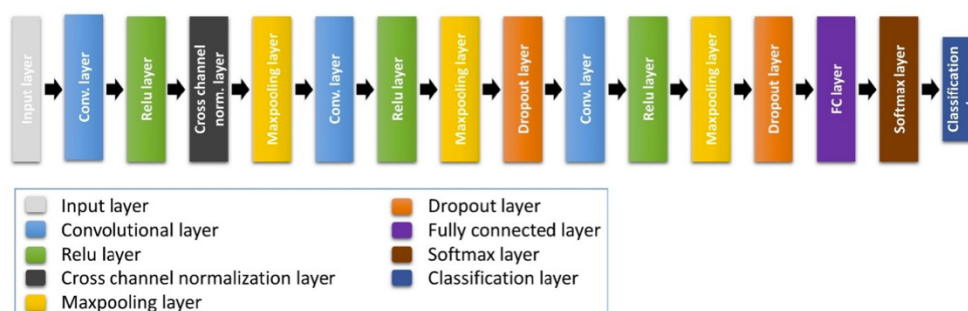
importancia de la transparencia, la aplicabilidad local y el potencial impacto global en el ámbito médico.

III. ESTADO DEL ARTE

3.1 ANTECEDENTES

Existen numerosos artículos relacionados a este tema de investigación como: (Willeminck et al., 2020) en el cual se crea un modelo de CNN con aprendizaje profundo utilizando dos bases de datos una para diferenciar tumores en Glioma, Meningioma y tumor pituitario. Y otra para diferenciar tumores glioma en grado I,II,III y IV. La base de datos incluye 3580 imágenes.

Ilustración 1 Arquitectura del método propuesto



Fuente:(*Sultan et al. - 2019 - Multi-Classification of Brain Tumor Images Using D.pdf, s. f.*)

El diagrama del método propuesto comienza con una base de datos con imágenes divididas por etiquetas que son preprocesadas, aumentadas y particionadas entre Entrenamiento y Validación, y las imágenes para pruebas. Se seleccionarán los Hiperparametros para la construcción de la arquitectura del CNN para luego entrenarlos con las imágenes de entrenamiento y validación, y el modelo final será probado con las imágenes de prueba.

La arquitectura propuesta de la red neuronal convolucional (CNN) consto de múltiples capas fundamentales. Comienzo con una capa de entrada que recibió

las imágenes aumentadas obtenidas en el paso previo de preprocesamiento. A continuación, se emplearon diversas capas de convolución para extraer características destacadas de las imágenes, seguidas de funciones de activación como ReLU, las cuales introducen no linealidad en la red. Asimismo, se aplicaron capas de normalización y de agrupación para normalizar los datos y reducir la dimensionalidad, respectivamente.

Con el fin de evitar el sobreajuste, se integró una capa de abandono, la cual descarta de manera aleatoria algunas de las características aprendidas durante el entrenamiento para promover una generalización más sólida. Posteriormente, se utilizó una capa completamente conectada que recopila las características extraídas y las interpreta para la predicción final de la salida. La capa softmax se utiliza para generar la distribución de probabilidad sobre las posibles clases de salida, mientras que la capa de clasificación produce la clase final predicha basándose en estas probabilidades.

Tabla 1 Diferentes arquitecturas y hiperparámetros probados durante la investigación

Factor	Valor
Numero de convoluciones + capas ReLu	1,2,3,4
Número de capas de normalización de canales cruzados.	1,2,3
Número de capas de abandono.	1,2,3
Máximo número de Épocas	20,40,60,80,100
Numero de capas totalmente conectadas	1,2,3
Numero de núcleos de convolución	8,16,32,64,128,256
Tamaño del núcleo	2,3,4,5

Capa de agrupamiento	Max Pooling, Average pooling
Tamaño de la ventana de la capa de agrupamiento.	2,3,4,5
Optimizador	SGD, Adam,RMSprop
Tamaño del mini lote	1,4,8,16,32,64,128
Tasa de abandono	0.1,0.15,0.2,0.25,0.5
Tasa de aprendizaje inicial	0.01,0.001,0.0001
Factor de reducción de la tasa de aprendizaje.	0.1,0.2,0.3

Fuente: (Sultan et al., 2019)

Entre otros estudios relevantes están los de Al-Azzwi y Nazarov, 2023 en su artículo el cual tuvo como objetivo mejorar la precisión en la predicción y clasificación de IRM de tumores cerebrales de varios modelos de aprendizaje profundo de conjunto. El método utilizado fue utilizar una base de datos de mangle con dos categorías cerebros normales y anormales y combinar un modelo CNN con tres modelos VGG19, Inception V3 y Resnet 10 para entrenarlos. Los pasos que siguieron para la realización del proyecto fueron en primer lugar alimentar al algoritmo con una base de datos, luego preprocesar estas imágenes para posteriormente afinar los modelos y luego estos puedan realizar una predicción. Para la elección de parámetros para preprocesar los datos se usaron El rango de zoom es de 0.1, los rangos de rotación, horizontalidad y brillo son de 0.5 y 1.0, respectivamente, y los rangos de preprocesamiento para el reescalado de imágenes, el desplazamiento de ancho y el desplazamiento de altura son cada uno de 0.1. también se dividió la base de datos en un 80% de entrenamiento y un 20% para la validacion. Para el modelo VGG19 su sintonización fina consistió en congelar las capas. Se utilizó el optimizador Adam. El entrenamiento llevó muchas horas, el tamaño del lote fue de 64 y la época fue de 25 para producir el resultado. Modelo: "secuencial", Parámetros totales: 20,049,473, Parámetros entrenables:

25,089; Parámetros no entrenables: 20,024,384. Los valores de exactitud 92%, precisión 97%, recuperación 91%, puntuación F1 son 94% respectivamente. Para el modelo Inception V3 se congelo la capa, Los parámetros totales son: 21,933,857, con 131,073 parámetros entrenables y 21,802,784 parámetros no entrenables, con 25 épocas. El valor de recuperación 97%, exactitud 97 %y puntuación F1 es del 97% y La precisión es del 96%. Por ultimo ResNet101 también se congelo la capa, Cuenta con 42,726,913 parámetros totales, 100,353 parámetros entrenables y 42,626,560 parámetros no entrenables. El valor de la precisión 1.00, recuperación 1.00, puntuación F1 es 1.00 y La precisión es 1.00.

Al congelar las capas se preservan los pesos previamente entrenados en ciertas capas, lo que garantiza que la red conserve el conocimiento adquirido durante el entrenamiento inicial. Este enfoque resulta útil cuando se trabaja con conjuntos de datos más pequeños o se busca evitar el sobreajuste en tareas específicas. Al restringir una parte de la red neuronal convolucional, se reduce la cantidad de parámetros ajustables durante el entrenamiento, lo que acelera el proceso en general. Esta estrategia es crucial en situaciones que involucran conjuntos de datos extensos o cuando se busca optimizar el tiempo de entrenamiento de la red.

Tabla 2 configuración de algoritmos de entrenamiento

Componente del modelo	Configuración
Datos de entrenamiento	80%
Datos de validación	20%
Optimizador	Adam
Época	25
Tamaño del lote	64
Radio de aprendizaje	0.0001

Clase	Dos
Perdida	Entropía cruzada

Fuente: (Al-Azzwi & Nazarov, 2023)

Una vez entrenados los 3 modelos se procede al apilamiento del aprendizaje en conjunto representada por el generalizador que fusiona las decisiones finales de los 3 clasificadores y así lograron una convergencia rápida y precisa de su modelo utilizando este método. Incrementaron el rendimiento de los modelos de bloques al apilarlos a través del entrenamiento.

En Musallam et al., 2022 buscaron mejorar la clasificación de IRM de tumores Gliomas, Meningiomas e Hipofisarios proponen un preprocesamiento de tres estepas; remover los objetos confusos como letras, número o áreas negras también eliminando el ruido de las IRM y por último la utilización del histograma de ecualización para mejorar las imágenes de resonancia magnética combinarlas Junto a una nueva arquitectura de red neuronal convolucional profunda (CDNN)

Esta arquitectura utilizo la normalización por lote para acelerar el entrenamiento aumentando la taza de aprendizaje y facilitando la inicialización de los pesos de las capas. La normalización por lotes se emplea para estabilizar y agilizar el proceso de entrenamiento de redes neuronales. Al mitigar los problemas relacionados con la variabilidad en la distribución de los datos durante el entrenamiento de redes profundas, este enfoque posibilita un aprendizaje más eficaz y veloz. Asimismo, puede contribuir a prevenir el sobreajuste en el modelo. El modelo es computacionalmente liviano cuenta con muy pocas capas de convolución, max-poolin y de iteraciones de entrenmiento. Se logro una precision general de 98.22%

En este artículo se propone una red neural convolucional profunda(DCNN) que consistirá en una parte convolucional con 10 capas convolucionales, 5 capas de lotes de normalización además de 4 capas de discretización o max-pooling y una parte destinada a la clasificación con 3 capas densas y 2 capas de abandono o dropout.

Tabla 3 Parámetros de los modelos utilizados

Parámetro	VGG16	VGG19	CNN-SVM	Modelo propuesto
Imagen de entrada	244x24 4x3	244x24 4x3	244x24 4x3	244x24 4x3
Función de activación	SoftMa x	SoftMa x	SoftMa x	SoftMa x
Optimizador	Adam	Adam	Adam	Adam
Época	60	60	60	60
Tamaño del lote	16	16	16	16
Radio de aprendizaje	0.0001	0.0001	0.0001	0.0001
Clase	cuatro	cuatro	cuatro	cuatro
Perdida	Entropía a cruzada	Entropía a cruzada	Entropía a cruzada	Entropía a cruzada

Fuente: (Musallam et al., 2022)

En Kibriya et al., 2022 proponen un método para clasificar tumores basado en la fusión profunda de características, que consiste en fusionar las características de las CNN AlexNet, GoogLeNet y ResNet 18 para construir un único vector, cargarlo en Support Vector Machine (SVM) y K-nearest neighbor (KNN). Este nuevo vector de características contiene más información que los modelos independientes

Se usa el aumento de datos artificial el cual consiste en aumentar el número de imágenes aplicando espejos, agregando ruido de sal y girando las imágenes en diferentes ángulos para combatir la problemática del limitado número de muestras de IRM y luego se entrena y evalúa con 15,320 IRM aumentadas.

La arquitectura de la CNN consta de dos partes un módulo de extracción de características que usa capas convolucionales para aprender y capas de

agrupación para reducir el tamaño de las imágenes, y un módulo de clasificación de las imágenes.

Este método logro una precisión del 99.7% en la detección de tumores Glioma, Pituitario y Meningioma.

Tabla 4 parametros utilizados en cada modelo

Parámetro	AlexNet	GoogLeNet	Resnet	Vector de características fusionado
Imagen de entrada	244x22 7x3	244x24 4x3	244x24 4x3	244x24 4x3
Función de activación	SoftMa	SoftMax	SoftMa	SoftMa
Optimizador	SGDM	SGDM	SGDM	SGDM
Época	30	30	30	30
Tamaño del lote	10	10	10	10
Radio de aprendizaje	0.0001	0.0001	0.0001	0.0001
Clase	cuatro	cuatro	cuatro	cuatro
Perdida	Entropía a cruzada	Entropía cruzada	Entropía a cruzada	Entropía a cruzada

Fuente (Kibriya et al., 2022b)

Este método logro una precisión del 99.7% en la detección de tumores Glioma, Pituitario y Meningioma.

En **“Clasificación de tumores cerebrales usando algoritmos de aprendizaje profundo”** Kadam, 2021

Se realizó un estudio comparativo de varios modelos de aprendizaje profundo basados en redes neuronales para clasificar tumores en 3 clases, benigno, maligno y pituitario. Usaron 3190 IRM que fueron limpiadas y aumentadas como base de datos para los modelos, el mejor modelo de TL fue VGG16 inicializado con pesos de imágenes y reentrenado con esta base de datos obteniendo una puntuación F1 del 94% con una precisión de prueba del 94% y una pérdida de prueba del 81%

Las imágenes de entrada al modelo VGG16 tenían dimensiones de (224,224,3). Estas imágenes atravesaban primero dos de las múltiples capas convolucionales. Luego, después de una capa ReLu y de maxpooling, ingresaban al segundo conjunto de dos capas convolucionales. Posteriormente, después de otra capa ReLu y de agrupamiento, los datos pasaban por 3 conjuntos de 3 capas de convolución y agrupamiento. Luego, había 3 capas totalmente conectadas. La salida de la capa final consistía en 1000 canales correspondientes a las 1000 clases del desafío ILSVRC, y posteriormente, la salida de la tercera capa totalmente conectada se pasaba a la capa softmax para normalizar el vector de clasificación. Para adaptar VGG16 a nuestro conjunto de datos, realizamos una modificación sencilla reemplazando la capa final de salida de 1000 clases por una salida de 4 clases. La estructura del modelo y los pesos asociados de la red se cargaron desde keras. Tras este paso, procedieron a entrenar el modelo con su conjunto de datos.

Lastimosamente este artículo no proporcionó información sobre cómo se configuraron los parámetros salvo que se usó Adam como optimizador en las pruebas de entrenamiento, si nos brindó los resultados de los modelos.

Tabla 5 Comparativa de los modelos de Aprendizaje por transferencia

Modelo de transferencia aprendizaje	Prueba de precisión	Prueba de perdida	Puntaje F1
VGG16	94	0.81	94
Inception V3	27	1.40	19
VGG19	47	0.46	33

ResNet50	88	0.41	88
MobileNet_V2	37	1.71	30

Fuente:(*Kadam - 2021 - Brain Tumor Classification using Deep Learning Alg.pdf*, s. f.)

Un estudio muy relevante para esta investigación es Shah et al., 2022 cuya investigación consistió en realizar varios experimentos con redes neuronales profundas, transferencia de aprendizaje y ajuste fino para automatizar el proceso de clasificación y detección de tumores.

El diagrama del modelo propuesto consistió en una base de datos de IRM que es preprocesada y aumentada para luego dividirse en 2400 imágenes para entrenamiento y 600 para validación, con estas imágenes entrenaron la red profunda y luego el modelo para que fuera capaz de tomar una decisión, luego se evaluó el rendimiento del modelo.

Este trabajo estuvo enfocado a la utilización de EfficientNet-B0 con las ultimas capas utilizadas actualizadas insertadas a través de la congelación de capas mediante el ajuste fino y el entrenamiento. Después de aumentar y ampliar las imágenes son enviadas al modelo reentrenado que extrajo las características como bordes, color, formas, redondes.

Las capas finales propuestas para el modelo EfficientNet-B0 consisten en un proceso de aplanamiento. El aplanamiento se refiere a la conversión de las características extraídas de la sexta capa MBConv en una estructura unidimensional que puede ser procesada más fácilmente., una capa de abandono es una técnica utilizada en redes neuronales para reducir el sobreajuste (overfitting) y mejorar la generalización del modelo. Durante el entrenamiento, la capa de abandono desactiva aleatoriamente un cierto porcentaje de neuronas en una capa determinada, lo que significa que su contribución se elimina temporalmente en ese paso hacia adelante y hacia atrás. También tiene dos capas completamente conectadas (FC). Se refiere a una configuración en la cual cada neurona de una capa está conectada a todas las neuronas de la capa siguiente. Esto implica que todas las entradas de una capa se utilizan para calcular las salidas de la siguiente capa, y un clasificador sigmoide. Los conjuntos de características

son extraídos desde la sexta capa MBConv y transformados en una estructura unidimensional mediante una capa aplanada. Tras este proceso de aplanamiento, los datos se canalizan hacia una capa densa que cuenta con 128 unidades ocultas, implica que hay 128 neuronas en esta capa que procesan los datos. La función de activación utilizada es la unidad lineal rectificadora ReLu, y se combina con otra capa densa que presenta una única neurona que representa las etiquetas proporcionadas, antes de realizar las predicciones.

Para entrenar y refinar el modelo se importó la biblioteca keras con un modelo base EfficientNet-B0 preentrenado con el conjunto de imágenes de Imagenet. Luego se congelaron todas las capas del modelo base antes de realizar el ajustar las capas finales propuestas con los datos de entrenamiento de IRM de tumores cerebrales. Después de entrenar el clasificador como las capas recomendadas se descongeló las capas completas de la red con los pesos obtenidos del conjunto de datos de ImageNet para crear el modelo definitivo. La red EfficientNet-B0 con ajuste fino propuesta alcanzó un (98.87%) en los datos de validación.

Tabla 6 Parámetros Configurados con EfficientNet-B0

Hiperparámetro	Configuración
Optimizador	Adam
Época	50
Tamaño del lote	32
Radio de aprendizaje	0.0001
Clase	cuatro
funcionPerdida	Entropía cruzada binaria

Fuente:(Shah et al., 2022)

En el artículo Srinivas et al., 2022 Se realizó un análisis comparativo del rendimiento de los modelos preentrenados basados en transferencia de aprendizaje VGG-16, ResNet-50 e Inception-V3. Este estudio se realizó con 233 imágenes obtenidas de Kaggle y tiene como objetivo localizar tumores cerebrales con IRM.

El método propuesto fue utilizar una CNN con arquitecturas preentrenadas para reentrenar el modelo y detectar tumores

El diagrama general de este modelo consiste en que se ingresó al algoritmo las IRM normales y con tumor luego se aumentó el número de imágenes artificialmente para después agregar las capas base de convolución de cada modelo y después entrenar la capa densa, como paso se realizó un ajuste fino y se volvió a entrenar el modelo para que pueda realizar las predicciones. Se ajustaron los hiperparámetros, incluyendo el recuento de neuronas y épocas, la función de activación softmax, la tasa de aprendizaje y el optimizador. El ajuste del número de capas de convolución se realizó como segundo paso del hiperparámetro. Pero no se ofrece mucha información sobre que valores se usaron.

Tabla 7 Configuración y parámetros entrenados

Hiperparámetro	Configuración
Optimizador	SMO
Época	75-125

Fuente:(Srinivas et al., 2022)

Por último (Reyes, 2022) es un Proyecto en el cual se analizó a varios modelos de CNN para clasificar IRM de tumores gliomas, meningiomas y tumores hipofisarios además de agregarle una cuarta clase que representa cerebros sin masa tumorales. En el caso de los modelos preentrenados se usó el aprendizaje por transferencia en que se emplean los pesos almacenados por la red y luego es entrenada con el conjunto de IRM. En este trabajo se mostraron los resultados obtenidos de los modelos, información acerca de la viabilidad de algunas arquitecturas muy populares, el empleo del aumento de datos y distintos preprocesamientos.

La metodología usada en el proyecto es una denominada como metodología de ciencia de datos y la definen como un marco iterativo, y se diferencia de otros métodos en que este cuenta con una primera fase en la que se realizan tareas de análisis, recolección y comprensión de datos.

La primera fase del proyecto consistió en la búsqueda de una base de datos con tumores a clasificar y pacientes sin tumores, posteriormente se empezó con la zona iterativa la cual correspondió a la zona práctica del proyecto comenzando con el modelaje de un primer modelo predictivo el cual fue entrenado y evaluado en la clasificación de las imágenes. Los resultados obtenidos del primer modelo sirven como pauta y alimentarán el proceso iterativo, a esto se le conoce como feedback ya que determinan los siguientes pasos a seguir con la idea de mejorar los resultados. Las tareas incluyen ajustar los hiperparámetros, agregar o quitar capas al modelo, crear más modelos y comparar resultados y realizar el despliegue del modelo.

En esta etapa se incluyó la creación y ajuste fino del primer modelo predictivo desde cero, utilizando capas de convoluciones y capas de submuestreo Max Poolin2D. Esta primera red lograba apenas un 60% en la tasa de predicción pero sirve como base para los siguientes modelos propuestos ya que sufrió varias modificaciones y pruebas con varios hiperparámetros y optimizadores, tras cada modificación fue reentrenada y los resultados servían como feedback, permitiendo al autor realizar las modificaciones de manera cíclica hasta alcanzar un 90% de precisión.

Para mejorar ese 90% de predicción se utilizaron varios modelos de aprendizaje profundo como los VGG, ResNet, Xception y algunas de sus variantes. Posteriormente el autor utilizó transferencia de aprendizaje en varios modelos como VGG-16 que había obtenido apenas un 30% en la etapa anterior mejorándola hasta un 90% por lo cual se procedió a utilizar ese método con el resto de modelos.

Posteriormente se encuentra la parte de esquematización y análisis de resultados en la cual se englobó el desarrollo de la parte analítica del proyecto, mostrando gráficas y métricas relacionadas con, Pérdida, Precisión, recuperación, puntaje F-1, matrices de confusión y predicciones

El modelo propuesto cuenta con una configuración secuencial, lo que significa que utilizo un apilamiento por capas. La capa inicial fue de tipo convoluciones Conv2D, que hace la función de capa de entrada y conecta sus neuronas con las capas de la imagen. La primera capa convolucional tiene un conjunto de 64 filtros de salida, un tamaño de núcleo de 2x2, El núcleo determina el tamaño del área de la imagen que se está analizando en un momento dado. y un Stride predeterminado de 1x1, El "Stride" define cómo se mueve el filtro a lo largo de la imagen. Realiza una convolución entre los filtros y la entrada para extraer características específicas de la imagen. El número de filtros indica la cantidad de características diferentes que se están buscando El "Padding" mantiene el tamaño de la imagen de salida igual que el de la imagen de entrada.

Utiliza el relleno "Same" para mantener una cantidad uniforme de píxeles en todas las direcciones, y emplea la función de activación ReLU. Esta función se aplica a la salida de la capa convolucional y elimina los valores negativos, lo que permite que la red aprenda de manera más eficiente y acelera el proceso de entrenamiento. Todos los parámetros, excepto el número de filtros de salida, permanecen constantes en cada capa convolucional. Las capas convolucionales en esta red están dispuestas de manera que la primera tenga 64 filtros, la segunda 128, la tercera 256, la cuarta 128 y la quinta 512. Después de cada capa convolucional, se aplica una capa de submuestreo MaxPooling2D que redujo a dimensionalidad de la imagen y ayuda a disminuir la cantidad de parámetros en la red. El submuestreo se realiza seleccionando el valor máximo de un área específica de la imagen. con un núcleo de 2x2 y una capa de Dropout esta capa se utiliza para evitar el sobreajuste en la red neuronal, Durante el entrenamiento, apaga un porcentaje de las neuronas de manera aleatoria, lo que evita que la red se vuelva demasiado dependiente de ciertas neuronas y características específicas. con una tasa del 20% para reducir el overfitting.

Por último, la red consta de una capa de "aplanamiento" que transforma los datos matriciales en datos vectoriales, una capa densa con 1024 filtros de salida como capa conectada, otra capa de Dropout con una tasa del 50%, y una capa de salida con cuatro neuronas que utiliza la activación Softmax para producir la respuesta del modelo.

Luego se cargó cada modelo y se congeló agregando el modelo propuesto en la última capa de cada modelo para luego ser evaluado en distintas métricas por varias épocas de 0 a 50 en múltiplos de 10. El modelo utilizó el optimizador Adam con una tasa de aprendizaje específica, la función de pérdida "categorical_crossentropy" y la métrica de evaluación "accuracy".

Tabla 8 Resultados con aumento de datos

	Modelo	Entrenamiento	Validación	Prueba
	ResNet50V2			
TFL		0.853	0.8198	0.813
	VGG-19 TFL	0.7738	0.8	0.8206
	Xception TFL	0.8112	0.8183	0.832
	VGG-16 TFL	0.7999	0.8458	0.8321
	ResNet101			
GS		0.8082	0.8305	0.8473
	Custom RGB	0.801	0.8229	0.8511
	ResNet101V2			
TFL		0.8338	0.829	0.8511
	ResNet152V2			
GS		0.8854	0.829	0.855
	ResNet50V2			
RGB		0.9956	0.916	0.8893
	ResNet50V2			
GS		0.9916	0.9053	0.9198
	Xception GS	0.9425	0.9008	0.9275

Fuente:(Reyes, 2022)

Tabla 9 Resultados sin aumento de datos

Modelo	Entrenamiento	Validación	Prueba
---------------	----------------------	-------------------	---------------

	ResNet50V2			
RGB		0.9892	0.8489	0.8588
	ResNet152V2			
RGB		0.9782	0.8641	0.8588
	ResNet101			
RGB		0.9904	0.8153	0.8664
	ResNet101			
GS		0.9881	0.8794	0.8702
	ResNet50V2			
TFL		0.9688	0.8824	0.8779
	ResNet152V2			
TFL		0.9827	0.8855	0.8779
	ResNet101V2			
TFL		0.9922	0.9008	0.8931
	VGG-16 TFL	0.9759	0.9145	0.9046
	Xception GS	0.9949	0.9252	0.9048
	Custom RGB	0.9827	0.9298	0.9122
	Custom GS	0.9753	0.913	0.9237
	VGG-19 TFL	0.954	0.913	0.9237
	Xception RGB	0.9988	0.9435	0.9274
	Xception TFL	0.9982	0.9573	0.9656

Fuente:(Reyes, 2022)

No existen estudios exactos acerca de la detección de tumores en Honduras, debido a esto se recurrió a revisar la literatura de otros países.

Tabla 10 Comparación de modelos, parámetros y resultados obtenidos

Estudio	Modelos	Parámetros	Resultados Obtenidos
"Clasificación múltiple de imágenes de tumores cerebrales utilizando redes neuronales profundas" (Sultan et al., 2019)	CNN elaborado por el autor	Tamaño del lote:1,4,8,16,32,64,128 Época: 20,40,60,80,100	96.13%
"Clasificación de tumores cerebrales basada en métodos mejorados de aprendizaje profundo de conjuntos apilados" (Al-Azzwi y Nazarov, 2023)	Vgg19, Inception v3, resnet 101 + CNN	Tamaño del lote: 64 Época: 25	94% 97% 1%
"Una Nueva Arquitectura de Red Neuronal Convolutiva para la Detección Automática de Tumores Cerebrales en Imágenes de Resonancia Magnética" (Musallam et al., 2022)	DCNN	Tamaño del lote: Época:	98.22
Un modelo novedoso y efectivo de clasificación de tumores cerebrales	Vector de características	Tamaño del lote:30 Epoca:10	99.7%

que utiliza la fusión profunda de características y clasificadores famosos de aprendizaje automático” Kibriya et al., 2022	Fusionado AlexNet, GoogLeNet, Resnet		
“Clasificación de tumores cerebrales usando algoritmos de aprendizaje profundo” (Kadam, 2021)	Estudios comparativos. Mejor modelo VGG16	Tamaño del lote:-- Época:-- Optimizador Adam	94%
“Una aproximación robusta para la detección de tumores cerebrales en imágenes de resonancia magnética mediante la afinación de EfficientNet.”(Shah et al., 2022)	EfficientNet	Tamaño del lote:50 Epoca:32	98.87
“Enfoques profundos de transferencia de aprendizaje en el análisis de rendimiento de la clasificación de tumores cerebrales utilizando imágenes de resonancia magnética (MRI).” Srinivas et al., 2022	VGG16,resnet50, InceptionV3	Tamaño del lote:-- Epoca:75-125	96%,95%,75%
“Clasificación Automática de Tumores Cerebrales Haciendo Uso de Redes Neuronales”(Reyes, 2022)	Xception,VGG, Resnet	Tamaño del lote: Epoca:10,20,30,40,50	96.56%,92.37%



3.2 PROBLEMÁTICA

Se evidencia la necesidad de la creación de más bases de datos para hacer estudios más precisos ya que los estudios analizados en los antecedentes comparten en su mayoría la misma base de datos.

La detección temprana y precisa de tumores cerebrales es fundamental para mejorar los resultados clínicos y la supervivencia de los pacientes. Las imágenes de resonancia magnética cerebral son una herramienta de diagnóstico clave utilizada por los neurocirujanos, radiólogos y oncólogos para identificar y caracterizar tumores cerebrales.

En Honduras existen muy pocos hospitales públicos y privados que tengan equipos de Resonancia Magnética y el acceso a la información de los pacientes es muy limitada, esto constituye un atraso para la implementación de la inteligencia artificial para la clasificación de tumores cerebrales.


En los últimos años, el aprendizaje profundo, especialmente las redes CNN, mostrado un gran potencial en la clasificación de tumores cerebrales. Estas redes pueden aprender automáticamente características discriminativas a partir de las imágenes sin la necesidad de una extracción manual. Además, la arquitectura de las CNN permite capturar información espacial en las imágenes, lo que las hace adecuadas para tareas de clasificación de imágenes médicas, como la detección de tumores cerebrales.

La mayoría de los estudios han utilizado arquitecturas de redes neuronales preentrenadas, como VGGNet, ResNet y InceptionNet (Low et al., 2022) (Kadam, 2021), para clasificar tumores cerebrales en imágenes de resonancia magnética cerebral. Estas redes se han adaptado utilizando la misma base de datos de imágenes y un método llamado aumento de datos para suplir la poca cantidad de estudios de RM de tumores cerebrales y así intentar mejorar la precisión.

Es necesario invertir y promover el desarrollo de investigaciones científicas relacionadas a la detección de estos tumores para poder generar herramientas como algoritmos o softwares que puedan ser útiles en el diagnóstico clínico de estas enfermedades.


3.3 IMAGEN INTEGRADORA

Ilustración 2 Tiempo que tarda cada proceso un paciente para ser diagnosticado en horas



Fuente: Autoría Propia

Ilustración 3 Tiempo que tarda cada proceso un paciente para ser diagnosticado en horas



Fuente: Autoría Propia

El tiempo requerido para el diagnóstico de un tumor puede variar considerablemente, según la disponibilidad de recursos médicos y la complejidad del caso. En primer lugar, una evaluación inicial completa, que incluye un examen

médico exhaustivo, generalmente toma alrededor de una o dos horas, dependiendo de la naturaleza de los síntomas. Las pruebas diagnósticas, como análisis de sangre y pruebas de diagnóstico por imágenes, pueden ofrecer resultados en un plazo de horas o días, dependiendo del tipo de prueba y la carga de trabajo del laboratorio. En el caso de una biopsia, el procedimiento en sí dura entre 30 minutos y una hora, y los resultados de la biopsia pueden tardar desde varios días hasta una semana, según el tipo de análisis requerido y la capacidad del laboratorio. Las consultas con especialistas y la revisión de los resultados pueden programarse dentro de unos pocos días a una semana, dependiendo de la urgencia del caso y la disponibilidad del especialista. Por lo tanto, el proceso de diagnóstico completo podría llevar desde unos pocos días hasta un par de semanas, dependiendo de las circunstancias individuales. Comunicarse abiertamente con el equipo médico puede ayudar a obtener una comprensión clara de los plazos esperados y garantizar un seguimiento adecuado para obtener resultados lo más rápido posible.

3.4 TABLA DE LIMITACIONES

Tabla 2: limitaciones

Estudio	Limitaciones	Descripción
“Clasificación múltiple de imágenes de tumores cerebrales utilizando redes neuronales profundas” (Sultan et al., 2019)	Base de datos limitada. Limitaciones por Google Colab.	Al usar aumento de datos puede introducir ruido a los datos
“Clasificación de tumores cerebrales basada en métodos mejorados de aprendizaje profundo de	Base de datos limitada Limitaciones por Google Colab.	Al usar aumento de datos puede introducir distorsiones a los datos

conjuntos apilados" (Al-Azzwi y Nazarov, 2023)

"Una Nueva Base de datos Al usar Arquitectura de Red limitada aumento de datos Neuronal Convolutiva para puede introducir la Detección Automática de muestras que no son Tumores Cerebrales en representativas de la Imágenes de Resonancia Magnética" (Musallam et al., 2022)

"Clasificación de Base de datos El aumento de tumores cerebrales usando limitada datos puede traer algoritmos de aprendizaje profundo" (Kadam, 2021) consigo a una ampliación excesiva de los datos podría llevar a un sobreajuste del modelo a los datos de entrenamiento específicos

"Una aproximación Base de datos El aumento de robusta para la detección de limitada datos puede resultar tumores cerebrales en imágenes de resonancia magnética mediante la afinación de EfficientNet."(Shah et al., 2022) en un rendimiento deficiente en datos no vistos.

"Enfoques profundos Base de datos La ampliación de transferencia de limitada datos puede aumentar aprendizaje en el análisis de rendimiento de la clasificación de tumores cerebrales utilizando imágenes de resonancia computacional y el tiempo de procesamiento

magnética (MRI).” Srinivas
et al., 2022

“Clasificación Automática de Tumores Cerebrales Haciendo Uso de Redes Neuronales” (Reyes, 2022)	Emplear modelos de Keras implementados en Python, aplicaciones webs	Desde fallos propios del autor como realizar las validaciones con el lote de testeo, hasta fallos sin solución de librerías.
	Limitaciones por Google Colab.	Se agotaron los 15 Gb de GPU proporcionados por Google colab

IV. OBJETIVO

4.1.1 OBJETIVO GENERAL

1. Incrementar el valor de las métricas de desempeño de un algoritmo de clasificación de imágenes de resonancia magnéticas de corte axial, sagital y coronal de tumores cerebrales basado en algoritmos de aprendizaje profundo de clasificación.

4.1.2 OBJETIVOS ESPECÍFICOS

1. Utilizar la bibliografía de la literatura para seleccionar modelos utilizados en el estado del arte y detectar parámetros para modificar con el fin de aumentar el desempeño de los algoritmos seleccionados.
2. Modificar los parámetros de entrenamiento en cada uno de los algoritmos y realizar entrenamiento de las redes con el fin de detectar una red con mayor precisión.
3. Validar el algoritmo que presente mayor desempeño con imágenes de pacientes hondureños recolectadas en el Instituto Hondureño de Seguridad Social.
4. Crear una base de datos con las imágenes recolectadas.

V. MÉTODO

En esta sección se presenta la metodología empleada en el desarrollo de este estudio, la cual incluye la definición del enfoque de la investigación, su alcance y diseño, así como las variables dependientes e independientes. También se describen los métodos utilizados para alcanzar los objetivos establecidos.

5.1 ENFOQUE

El enfoque de la investigación es Iterativo o también conocido como cuantitativo debido a que se evaluaron métricas como puntaje F1, exactitud, sensibilidad y precisión del algoritmo para validar la eficacia al momento de la clasificación de imágenes. El diseño es experimental ya que se modificaron las variables. También se entrenó el modelo y se modificaron los parámetros para ver si estas alteraciones aumentan o no el rendimiento del algoritmo.

En Honduras no se han realizado investigaciones acerca del uso de algoritmos para la clasificación de tumores cerebrales por lo que el alcance de la investigación es exploratorio.

Tabla 3- Metodología de Investigación

Metodología de Investigación	
Enfoque	iterativo
Tipo de diseño	Experimental
Alcance	Exploratorio

Fuente: Autoría propia

5.2 VARIABLES DE INVESTIGACIÓN

5.2.1 VARIABLES DEPENDIENTES:

Exactitud (Accuracy): La proporción de predicciones correctas en relación con el total de predicciones. Aunque es una métrica común, puede ser engañosa en conjuntos de datos desequilibrados.

Ecuación 1 Exactitud

$$\text{Exactitud} = \frac{\sum_i^{\text{Número de clases}} TP}{\text{Número de imágenes de prueba}} \times 100\%$$

PRECISIÓN (PRECISIÓN): La precisión es la proporción de predicciones positivas (clase identificada) que fueron realmente correctas en relación con el total de predicciones positivas realizadas por el modelo. Esta métrica mide la capacidad del modelo para evitar la clasificación errónea de ejemplos negativos como positivos.

Ecuación 2 Precisión

$$\text{Precisión} = \frac{TP}{TP + FP} \times 100\%$$

SENSIBILIDAD (RECALL): TAMBIÉN conocida como Sensibilidad o Tasa de Verdaderos Positivos, es la proporción de ejemplos positivos que el modelo identificó correctamente en relación con el total de ejemplos positivos reales en el conjunto de datos. Mide la capacidad del modelo para detectar con éxito todos los ejemplos positivos.

Ecuación 3 Sensibilidad

$$\text{Sensibilidad} = \frac{TP}{TP + FN} \times 100\%$$

Puntuación F1 (F1 Score): Es una medida que combina la precisión y la recuperación en un solo valor. Es la media armónica de la precisión y la recuperación, lo que la hace útil cuando deseamos un equilibrio entre ambas métricas. Se utiliza especialmente cuando las clases están desequilibradas.

Ecuación 4 Puntaje F1

$$\text{Puntaje F1} = 2 \times \frac{\text{Sensibilidad} \times \text{Precisión}}{\text{Sensibilidad} + \text{Precisión}} \times 100\%$$

5.2.2 VARIABLES INDEPENDIENTES:

- Modelos pre-entrenados de aprendizaje profundo: se refieren a redes neuronales que han sido entrenadas previamente y que pueden aplicarse para realizar tareas de aprendizaje profundo, como la clasificación de imágenes. En esta investigación utilizaremos VGG16, InceptionV3, Resnet50 y EfficientNetB0 que obtuvieron mejores resultados (*Kadam - 2021 - Brain Tumor Classification using Deep Learning Alg.pdf, s. f.*)
- Épocas: se define como la cantidad de veces que un algoritmo aprende de todos los ejemplos durante la fase de entrenamiento. De 10-100 en múltiplos de 10 ya que fueron los valores mínimos y máximos que se cambiaron en la teoría (*Sultan et al. - 2019 - Multi-Classification of Brain Tumor Images Using D.pdf, s. f.*)
- Tamaño de lote: hace referencia a la cantidad de ejemplos de entrenamiento utilizados para actualizar los pesos del algoritmo en cada paso durante la fase de entrenamiento. De uno 1,8,16,32,64,128 los

tamaños mínimos y máximos que se cambiaron en la literatura(Sultan et al. - 2019 - Multi-Classification of Brain Tumor Images Using D.pdf, s. f.)

5.3 TÉCNICAS E INSTRUMENTOS APLICADOS


En esta sección, se detallan las técnicas e instrumentos utilizados, los cuales son herramientas fundamentales para asegurar la confiabilidad y validez de los resultados obtenidos. Estas herramientas fueron de gran importancia para obtener datos precisos y lograr una interpretación precisa de los resultados.

5.3.1 TÉCNICAS

Para las técnicas para poder clasificar las imágenes según el diagnóstico, ya sea Mioma, Meningioma, tumor hipofisario o sano, se utilizaron algoritmos del estado del arte como ser VGG16, InceptionV3 y Resnet50. Cada uno de estos son modelos pre-entrenados que utilizan aprendizaje profundo para lograr identificar y clasificar un conjunto de imágenes de una determinada base de datos.

5.3.1.1 ARQUITECTURA DE VGG16

VGG16 es una red neuronal convolucional profunda conocida por su diseño sencillo pero efectivo. Consta de 16 capas, incluyendo capas convolucionales y completamente conectadas, empleando convoluciones de 3x3 y agrupaciones máximas de 2x2. A pesar de su simplicidad, VGG16 ha demostrado ser altamente competente en tareas de clasificación de imágenes. Ilustración 4 Arquitectura modelo VGG16



Fuente:(Srinivas et al., 2022)

5.3.1.2 ARQUITECTURA DE INCEPTION V3

Inception V3, desarrollada por Google, destaca por su eficiencia y rendimiento en la clasificación de imágenes. Su enfoque innovador se basa en módulos de Inception, que facilitan el procesamiento simultáneo de convoluciones de diferentes tamaños, permitiendo capturar características a múltiples escalas y mejorando la eficiencia general de la red.

Ilustración 5 Arquitectura modelo InceptionV3

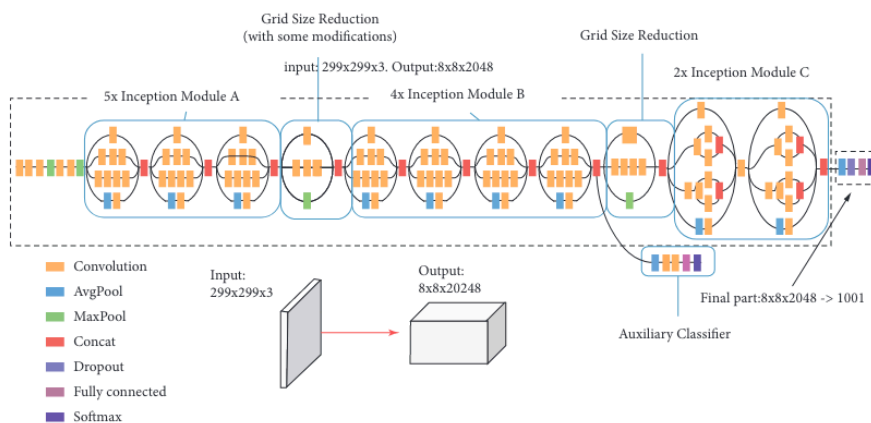


FIGURE 10: Inception-v3 model architecture.

Fuente:(Srinivas et al., 2022)

5.3.1.3 ARQUITECTURA DE RESNET50

ResNet50 es una red neuronal convolucional profunda que aborda el desafío de entrenar redes más profundas sin sufrir el problema de la desaparición del gradiente. Creada por Microsoft Research, se compone de 50 capas y se distingue por el uso de conexiones residuales que facilitan una propagación de gradientes más efectiva a lo largo de la red, lo que simplifica el entrenamiento de modelos más profundos.

Ilustración 6 Arquitectura modelo ResNet50





FIGURE 11: ResNet50 model architecture.

Fuente: (Srinivas et al., 2022)

5.3.1.4 EFICIENTNET

EfficientNet representa una serie de redes neuronales convolucionales (CNN) creadas por investigadores de Google AI en 2019. Esta familia de redes ha destacado por su habilidad para lograr un rendimiento excepcional en la clasificación de imágenes utilizando menos recursos computacionales que sus predecesoras. Este logro tiene implicaciones significativas para el desarrollo futuro de la Inteligencia Artificial, ya que podría impulsar la creación de sistemas más poderosos y eficientes, adaptables a una amplia gama de dispositivos, desde teléfonos inteligentes hasta sistemas informáticos de alto rendimiento.

Ilustración 7 Arquitectura Modelo EfficientNetB0



Fuente: (Shah et al., 2022)

La efectividad de EfficientNet radica en su arquitectura innovadora y en una técnica denominada "escalado compuesto". A diferencia de las estrategias convencionales de escalado en redes neuronales, que tienden a modificar de forma independiente la profundidad, el ancho o la resolución de la red, el enfoque de escalado compuesto ajusta estas tres dimensiones simultáneamente, basándose en un conjunto fijo de coeficientes de escala. Esta estrategia permite que EfficientNet mantenga un equilibrio entre las diferentes dimensiones, optimizando así el uso de recursos computacionales y mejorando el rendimiento de manera eficaz.

Además, los investigadores presentaron EfficientNet-B0 como un nuevo punto de referencia, desarrollado mediante una técnica conocida como "Búsqueda de Arquitectura Neuronal" (NAS). Esta técnica implica el uso de algoritmos de aprendizaje automático para buscar la mejor estructura para una tarea específica, en lugar de depender únicamente de la intuición humana o de pruebas y errores. En el caso de EfficientNet-B0, los investigadores utilizaron un algoritmo de aprendizaje por refuerzo para encontrar la combinación óptima de capas y operaciones para la clasificación de imágenes. Como resultado, se obtuvo un modelo compacto y eficiente que superó a sus predecesores en el conjunto de datos ImageNet, ampliamente reconocido en la comunidad de visión por computadora.

5.3.1.5 PROCESO DE TRANSFERENCIA DE APRENDIZAJE PROFUNDO.

Dado que este estudio implica la utilización de múltiples modelos preentrenados de aprendizaje profundo para la clasificación de imágenes de la columna vertebral, es necesario comprender el proceso por el cual se lleva a cabo el aprendizaje de transferencia. El proceso comienza con la adquisición de cada modelo, cada uno de los cuales tiene su propia arquitectura, compuesta por varias capas. Cada modelo incluye una capa de salida que ya ha sido entrenada con los pesos obtenidos de ImageNet.

El primer paso es descartar la capa final del modelo preentrenado luego se agrega una nueva capa de clasificación de cuatro nodos, uno para cada clase. Posteriormente se congelan todas las capas preentrenadas para mantener sus pesos fijos, esto evita que se pesos se modifiquen durante el entrenamiento con la nueva base de datos, luego se incorpora la capa de salida que aborda el problema de clasificación específico de esta investigación. Los parámetros de esta capa son la cantidad de clases, que en este caso es cuatro (correspondientes a las clases de Glioma, Meningioma y Tumor hipofisiario y cerebro normal).

Finalmente se entrena el modelo con la nueva base de datos ajustando los parámetros para mejorar el algoritmo como la tasa de aprendizaje, el número de épocas, el tamaño de lote, entre otros.

Esto permitirá reutilizar las características aprendidas por el modelo preentrenado en las primeras capas para acelerar el proceso de entrenamiento y mejorar la precisión.

5.3.2 HERRAMIENTAS

5.3.2.1 *KAGGLE:*

En términos de herramientas utilizadas, se emplearon plataformas para el entrenamiento, pruebas y validación del algoritmo, siendo una de ellas Kaggle. Esta plataforma está dedicada al aprendizaje automático e inteligencia artificial, proporcionando problemas de ciencia de datos, conjuntos de datos públicos y recursos para que los investigadores colaboren, aprendan y compitan en proyectos de análisis y modelado de datos.

Es un sitio web que alberga una comunidad de profesionales e interesados en los campos de la ciencia de datos y la inteligencia artificial en la cual se pueden encontrar bases de datos y usa un lenguaje de programación de Python para entrenar algoritmos de clasificaciones de imágenes y bases de datos

En Kaggle, se adquirió el algoritmo de clasificación de imágenes y también se obtuvo una de las bases de datos de imágenes de resonancia magnética del cerebro de los pacientes que se utilizaron. El código, contiene diversas funciones para llevar a cabo las tareas de clasificación.

5.4 MATERIALES

Los elementos clave de esta investigación fueron las bases de datos que contenían imágenes de RM del cerebro de pacientes con Tumores cerebrales como Gliomas, Meningiomas y tumor hipofisiario junto con imágenes de pacientes sin ninguna anomalía o patología en el cerebro.

Este estudio tuvo como objetivo la clasificación de imágenes de resonancias magnéticas en cuatro categorías distintas, lo cual presento un desafío de clasificación de cuatro clases. Los datos para las redes neuronales estaban en formato de imagen (.jpg) y se han recopilado de fuentes como Kaggle y un repositorio privado como figshare y Br35h.

Además, hemos incorporado imágenes de la sociedad de neurocirujanos de honduras para enriquecer la variedad. En resumen, se ha utilizado un conjunto de datos compuesto por las fuentes antes mencionadas.

Cabe mencionar que el conjunto de datos no había sido completamente depurado y se identificaron imágenes mal ubicadas, las cuales han sido corregidas, eliminadas o reemplazadas según corresponda. Este enfoque es crucial para garantizar una distribución equitativa de imágenes en cada categoría, evitando cualquier posible sesgo en el entrenamiento de las redes neuronales.

Este conjunto de datos es una combinación de los siguientes tres subconjuntos de datos:

- figshare Cheng, Jun (2017).
- Conjunto de datos SARTAJ(Sartaj)
Sartaj, el principal autor de este trabajo comenta que las imágenes las tomaron de otro conjunto de datos cuyo autor es Navoneel Chakrabarty.
- Conjunto de datos Br35H(Ahmed)


Este conjunto de datos contiene 7827 imágenes de resonancias magnéticas del cerebro humano, las cuales se clasifican en 4 categorías: glioma, meningioma, sin tumor e hipófisis.

Las imágenes de la clase "sin tumor" se tomaron del conjunto de datos Br35H.

Se identifico que el conjunto de datos SARTAJ presenta un problema en el que las imágenes de la clase "glioma" no están categorizadas correctamente.

Debido a esto, se eliminó las imágenes en esta carpeta y en su lugar se utilizó las imágenes del sitio de figshare.


Ilustración 8 Imágenes de la base de datos



Fuente:(Autoría Propia)

Se distribuyen de la siguiente manera 70% para entrenamiento, 20% para validación y 10% para pruebas.

Ilustración 9 Imágenes divididas por clase



Fuente:(Autoría Propia)

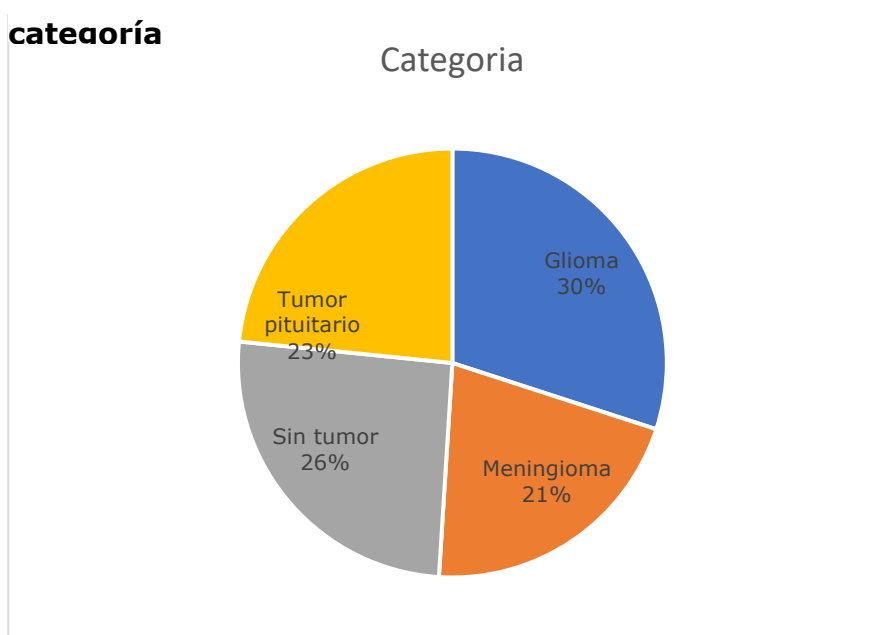
En total la clasificación sería de 5479 imágenes para entrenamiento, 1565 para validación y 783 para pruebas, divididas de la siguiente manera.

Tabla 2: Distribución de Imágenes

Categoría	Porcentaje	Cant. de img	Entrenamiento	Validación	Pruebas
Glioma	30 %	2151	1646	470	235
Meningioma	21 %	1645	1152	329	164
Sin tumor	25.6%	2000	1400	400	200
Tumor pituitario	23.40%	1831	1282	366	183

Fuente:(Autoría Propia)

Ilustración 10 **Imágenes divididas por categoría**



Fuente:(Autoría Propia)

5.5 METODOLOGÍA DE ESTUDIO

5.5.1 ENFOQUE

El enfoque metodológico adoptado en esta investigación se basó en una metodología incremental o iterativa, una práctica fundamental en el desarrollo de proyectos relacionados con el manejo de información. La metodología incremental o iterativa implica iniciar con un esquema inicial y, a medida que avanza el

proceso, se van desarrollando incrementos cada vez más complejos para presentar versiones más sofisticadas del sistema.

Esta metodología se compone de varias etapas, conocidas como incrementos, lo que permite que el proceso de trabajo sea sistemático y ordenado. Al seguir un proceso organizado, se logra la entrega de componentes de trabajo distintos en cada incremento, facilitando el progreso estructurado del proyecto. La ventaja de esta metodología es que le permite al autor tener una retroalimentación del sistema a medida que varía los parámetros.

5.5.2 METODOLOGÍA DE VALIDACIÓN

La metodología de validación permite reconocer las bases científicas que soportan a la investigación, para este estudio se contempló la creación de un conjunto de datos de validación y el uso de herramientas gráficas como la matriz de confusión.

5.5.3 CREACIÓN DE CONJUNTO DE DATOS DE PRUEBA Y VALIDACIÓN

Para garantizar la validez del estudio, se estableció la creación de conjuntos de prueba a partir de las imágenes tomadas de las diferentes bases de datos utilizadas en varias etapas de la investigación. Este conjunto se derivó de la división del conjunto de entrenamiento, donde se asignó un conjunto específico de imágenes para validar el rendimiento del algoritmo.

Esta metodología permitió ajustar los parámetros para los entrenamientos del algoritmo, asegurando que los modelos no solo memorizaran los datos de entrenamiento, sino que también generalizaran correctamente con datos nuevos. Durante los incrementos destinados al entrenamiento del algoritmo, los modelos se expusieron repetidamente al conjunto de datos de entrenamiento, y se ajustaron parámetros como las épocas y el tamaño del lote para mejorar el rendimiento del algoritmo. Dado que el objetivo final del modelo era clasificar datos nuevos, se consideró fundamental implementar un conjunto de datos de validación para los modelos que demostraron un mejor rendimiento durante las pruebas en los diferentes incrementos.


Por lo tanto, se propuso la creación de un conjunto de datos de validación a partir de imágenes recopiladas en colaboración con Instituto Hondureño de seguridad social, así como con la Sociedad Hondureña de Neurocirujanos. La

evaluación de la eficacia del algoritmo se llevó a cabo mediante el rendimiento obtenido en la clasificación realizada en el conjunto de datos de validación. Los resultados de la validación desempeñaron un papel fundamental en el estudio, ya que permitieron realizar predicciones precisas una vez que los modelos seleccionados fueron entrenados. Las predicciones en el ámbito del aprendizaje profundo se refieren a la salida o resultado que un algoritmo genera en función de los datos de entrada.

5.5.4 MATRIZ DE CONFUSIÓN

Las matrices de confusión son herramientas que permiten identificar la cantidad de aciertos y errores, clasificados por clase, generados por un modelo inteligente al realizar predicciones o evaluaciones en imágenes de un conjunto de datos, en este caso, el conjunto de pruebas. Estas matrices son útiles para determinar qué clases presentan mayores desafíos en términos de predicción por parte de los modelos, es decir, cuáles son las clases más complicadas de predecir. En estas matrices, los ejes X e Y representan las clases del conjunto de datos y están debidamente etiquetados.

Ilustración 11 Ejemplo Matriz de confusión incorrecta



Fuente: (Autoría Propia usando Kaggle)

La interpretación de estas matrices implica considerar el eje X como la clase bajo análisis y el eje Y como la predicción hecha por el modelo. Cada cuadro en la matriz indica cuántas imágenes de esa clase, según el eje X, fueron clasificadas por el modelo como la clase indicada en el eje Y. Cuando las etiquetas en ambos ejes coinciden, se considera un acierto. En caso contrario, se trata de un error. La expectativa ideal es que la matriz muestre una diagonal descendente, desde el

punto (0, 0) hasta el punto (N-1, N-1), donde N es el número de clases, lo que indicaría un rendimiento perfecto. No obstante, debido a las características propias del proceso de aprendizaje de los modelos, esta diagonal puede no ser perfecta.

5.5.5 ANÁLISIS Y CÁLCULOS NUMÉRICOS

Al diseñar sistemas automatizados, la evaluación del rendimiento del modelo es esencial, ya que el propósito principal de dicho modelo es prever de manera confiable datos no anticipados; por lo tanto, analizar el conjunto de prueba de entrenamiento y validación revela la capacidad de generalización del marco de trabajo. y son cruciales para evaluar su eficacia en situaciones del mundo real.

En la primera etapa, se enfocaron en probar y ajustar el rendimiento del modelo VGG16, InceptionV3, Resnet50 y EfficientNetBo. Posteriormente, La segunda etapa implicó pruebas y ajustes en el modelo ResNet50. En la última etapa, se estableció una base de datos de imágenes médicas de pacientes hondureños, en la tercera etapa se realiza la inferencia con la nueva base de datos y de predicciones utilizando los modelos que mostraron un mejor rendimiento.

5.5.6 CRONOGRAMA DE ACTIVIDADES

Fase 1: Recopilación de la base de datos original (1 semana)

Fase 2: Modificación de parámetros del modelo y pruebas (2 semanas)

Fase 3: Obtención de imágenes de MRI de pacientes hondureños (2 semanas)

Fase 4: Creación de una base de datos local (1 semana)


Fase 5: Entrenamiento del algoritmo de clasificación (2 semanas)

Fase 6: Evaluación de la precisión del algoritmo (1 semana)

Fase 7: Análisis e interpretación de los resultados (2 semanas)

Fase 8: Redacción del informe final de investigación (12 semanas)

Tabla - Diagrama de Gantt del Cronograma de Actividades



5.5.7 MATRIZ METODOLÓGICA

Aquí se presentan algunas secciones cruciales de este estudio, como el título, el problema planteado, las preguntas de investigación y los objetivos del proyecto. Además, se detallan las variables que están sujetas a cambios y las que permanecen constantes, junto con las técnicas y herramientas propuestas para realizar la investigación de manera efectiva.

Título	Problema de Investigación Problema de Investigación	Objetivos	Variables	Metodologías y Herramientas
Algoritmos de Clasificación Gliomas, Meningiomas y Tumores Hipofisarios y de Pacientes Hondureños	En Honduras, en la actualidad, no se dispone de herramientas tecnológicas basadas en inteligencia artificial, como los algoritmos de clasificación, para respaldar el proceso de diagnóstico de patologías como Glioma, Meningioma o tumor hipofisario. Los algoritmos de clasificación se encargan de identificar características de las imágenes bajo estudio y, en función de los resultados obtenidos, clasificarlas en distintas	General Mejorar las métricas de rendimiento de un algoritmo de clasificación de IRM de cerebro	Dependientes <ul style="list-style-type: none"> • Exactitud • Precisión • Sensibilidad • Puntaje F1 	Técnicas <ul style="list-style-type: none"> • VGG13 • ResNet50 • Inception V3

	<p>categorías, lo que permite optimizar la detección de estas deformidades del cerebro. La implementación de un algoritmo implica cumplir diversos parámetros, como la necesidad de lograr una alta precisión en esta aplicación. Además, esta área de investigación ha sido poco explorada, lo que ha impedido disponer de bases de datos propias de imágenes médicas pertenecientes a pacientes hondureños con estas desviaciones, para el desarrollo de fases de validación de un algoritmo de clasificación de imágenes de resonancia magnética.</p>	Específicos	Independientes	Herramientas
--	--	-------------	----------------	--------------

		<p>1. Ajustar los parámetros de los modelos descritos en investigaciones anteriores con el fin de mejorar la precisión del algoritmo.</p> <p>2. Emplear imágenes de resonancia magnética (RM) de pacientes hondureños suministradas por la Sociedad de Neurocirujanos y el IHSS para evaluar la viabilidad del algoritmo en imágenes</p>	<ul style="list-style-type: none"> • Épocas • Modelos preentrenados de aprendizaje profundo • Tamaño del lote 	<ul style="list-style-type: none"> • Kaggle
--	--	--	--	--

		utilizadas en el país. 3. Establecer una base de datos a partir de las imágenes recopiladas.		
--	--	--	--	--

Fuente: Elaboración Propia

5.5.8 OPERACIONALIZACIÓN DE VARIABLES

Se presenta la tabla de las variables investigadas en el estudio, junto con sus métodos de medición y manipulación. El propósito es garantizar que las variables sean cuantificables y obtener datos fiables.

Tabla 4-Operaciones con variables

VARIABLES	DIMENSIONES	DEFINICIÓN OPERACIONAL	TIPO DE VARIABLE	ESCALA DE MEDICIÓN	INSTRUMENTO	INDICADOR DE CALIFICACIÓN
Precisión	Falsos Positivos	Los eventos en los que el modelo clasifica erróneamente ejemplos negativos como positivos	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico
	Verdaderos Positivos	Los eventos en los que el resultado es positivo y el modelo lo clasifica correctamente como positivo	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico
		Los eventos en los que el				

	Falsos Positivos	modelo clasifica erróneamente ejemplos negativos como positivos	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico
Sensibilidad	Verdaderos Positivos	Los eventos en los que el resultado es positivo y el modelo lo clasifica correctamente como positivo	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico
	Precisión	La proporción de elementos que el sistema devuelve y que son exactamente correctos.	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico
Puntaje F1	Sensibilidad	La medición total de todos los objetos que fueron detectados de manera correcta.	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico
	Sumatoria de los Verdaderos Positivos de cada Clase	La suma (+) de todos los verdaderos positivos para todas las clases.	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico

Modelos preentrenados de aprendizaje profundo	Exactitud	Número de Imágenes para Pruebas	Cantidad total de imágenes que se tienen en la fase de validación del algoritmo.	Cuantitativa	Escala de Razón	Matriz de Confusión	Valor Numérico
		Tamaño de Entrada	Tamaño de las imágenes de entrada para que el modelo pueda procesarlos correctamente.	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Valor Numérico
		Tamaño de Salida	Tamaño de las imágenes de salida para que el modelo pueda procesarlos correctamente.	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Valor Numérico
		Pesos	Son factores que un modelo usa para aprender y representar las relaciones entre las variables de entrada y las salidas deseadas durante la fase de entrenamiento.	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Valor Numérico
		Pooling	Proceso usado para reducir el tamaño de las representaciones	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Valor Numérico

		generadas por las capas convolucionales.				
Épocas	Complejidad del modelo	Es la arquitectura de cada uno de los modelos de aprendizaje profundo.	Cualitativa	Nominal	Ficha de recolección de datos	Alta Mediana Baja
	Número de imágenes para entrenamiento	Cantidad total de imágenes para entrenamiento del algoritmo.	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Valor Numérico
	Recursos Computacionales	Hardware de la computadora.	Cualitativa	Nominal	Ficha de recolección de datos	Alta Mediana Baja
	Número de imágenes para entrenamiento	Cantidad total de imágenes para entrenamiento del algoritmo.	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Valor Numérico
	Complejidad del modelo	Es la arquitectura de cada uno de los modelos de aprendizaje profundo.	Cualitativa	Nominal	Ficha de recolección de datos	Alta Mediana Baja
	Recursos Computacionales	Hardware de la computadora.	Cualitativa	Nominal	Ficha de recolección de datos	Alta Mediana

Tamaño de Lote	Naturaleza de los Datos	Características de las imágenes.	Cualitativa	Nominal	Ficha de recolección de datos	Baja
						Alta
						Mediana
Tiempo de entrenamiento	Número total de imágenes para entrenamiento	Cantidad total de imágenes para entrenamiento del algoritmo.	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Baja
	Recursos Computacionales	Hardware de la computadora.	Cualitativa	Nominal	Ficha de recolección de datos	Alta
						Mediana
	Hiperparámetros	Son las épocas y el tamaño de lote.	Cuantitativa	Escala de Razón	Ficha de recolección de datos	Baja
	Complejidad del modelo	Es la arquitectura de cada uno de los modelos de aprendizaje profundo.	Cualitativa	Nominal	Ficha de recolección de datos	Alta
						Mediana
						Baja

Fuente: Elaboración Propia

VI. RESULTADOS Y ANÁLISIS

En este capítulo se exponen los resultados de los modelos en cada una de las pruebas y ajustes a los que fue sujeto, los resultados se evalúan de acuerdo a los resultados de cada parámetro exactitud, precisión, sensibilidad y puntaje F1 en cada prueba.

6.1 INCREMENTO 1: PRUEBAS Y AJUSTE FINO PARA MODELOS PREENTRENADOS: EFFICIENTNETBO, VGG16, RESNET50 E INCEPTIONV3

En el primer incremento se procedió a utilizar la base datos previamente clasificada para el desarrollo de pruebas de dos modelos preentrenados de aprendizaje profundo EfficientNetBO, VGG16, Resnet50 e InceptionV3. En el transcurso de las pruebas se buscó alcanzar un ajuste fino para cada modelo, esto se llevó a cabo entrenando al algoritmo para aprender características específicas como son la forma, textura, límites y colores de los tumores por medio del ajuste de las variables independientes expuestas en este documento, en este incremento se estandarizo el color y tamaño de las imágenes [224,224,3], que son los valores de entrada para estos modelos.

Los parámetros utilizados para la realización del entrenamiento fueron épocas de 12,30,50 y lotes de 32,64 y 96 además de un radio de aprendizaje de 0.001. Al variar estos parámetros de manera incremental se espera analizar gradualmente el rendimiento en la clasificación de IRM en las cuatro diferentes categorías de la base de datos.

Los resultados del primer incremento fueron anotados en dos tablas con la descripción de las configuraciones establecidas en el algoritmo de entrenamiento para la clasificación de imágenes. Se registro la información del tiempo de entrenamiento en segundos y a partir de la matriz de confusión obtenida se calculan las métricas de desempeño como exactitud, Precisión, Sensibilidad y Puntaje F1, para cada clase del conjunto de pruebas.

También se recopiló el promedio de los porcentajes obtenidos para cada métrica de las 4 clases. De igual forma se calculó el promedio ponderado el cual es muy importante para el análisis debido a que este es obtenido a partir del

número de imágenes para cada clase, tomando en consideración que la base de datos con la que se trabajó no se encuentra balanceada.

Tabla -Comparativa de modelos EfficientNetB0 y VGG16 con un entrenamiento de 12 épocas.

No. de Época	No. Tam año de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)	
Época 12	EfficientNetB0	Meningioma	219	100	99	99	
		Cerebro normal		98	100	99	
		Meningioma		99	92	96	
		T Pituitario		94	100	97	
		Exactitud				98	
		Promedio macro		98	98	98	
		Promedio Ponderado		98	98	98	
	VGG16	Meningioma	217	92	100	96	
		Cerebro normal		99	100	99	
		Meningioma		100	86	92	
		T.Pituitario		99	100	99	
		Exactitud				97	
		Promedio macro		97	96	97	
		Promedio Ponderado		97	97	97	
		96	Meningioma	211	100	100	100

		Cerebro normal	100	100	100	
		Meningioma	100	100	100	
		T. Pituitario	100	100	100	
		Exactitud			100	
		Promedio macro	100	100	100	
		Promedio Ponderado	100	100	100	
	32	Meningioma	297.88	92	87	89
		Cerebro normal		84	94	89
		Meningioma		75	68	71
		T. Pituitario		91	92	91
		Exactitud				86
		Promedio macro		85	85	85
		Promedio Ponderado		86	86	86
	64	Meningioma	241	94	87	91
		Cerebro normal		86	98	91
		Meningioma		83	70	76
		T. Pituitario		89	98	93
		Exactitud				89
		Promedio macro		88	88	88
		Promedio Ponderado		89	89	88
VGG16	96	Meningioma	267	30	100	46

Cerebro normal	0	0	0
Meningioma	0	0	0
T. Pituitario	0	0	0
Exactitud			30
Promedio macro	0.8	25	12
Promedio Ponderado	0.9	30	14

Fuente: Elaboración Propia

Los resultados denotan que el modelo EfficientnetB0 supera con creces el 85% de exactitud en los primeros entrenamientos por lo cual es apto para desempeñar la tarea de clasificación de imágenes, mientras el contrario el modelo VGG16 en las épocas 32 y 64 apenas pasa el 85% y en la época 96 fracasa obtenido un 30% de exactitud. Finalizado el primer entrenamiento se procede a aumentar el número de época de 12 a 30 para examinar la conducta de los modelos.

1.1 TABLA -COMPARATIVA DE MODELOS EFFICIENTNETB0 Y VGG16 CON UN ENTRENAMIENTO DE 30 ÉPOCAS.

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
Época 30	EfficientNetB0	Glioma	456	98	100	99
		Meningioma		100	99	99
		Cerebro normal		99	98	98
		T Pituitario		100	99	100
		Exactitud				99
		32				

		Promedio macro		99	99	99
		Promedio Ponderado		99	99	99
64		Glioma	461	100	100	100
		Meningioma		100	100	100
		Cerebro normal		100	100	100
		T Pituitario		100	100	100
		Exactitud				100
		Promedio macro		100	100	100
		Promedio Ponderado		100	100	100
		96		Glioma	468	99
Meningioma				100	100	99
Cerebro normal				100	98	99
T Pituitario				100	100	100
Exactitud						100
Promedio macro				100	100	100
Promedio Ponderado				100	100	100
32				Glioma	634	99
		Meningioma		93	99	96
		Cerebro normal		93	91	92
		T Pituitario		98	99	98
		Exactitud				96
VGG16						

	Promedio macro		96	96	96
	Promedio Ponderado		96	96	96
64	Glioma	607.s	99	95	97
	Meningioma		96	99	98
	Cerebro normal		95	96	96
	T Pituitario		99	100	99
	Exactitud				98
	Promedio macro		97	98	98
	Promedio Ponderado		97	98	98
96	Glioma	618	93	93	93
	Meningioma		90	96	93
	Cerebro normal		88	76	82
	T Pituitario		93	98	95
	Exactitud				91
	Promedio macro		91	91	91
	Promedio Ponderado		91	91	91

Fuente: Elaboración Propia

Los resultados recopilados muestran que el modelo efficientNetBo estudiado en este experimento presenta una leve mejoría respecto al primer estudio y mientras que VGG16 mejoro considerablemente superando el umbral del 85% por lo cual también se le considera aptos para la clasificación de tumores cerebrales. Después de completar este experimento continuamos elevando el número de

épocas de 30 a 50 para analizar cómo es la conducta de los modelos durante entrenamientos más extensos.

Tabla -Comparativa de modelos EfficientNetB0 y VGG16 con un entrenamiento de 50 épocas.

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
Época 50	32	Glioma	870	97	100	98
		Meningioma		100	100	100
		Cerebro normal		100	95	97
		T Pituitario		100	100	100
		Exactitud				99
		Promedio macro		99	99	99
		Promedio Ponderado		99	99	99
	64	Glioma	753	100	100	100
		Meningioma		100	99	99
		Cerebro normal		99	100	100
		T Pituitario		100	100	100
		Exactitud				100
		Promedio macro		100	100	100
		Promedio Ponderado		100	100	100
96	Glioma	759.1	100	100	100	

		Meningioma	100	100	100	
		Cerebro normal	100	100	100	
		T Pituitario	100	100	100	
		Exactitud			100	
		Promedio macro	100	100	100	
		Promedio Ponderado	100	100	100	
	32	Meningioma	1039	99	98	99
		Cerebro normal		98	100	99
		Meningioma		99	97	98
		T. Pituitario		99	100	99
		Exactitud				99
		Promedio macro		99	99	99
		Promedio Ponderado		99	99	99
	64	Glioma	1006	97	97	97
		Meningioma		99	99	99
		Cerebro normal		95	94	95
		T Pituitario		99	100	99
		Exactitud				98
		Promedio macro		98	97	97
		Promedio Ponderado		98	98	98
VGG16	96	Glioma	1017	99	92	95

Meningioma	96	99	97
Cerebro normal	88	91	89
T Pituitario	96	99	98
Exactitud			95
Promedio macro	95	95	95
Promedio Ponderado	95	95	95

Fuente: Elaboración Propia

Ahora, se analizan los resultados del último entrenamiento del primer incremento en los entrenamientos con los modelos con 50 épocas. Se observa que el valor de la exactitud en los modelos VGG16 sigue aumentando gradualmente mientras que los modelos EfficientNet al presentar resultados muy buenos desde el primer incremento mejora a un ritmo menor.

En el incremento uno se realizaron un total de 18 pruebas desarrolladas entre los dos modelos y las 9 configuraciones establecidas. El objetivo de este incremento fue evaluar los dos modelos de redes neuronales convulsiónales EfficientNetBO y VGG16 con el desempeño de las variables dependientes para identificar con que parámetros se obtiene la mayor exactitud.

Para finalizar, el modelo Efficientnet obtuvo los mismos resultados desde el primer incremento, pero el modelo VGG16 presentó mejores resultados en la época 50 y tamaño de lote 32.

6.2 PRUEBAS Y AJUSTE FINO PARA MODELOS PRE-ENTRENADOS: INCEPTIONV3 Y RESNET 50

Para la segunda parte del incremento 1 se realizaron pruebas de ajuste fino en los modelos InceptionV3 y Resnet50. El entrenamiento de los modelos se realizó con la misma base de datos y el mismo código. El ajuste fino de este experimento consistió en modificar los parámetros de las variables independientes para lograr la mayor exactitud posible esto se logró modificando el número de épocas de 12,30,50 y el tamaño del lote 32,64,96 con un ritmo de aprendizaje de 0.001.

Siguiendo la línea metodológica del primer incremento, en el incremento dos Los resultados fueron anotados en dos tablas con la descripción de las configuraciones establecidas en el algoritmo de entrenamiento para la clasificación de imágenes. Se registro la información del tiempo de entrenamiento en segundos y a partir de la matriz de confusión obtenida se calculan las métricas de desempeño como exactitud, precisión, Sensibilidad y Puntaje F1, para cada clase del conjunto de pruebas.

También se recopiló el promedio de los porcentajes obtenidos para cada métrica de las 4 clases. De igual forma se calculó el promedio ponderado el cual es muy importante para el análisis debido a que este es obtenido a partir del número de imágenes para cada clase, tomando en consideración que la base de datos con la que se trabajó no se encuentra balanceada.

Para la segunda parte se evaluaron los modelos Resnet50 e InceptionV3. Los resultados obtenidos del primer experimento del segundo incremento se muestran a continuación

Tabla - Comparativa de modelos InceptionV3 y Resnet50 un entrenamiento de 12 épocas.

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
Época 12	InceptionV3	Glioma	220	86	100	92
		Meningioma		98	97	98
		Cerebro normal	32	100	97	93
		T Pituitario		100	91	95
		Exactitud				94

		Promedio macro	96	94	94	
		Promedio Ponderado	95	94	94	
64	64	Glioma	189	99	1	17
		Meningioma		99	87	93
		Cerebro normal		56	76	65
		T Pituitario		50	100	66
		Exactitud				64
		Promedio macro		76	68	60
		Promedio Ponderado		79	64	58
		Glioma	180	99	93	96
		Meningioma		99	99	99
		Cerebro normal		95	94	94
96	96	T Pituitario		92	100	96
		Exactitud				97
		Promedio macro		96	97	96
		Promedio Ponderado		97	97	97
		Glioma	552	99	100	99
		Meningioma		99	100	100
		Cerebro normal		100	99	99

Resnet50

	T Pituitario		100	99	99
	Exactitud				99
	Promedio macro		99	99	99
	Promedio Ponderado		99	99	99
64	Glioma	336	87	87	87
	Meningioma		68	82	74
	Cerebro normal		71	68	69
	T Pituitario		96	79	86
	Exactitud				80
	Promedio macro		81	79	79
	Promedio Ponderado		81	80	80
	Glioma	331	100	98	99
Meningioma		100	100	100	
Cerebro normal		94	100	97	
T Pituitario		100	97	98	
Exactitud				98	
Promedio macro		98	98	98	
Promedio Ponderado		98	98	98	

Fuente: Elaboración Propia

Evaluando los resultados obtenidos de las métricas en el primer experimento se puede concluir que ambos modelos presentan un rendimiento general destacado en la clasificación de IRM de tumores cerebrales en una configuración de 12 épocas y unos lotes de 32,64, y 96. Ambos modelos presentaron una decaída en su rendimiento en el tamaño de lote 64. A continuación se procederá a aumentar las épocas a 30 para evaluar y analizar la conducta del modelo y las métricas con esta nueva configuración.

Tabla -Comparativa de modelos InceptionV3 y Resnet50 un entrenamiento de 30 épocas.

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
Época 30	InceptionV3	Glioma	522	100	100	100
		Meningioma		100	100	100
		Cerebro normal		100	100	100
		T Pituitario		100	100	100
		Exactitud				100
		Promedio macro		100	100	100
		Promedio Ponderado		100	100	100
		32	Glioma	512.63	100	100
	64	Meningioma		100	100	100
		Cerebro normal		100	100	100
		T Pituitario		100	100	100
		Exactitud				100

		Promedio macro		100	100	100
		Promedio Ponderado		100	100	100
96		Glioma	416	100	100	100
		Meningioma		100	100	100
		Cerebro normal		100	100	100
		T Pituitario		100	100	100
		Exactitud				100
		Promedio macro		100	100	100
		Promedio Ponderado		100	100	100
32		Glioma	583	100	68	81
		Meningioma		65	100	79
		Cerebro normal		90	95	93
		T Pituitario		100	77	97
		Exactitud				84
		Promedio macro		89	85	85
		Promedio Ponderado		89	84	84
64		Glioma	528	100	100	100
		Meningioma		100	100	100
		Cerebro normal		100	100	100
		T Pituitario		100	100	100
		Exactitud				100
Resnet50						

		Promedio macro	100	100	100	
		Promedio Ponderado	100	100	100	
94		Glioma	552	100	100	100
		Meningioma		100	100	100
		Cerebro normal		100	100	100
		T Pituitario		100	100	100
		Exactitud				100
		Promedio macro		100	100	100
		Promedio Ponderado		100	100	100

Fuente: Elaboración Propia

Se puede observar El modelo InceptionV3 modelos realiza las clasificaciones de manera sobresaliente mientras Resnet50 presenta una decaída gradual en su rendimiento. Para terminar el incremento dos se procedió a aumentar la época de 30 a 50. Los resultados de este incremento se presentan a continuación

Tabla -Comparativa de modelos InceptionV3 y Resnet50 un entrenamiento de 50 épocas.

No. de Época	No. Tamaño de Lote	Reporte	Tiempo (s)	Precisión (%)	Sensibilidad (%)	Puntaje F1 (%)
Época 50	InceptionV3 32	Glioma	630	100	84	91
		Meningioma		98	100	99
		Cerebro normal		82	100	90

		T Pituitario	99	98	99
		Exactitud			95
		Promedio macro	95	95	95
		Promedio Ponderado	96	95	95
	64	Glioma	645	100	100
		Meningioma		100	100
		Cerebro normal		100	100
		T Pituitario		100	100
		Exactitud			100
		Promedio macro	100	100	100
		Promedio Ponderado	100	100	100
	96	Glioma	639	100	100
		Meningioma		100	100
		Cerebro normal		100	100
		T Pituitario		100	100
		Exactitud			100
		Promedio macro	100	100	100
		Promedio Ponderado	100	100	100
Resnet50	32	Glioma	942	100	100
		Meningioma		100	100

	Cerebro normal		100	100	100
	T Pituitario		100	100	100
	Exactitud				100
	Promedio macro		100	100	100
	Promedio Ponderado		100	100	100
64	Glioma	852	100	100	100
	Meningioma		100	100	100
	Cerebro normal		100	100	100
	T Pituitario		100	100	100
	Exactitud				100
	Promedio macro		100	100	100
	Promedio Ponderado		100	100	100
96	Glioma	811	100	100	100
	Meningioma		100	100	100
	Cerebro normal		100	100	100
	T Pituitario		100	100	100
	Exactitud				100
	Promedio macro		100	100	100
	Promedio Ponderado		100	100	100

Fuente: Elaboración Propia

Para finalizar, se presentan los desenlaces de las evaluaciones realizadas en los procesos de entrenamiento de los modelos con 50 épocas de entrenamiento. Es evidente que ambos modelos son aptos para realizar las tareas de clasificación de IRM de tumores cerebrales como indican los valores de la exactitud que se encuentran remarcados en la tabla.

Esta segunda etapa está formada por un conjunto de 18 pruebas realizadas a dos modelos de aprendizaje profundo diferentes a los del primer incremento y 9 configuraciones específicas. El objetivo de esta fase fue analizar las CNN Resnet50 e InceptionV3 en términos de rendimiento y su relación con la configuración de parámetros para lograr la mayor exactitud.

En Resumen, se observó que para la red InceptionV3, la exactitud y precisión más altas fueron con las configuración de 30 épocas y un tamaño de lote 32 .En el caso de Resnet50 se alcanzaron con 30 épocas y un tamaño de lote de 64

6.3 INCREMENTO 2: CREACIÓN DE NUEVA BASE DE DATOS

Se reconoció la importancia de crear una base de datos de IRM cerebrales de pacientes hondureños, incluyendo las cuatro clases definidas previamente: glioma, meningioma, tumor pituitario e imágenes de cerebros sanos. Esto se logró en colaboración con el servicio de radiología de dos hospitales en la zona norte del país: La Lima Medicas Center y Hospital del Valle además del IHSS, recopilando imágenes desde septiembre hasta diciembre de 2023. En La Lima Medical Center, se recolectaron imágenes de resonancia magnética cerebral en los planos axial, coronal y sagital, con un total de 4 pacientes y 478 imágenes recolectadas entre pacientes de ambos sexos. Además, se obtuvieron imágenes de Tomografía en pacientes con ACV y TEC en Clínicas Del Valle. En el IHSS, se adquirieron 816 imágenes de 9 pacientes en los mismos planos y distribuidas entre ambos sexos, utilizadas 90 imágenes para la inferencia de las clases meningioma, mioma y T. Hipofisiario. Para las imágenes de la clase "No tumor", se recolectaron 9052 imágenes de 6 pacientes proporcionadas por la empresa INEQ MEDICA, utilizadas como ejemplos en la capacitación de técnicos en radiología en la adquisición de IRM. El propósito principal de este nuevo conjunto de datos fue demostrar la aplicabilidad de los algoritmos de clasificación de imágenes que mostraron los

mejores resultados en las métricas obtenidas en la primera etapa de la investigación.

6.4 INCREMENTO 3: EVALUACIÓN DE RESULTADOS DE RED

La evaluación de la implementación del algoritmo de clasificación de IRM cerebrales se realizó mediante predicciones con el modelo mejor calificado en las pruebas de desempeño, entrenamiento y validación. Esto se logró con la utilización de la base de datos recolectada para la validación con imágenes locales.

Es importante recalcar que con el incremento se recolectaron 800 imágenes, sin embargo, para propósitos de esta investigación no todas las imágenes recolectadas fueron de utilidad esto se debe a que algunos estudios eran de TC, pacientes con otras patologías o comienzos de los estudios que no aportaban información diagnóstica al algoritmo.

Tomando esto en consideración se seleccionaron e identificaron un total de 120 imágenes para validar el modelo preentrenado EfficientNetBo.

El conjunto de validación de IRM de pacientes hondureños se compone de 30 imágenes de Gliomas, 30 de meningiomas, 30 de tumores hipofisarios y 30 imágenes sin tumor.

6.5 DISCUSIÓN DE RESULTADOS

En esta sección del capítulo V, se analizarán los datos obtenidos por cada modelo en los diferentes entrenamientos y sus etapas. De tal manera que sea fácil comprender los resultados obtenidos. Esto por medio de una amplia interpretación de los datos y una comparación de estos con las metodologías expuestas en el Estado del Arte.

6.5.1 INTERPRETACIÓN DE DATOS Y OBSERVACIONES CLAVE DEL INCREMENTO 1

Medir el desempeño logrado por los modelos de aprendizaje profundo en la tarea de clasificación de imágenes de tumores cerebrales sirve para tener valores matemáticos acerca del rendimiento de los modelos. Las observaciones realizadas en esta etapa nos ayudan a medir la efectividad de los algoritmos propuestos por

medio de las pruebas desarrolladas. La siguiente tabla muestra la relación obtenida entre las variables dependientes e independientes en relación con la selección de las configuraciones que alcanzaron el mejor desempeño por cada modelo comprobado en esta etapa.

Tabla - Configuración y métricas de desempeño alcanzadas en los modelos EfficientNetBO y VGG16

Modelo	Época	Tamaño de lote	Tiempo (s)	Exactitud (%)	Precisión P. (%)	Sensibilidad P. (%)	Puntaje F1 P. (%)	
EfficientNetBO	30	64	456	100	100	100	100	
VGG16	50	32	1039	99	99	99	99	
Resnet50	50	32	942	100	100	100	100	
InceptionV3	30	32	522	100	100	100	100	

Fuente: Elaboración Propia


Se observa que para el primer incremento hay un triple empate con un 100% en todas las métricas de los modelos EfficientNetBO, Resnet50 e InceptionV3. mientras el modelo VGG16 les sigue de cerca con una exactitud de 99%, una precisión ponderada de 99%, sensibilidad ponderada de 99% y puntaje F1 ponderado de 99%.

La métrica clave en este análisis es la exactitud, que se deriva de la proporción entre el número total de elementos correctamente clasificados dentro de las cuatro clases específicas y el número total de elementos designados en el conjunto de validación, que comprende un total de 1565 imágenes distribuidas entre estas cuatro clases. El proceso de entrenamiento completo tomó 456,942 y 522 segundos respectivamente, un tiempo relativamente corto considerando la cantidad de imágenes utilizadas en el entrenamiento del modelo y el tiempo que le tomo al modelo VGG16.

Las métricas se derivaron de la herramienta mencionada anteriormente, conocida como matriz de confusión. En la siguiente Ilustración se presenta la matriz de confusión correspondiente a la prueba ejecutada con el modelo EfficientNetBO, utilizando un total de 30 épocas y un tamaño de lote de 64, que

fue donde se observó el mejor desempeño durante el Incremento 1 en menor tiempo. A continuación, se ofrece un ejemplo que detalla el proceso para calcular los indicadores de rendimiento, basándose en la prueba realizada con EfficientNetB0, donde se alcanzó el mejor rendimiento

Ilustración 11: Matriz de confusión de EfficientNetB0 con un entrenamiento de 30 épocas y un tamaño de lote de 64.



Fuente: Elaboración Propia

Donde la clase 0 corresponde a Gliomas,1 a Sin tumor,2 a Meningiomas y 3 a T.hipofisarios.Se puede observar, que en la clasificación realizada en el conjunto de pruebas para esta configuración de parámetros en el modelo EfficientNetB0 presento diversos errores donde se clasificaron varias imágenes de manera incorrecta, siendo la mayoría clasificando las imágenes de Hipofisarios como meningiomas. Los datos necesarios para el cálculo de las métricas de desempeño mostradas se describen en la tabla

Tabla 5- Matriz de Observación de EfficientNetB0 con un entrenamiento de 30 épocas y un tamaño de lote de 64.

Clases	Mediciones			
	TP	TN	FP	FN
Glioma	465	1063	9	5
No Tumor	400	1128	8	0
Meningioma	322	1206	20	7
T. Hipofisiario	341	1187	0	25

A partir de la fórmula 1 presentada en el capítulo previo, se obtuvo la exactitud general de clasificación:

$$Exactitud\ General = \frac{465 + 400 + 322 + 341}{1565} \times 100\% = 97.63\%$$

La fórmula 2 se utilizó para calcular la precisión de cada clase de la siguiente manera:

$$Precisión\ Clase\ Glioma = \frac{465}{465 + 9} \times 100\% = 98.1\%$$

$$Precisión\ Clase\ No\ tumor = \frac{400}{400 + 8} \times 100\% = 98.03\%$$

$$Precisión\ Clase\ Meningioma = \frac{322}{322 + 20} \times 100\% = 94.15\%$$

$$Precisión\ Clase\ T.\ Hipofisiario = \frac{341}{341 + 0} \times 100\% = 100\%$$

Estos resultados se emplearon para calcular el promedio de la precisión general realizada por el clasificador y el promedio ponderado, considerando el número de imágenes del conjunto de pruebas para cada clase.

$$\text{Promedio de Precisión} = \frac{0.981 + 0.9803 + 0.9415 + 1}{4} \times 100\% = 97.57\%$$

Promedio Ponderado de Precisión

$$= \frac{0.981 \times (465) + 0.9803 \times (400) + 0.9415 \times (322) + 1 \times (341)}{1565} \times 100\% = 95.36\%$$

La fórmula 3 se utilizó para calcular la sensibilidad individual en cada clase:

$$\text{Sensibilidad Clase Glioma} = \frac{465}{465 + 5} \times 100\% = 98.83\%$$

$$\text{Sensibilidad Clase No tumor} = \frac{400}{400 + 0} \times 100\% = 100\%$$

$$\text{Sensibilidad Meningioma} = \frac{322}{322 + 7} \times 100\% = 97.87\%$$

$$\text{Sensibilidad Clase T. Hipofisiario} = \frac{341}{341 + 25} \times 100\% = 93.24\%$$

Estos resultados se utilizaron para obtener el promedio de la sensibilidad general en la tarea de clasificación y el promedio ponderado considerando el número de imágenes del conjunto de pruebas para cada clase.

$$\text{Promedio de Sensibilidad} = \frac{0.9883 + 1 + 0.9787 + 0.9324}{4} \times 100\% = 97.48\%$$

Promedio Ponderado de Sensibilidad

$$= \frac{0.9883 \times (465) + 1 \times (400) + 0.9787 \times (322) + 0.9324(341)}{1565} \times 100\% = 95.37\%$$

Finalmente, utilizando la fórmula 4, se calculó el puntaje F1 para cada clase:

$$\text{Puntaje F1 Clase Glioma} = 2 \times \frac{0.9883 \times 0.981}{0.9883 + 0.981} \times 100\% = 98.46\%$$

$$\text{Puntaje F1 Clase No tumor} = 2 \times \frac{1 \times 0.9803}{1 + 0.9803} \times 100\% = 99\%$$

$$\text{Puntaje F1 Clase Meningioma} = 2 \times \frac{0.9787 \times 0.9415}{0.9787 + 0.9415} \times 100\% = 95.97\%$$

$$\text{Puntaje F1 Clase T.Hipofisiario} = 2 \times \frac{0.9324 \times 1}{0.9324 + 1} \times 100\% = 96.5\%$$

A partir de estos resultados, se calculó el promedio del puntaje F1 general obtenido en la clasificación con el conjunto de pruebas y el promedio ponderado del puntaje F1.

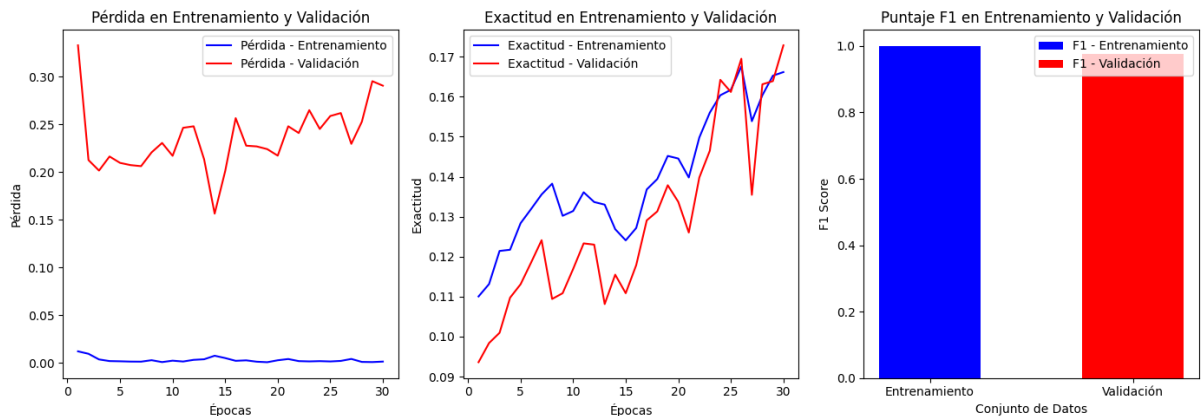
$$\text{Promedio de Puntaje F1} = \frac{0.9846 + 0.99 + 0.9597 + 0.965}{4} \times 100\% = 97.48\%$$

Promedio Ponderado de Puntaje F1

$$= \frac{0.9846 \times (465) + 0.99 \times (400) + 0.9597 \times (322) + 0.965(341)}{1565} \times 100\% = 97.63\%$$

Además, se registraron las curvas de aprendizaje, que contienen información sobre la pérdida durante el entrenamiento y la validación, así como las curvas de exactitud durante el entrenamiento y la validación (Ilustración 12).


Ilustración 12 Curvas de aprendizaje de EfficientNetB0 con un entrenamiento de 30 épocas y un tamaño de lote de 64.



Fuente: Elaboración Propia

Se puede observar, que en la clasificación realizada en el conjunto de pruebas para esta configuración de parámetros en el modelo EfficientNetB0 presento diversos errores donde se clasificaron varias imágenes de manera incorrecta y que los resultados de validación difieren el alrededor de un 2% de los del entrenamiento.

Ilustración 11: Matriz de confusión de VGG16 con un entrenamiento de 50 épocas y un tamaño de lote de 32.



Fuente: Elaboración Propia

Donde la clase 0 corresponde a Gliomas, 1 a Sin tumor, 2 a Meningiomas y 3 a T.hipofisarios. Se puede observar, que en la clasificación realizada en el conjunto de pruebas para esta configuración de parámetros en el modelo VGG16 presento diversos errores donde se clasificaron varias imágenes de manera incorrecta, siendo la mayoría clasificando las imágenes de Gliomas como meningiomas. Los datos necesarios para el cálculo de las métricas de desempeño mostradas se describen en la tabla

Tabla 6- Matriz de Observación de EfficientNetB0 con un entrenamiento de 30 épocas y un tamaño de lote de 64.

Clases	Mediciones			
	TP	TN	FP	FN
Glioma	393	974	47	77
No Tumor	399	969	34	1
Meningioma	253	1114	89	76
T. Hipofisario	322	1045	28	43

A partir de la fórmula 1 presentada en el capítulo previo, se obtuvo la exactitud general de clasificación:

$$Exactitud\ General = \frac{393 + 399 + 253 + 322}{1565} \times 100\% = 87.34\%$$

La fórmula 2 se utilizó para calcular la precisión de cada clase de la siguiente manera:

$$\text{Precisión Clase Glioma} = \frac{393}{393 + 77} \times 100\% = 83.61\%$$

$$\text{Precisión Clase No tumor} = \frac{399}{399 + 1} \times 100\% = 99.75\%$$

$$\text{Precisión Clase Meningioma} = \frac{253}{253 + 76} \times 100\% = 76.89\%$$

$$\text{Precisión Clase T. Hipofisiario} = \frac{322}{322 + 47} \times 100\% = 87.26\%$$

Estos resultados se emplearon para calcular el promedio de la precisión general realizada por el clasificador y el promedio ponderado, considerando el número de imágenes del conjunto de pruebas para cada clase.

$$\text{Promedio de Precisión} = \frac{0.8361 + 0.9975 + 0.7689 + 0.8726}{4} \times 100\% = 86.88\%$$

Promedio Ponderado de Precisión

$$\begin{aligned} &= \frac{0.8361 \times (393) + 0.9975 \times (399) + 0.7689 \times (253) + 0.8726 \times (322)}{1565} \times 100\% \\ &= 76.81\% \end{aligned}$$

La fórmula 3 se utilizó para calcular la sensibilidad individual en cada clase:

$$\text{Sensibilidad Clase Glioma} = \frac{393}{393 + 47} \times 100\% = 89.31\%$$

$$\text{Sensibilidad Clase No tumor} = \frac{399}{399 + 34} \times 100\% = 92.15\%$$

$$\text{Sensibilidad Meningioma} = \frac{253}{253 + 89} \times 100\% = 73.97\%$$

$$\text{Sensibilidad Clase T. Hipofisiario} = \frac{322}{322 + 28} \times 100\% = 92\%$$

Estos resultados se utilizaron para obtener el promedio de la sensibilidad general en la tarea de clasificación y el promedio ponderado considerando el número de imágenes del conjunto de pruebas para cada clase.

$$\text{Promedio de Sensibilidad} = \frac{0.8931 + 0.9215 + 0.7397 + 0.92}{4} \times 100\% = 86.85\%$$

Promedio Ponderado de Sensibilidad

$$= \frac{0.8931 \times (393) + 0.9215 \times (399) + 0.7397 \times (253) + 0.92(322)}{1565} \times 100\% = 76.80\%$$

Finalmente, utilizando la fórmula 4, se calculó el puntaje F1 para cada clase:

$$\text{Puntaje F1 Clase Glioma} = 2 \times \frac{0.8931 \times 0.8361}{0.8931 + 0.8361} \times 100\% = 86.36\%$$

$$\text{Puntaje F1 Clase No tumor} = 2 \times \frac{0.9215 \times 0.9975}{0.9215 + 0.9975} \times 100\% = 95.79\%$$

$$\text{Puntaje F1 Clase Meningioma} = 2 \times \frac{0.7397 \times 0.7689}{0.7397 + 0.7689} \times 100\% = 75.40\%$$

$$\text{Puntaje F1 Clase T. Hipofisiario} = 2 \times \frac{0.92 \times 0.8726}{0.92 + 0.8726} \times 100\% = 89.67\%$$

A partir de estos resultados, se calculó el promedio del puntaje F1 general obtenido en la clasificación con el conjunto de pruebas y el promedio ponderado del puntaje F1.


$$\text{Promedio de Puntaje F1} = \frac{0.8636 + 0.9579 + 0.7540 + 0.8967}{4} \times 100\% = 86.80\%$$

Promedio Ponderado de Puntaje F1

$$= \frac{0.8636(393) + 0.9579(399) + 0.7540(253) + 0.8967(322)}{1565} \times 100\% = 76.54\%$$

Además, se registraron las curvas de aprendizaje, que contienen información sobre la pérdida durante el entrenamiento y la validación, así como las curvas de exactitud durante el entrenamiento y la validación (Ilustración 12).


Ilustración 12 Curvas de aprendizaje de VGG16 con un entrenamiento de 30 épocas y un tamaño de lote de 32.



Fuente: Elaboración Propia

Se puede observar, que en la clasificación realizada en el conjunto de pruebas para esta configuración de parámetros en el modelo VGG16 presento muchos errores donde se clasificaron varias imágenes de manera incorrecta y que los resultados de validación difieren el alrededor de un 10% de los del entrenamiento, siendo la clase meningioma la que presento menor calificación en las evaluaciones

Ilustración 11: Matriz de confusión de ResNet50 con un entrenamiento de 50 épocas y un tamaño de lote de 32.



Fuente: Elaboración Propia

Donde la clase 0 corresponde a Gliomas, 1 a Sin tumor, 2 a Meningiomas y 3 a T. hipofisarios. Se puede observar, que en la clasificación realizada en el conjunto de pruebas para esta configuración de parámetros en el modelo ResNet50 presento diversos errores donde se clasificaron varias imágenes de manera incorrecta, siendo la mayoría clasificando las imágenes de Tumores Hipofisarios como meningiomas. Los datos necesarios para el cálculo de las métricas de desempeño mostradas se describen en la tabla

Tabla 7- Matriz de Observación de Resnet50 con un entrenamiento de 30 épocas y un tamaño de lote de 64.

Clases	Mediciones			
	TP	TN	FP	FN
Glioma	454	1044	11	16
No Tumor	400	1098	21	0
Meningioma	317	1181	33	12
T. Hipofisario	327	1162	2	39

A partir de la fórmula 1 presentada en el capítulo previo, se obtuvo la exactitud general de clasificación:

$$Exactitud\ General = \frac{454 + 400 + 317 + 327}{1565} \times 100\% = 95.7\%$$

La fórmula 2 se utilizó para calcular la precisión de cada clase de la siguiente manera:

$$Precisión\ Clase\ Glioma = \frac{454}{454 + 11} \times 100\% = 97.6\%$$

$$Precisión\ Clase\ No\ tumor = \frac{400}{400 + 21} \times 100\% = 99.75\%$$

$$Precisión\ Clase\ Meningioma = \frac{317}{317 + 33} \times 100\% = 95\%$$

$$\text{Precisión Clase T. Hipofisario} = \frac{327}{327 + 2} \times 100\% = 99.4\%$$

Estos resultados se emplearon para calcular el promedio de la precisión general realizada por el clasificador y el promedio ponderado, considerando el número de imágenes del conjunto de pruebas para cada clase.

$$\text{Promedio de Precisión} = \frac{0.976 + 0.9975 + 0.95 + 0.994}{4} \times 100\% = 98\%$$

$$\begin{aligned} \text{Promedio Ponderado de Precisión} &= \frac{0.976(454) + 0.9975(400) + 0.95(317) + 0.994(327)}{1565} \times 100\% \\ &= 93.82\% \end{aligned}$$

La fórmula 3 se utilizó para calcular la sensibilidad individual en cada clase:

$$\text{Sensibilidad Clase Glioma} = \frac{454}{454 + 16} \times 100\% = 96.6\%$$

$$\text{Sensibilidad Clase No tumor} = \frac{400}{400 + 0} \times 100\% = 100\%$$

$$\text{Sensibilidad Meningioma} = \frac{317}{317 + 12} \times 100\% = 96.4\%$$

$$\text{Sensibilidad Clase T. Hipofisario} = \frac{327}{327 + 39} \times 100\% = 89\%$$

Estos resultados se utilizaron para obtener el promedio de la sensibilidad general en la tarea de clasificación y el promedio ponderado considerando el número de imágenes del conjunto de pruebas para cada clase.

$$\text{Promedio de Sensibilidad} = \frac{0.966 + 1 + 0.964 + 0.89}{4} \times 100\% = 95.5\%$$

$$\begin{aligned} \text{Promedio Ponderado de Sensibilidad} &= \frac{0.966(454) + 1(400) + 0.964(317) + 0.89(327)}{1565} \times 100\% \\ &= 91.70\% \end{aligned}$$

Finalmente, utilizando la fórmula 4, se calculó el puntaje F1 para cada clase:

$$\text{Puntaje F1 Clase Glioma} = 2 \times \frac{0.966 \times 0.8361}{0.966 + 0.8361} \times 100\% = 89.6\%$$

$$\text{Puntaje F1 Clase No tumor} = 2 \times \frac{1 \times 0.9975}{1 + 0.9975} \times 100\% = 99.9\%$$

$$\text{Puntaje F1 Clase Meningioma} = 2 \times \frac{0.964 \times 0.95}{0.964 + 0.95} \times 100\% = 95.7\%$$

$$\text{Puntaje F1 Clase T. Hipofisario} = 2 \times \frac{0.89 \times 0.994}{0.89 + 0.994} \times 100\% = 94\%$$


A partir de estos resultados, se calculó el promedio del puntaje F1 general obtenido en la clasificación con el conjunto de pruebas y el promedio ponderado del puntaje F1.

$$\text{Promedio de Puntaje F1} = \frac{0.896 + 0.999 + 0.957 + 0.94}{4} \times 100\% = 95.05\%$$

$$\text{Promedio Ponderado de Puntaje F1} = \frac{0.896(454) + 0.999(400) + 0.957(317) + 0.94(327)}{1565} \times 100\% = 90.51\%$$

Además, se registraron las curvas de aprendizaje, que contienen información sobre la pérdida durante el entrenamiento y la validación, así como las curvas de exactitud durante el entrenamiento y la validación (Ilustración 12).

Ilustración 12 Curvas de aprendizaje de Resnet50 con un entrenamiento de 50 épocas y un tamaño de lote de 32.




Fuente: Elaboración Propia

Exactitud de validación y pérdida a lo largo de todas las iteraciones de entrenamiento del estudio: (a) Pérdida (menor es mejor) (b) Exactitud de validación (mayor es mejor)

Se puede observar, que en la clasificación realizada en el conjunto de pruebas para esta configuración de parámetros en el modelo Resnet50 presento algunos errores donde se clasificaron varias imágenes de manera incorrecta y que los resultados de validación difieren el alrededor de un 3% de los del entrenamiento, siendo la clase T. hipofisario la que presento menor clasificación en las evaluaciones

Ilustración 11: Matriz de confusión de InceptionV3 con un entrenamiento de 30 épocas y un tamaño de lote de 32.



Fuente: Elaboración Propia

Donde la clase 0 corresponde a Gliomas, 1 a Sin tumor, 2 a Meningiomas y 3 a T. hipofisarios. Se puede observar, que en la clasificación realizada en el conjunto de pruebas para esta configuración de parámetros en el modelo ResNet50 presento diversos

errores donde se clasificaron varias imágenes de manera incorrecta, siendo la mayoría clasificando las imágenes de Tumores Hipofisarios como meningiomas. Los datos necesarios para el cálculo de las métricas de desempeño mostradas se describen en la tabla

Tabla 8- Matriz de Observación de InceptionV3 con un entrenamiento de 30 épocas y un tamaño de lote de 64.

Clases	Mediciones			
	TP	TN	FP	FN
Glioma	462	1057	7	8
No Tumor	399	1120	13	1
Meningioma	323	1196	26	6
T. Hipofisario	335	1184	0	31

A partir de la fórmula 1 presentada en el capítulo previo, se obtuvo la exactitud general de clasificación:

$$Exactitud\ General = \frac{462 + 399 + 323 + 335}{1565} \times 100\% = 97\%$$

La fórmula 2 se utilizó para calcular la precisión de cada clase de la siguiente manera:

$$Precisión\ Clase\ Glioma = \frac{462}{462 + 7} \times 100\% = 98.6\%$$

$$Precisión\ Clase\ No\ tumor = \frac{399}{399 + 13} \times 100\% = 96.9\%$$

$$Precisión\ Clase\ Meningioma = \frac{323}{323 + 26} \times 100\% = 92.6\%$$

$$Precisión\ Clase\ T.\ Hipofisario = \frac{335}{335 + 0} \times 100\% = 100\%$$

Estos resultados se emplearon para calcular el promedio de la precisión general realizada por el clasificador y el promedio ponderado, considerando el número de imágenes del conjunto de pruebas para cada clase.

$$\text{Promedio de Precisión} = \frac{0.986 + 0.969 + 0.926 + 1}{4} \times 100\% = 97.1\%$$

$$\begin{aligned} \text{Promedio Ponderado de Precisión} &= \frac{0.986(462) + 0.969(399) + 0.926(323) + 1(335)}{1565} \times 100\% \\ &= 94.32\% \end{aligned}$$

La fórmula 3 se utilizó para calcular la sensibilidad individual en cada clase:

$$\text{Sensibilidad Clase Glioma} = \frac{462}{462 + 8} \times 100\% = 98\%$$

$$\text{Sensibilidad Clase No tumor} = \frac{399}{399 + 1} \times 100\% = 99.8\%$$

$$\text{Sensibilidad Meningioma} = \frac{323}{323 + 6} \times 100\% = 98.2\%$$

$$\text{Sensibilidad Clase T. Hipofisario} = \frac{335}{335 + 31} \times 100\% = 91.6\%$$

Estos resultados se utilizaron para obtener el promedio de la sensibilidad general en la tarea de clasificación y el promedio ponderado considerando el número de imágenes del conjunto de pruebas para cada clase.

$$\text{Promedio de Sensibilidad} = \frac{0.98 + 0.998 + 0.982 + 0.916}{4} \times 100\% = 96.9\%$$

$$\begin{aligned} \text{Promedio Ponderado de Sensibilidad} &= \frac{0.98(462) + 0.998(399) + 0.982(323) + 0.916(335)}{1565} \times 100\% \\ &= 94.24\% \end{aligned}$$

Finalmente, utilizando la fórmula 4, se calculó el puntaje F1 para cada clase:

$$\text{Puntaje F1 Clase Glioma} = 2 \times \frac{0.98 \times 0.986}{0.98 + 0.986} \times 100\% = 98.3\%$$

$$\text{Puntaje F1 Clase No tumor} = 2 \times \frac{0.998 \times 0.969}{0.998 + 0.969} \times 100\% = 98.3\%$$

$$\text{Puntaje F1 Clase Meningioma} = 2 \times \frac{0.982 \times 0.926}{0.982 + 0.926} \times 100\% = 95.3\%$$

$$\text{Puntaje F1 Clase T.Hipofisiario} = 2 \times \frac{0.916 \times 1}{0.916 + 1} \times 100\% = 95.6\%$$

A partir de estos resultados, se calculó el promedio del puntaje F1 general obtenido en la clasificación con el conjunto de pruebas y el promedio ponderado del puntaje F1.


$$\text{Promedio de Puntaje F1} = \frac{0.983 + 0.983 + 0.953 + 0.956}{4} \times 100\% = 96.87\%$$

$$\text{Promedio Ponderado de Puntaje F1} = \frac{0.983(462)+0.983(399)+0.953(323)+0.956(335)}{1565} \times 100\% = 94.21\%$$

Además, se registraron las curvas de aprendizaje, que contienen información sobre la pérdida durante el entrenamiento y la validación, así como las curvas de exactitud durante el entrenamiento y la validación (Ilustración 12).

Ilustración 12 Curvas de aprendizaje de InceptionV3 con un entrenamiento de 30 épocas y un tamaño de lote de 32.

Epocas vs. exactitud de Entrenamiento y Validation



Fuente: Elaboración Propia

Se puede observar, que en la clasificación realizada en el conjunto de pruebas para esta configuración de parámetros en el modelo Resnet50 presento algunos errores donde se clasificaron varias imágenes de manera incorrecta y que los resultados de validación difieren el alrededor de un 3% de los del entrenamiento, siendo la clase T. hipofisiario la que presento menor clasificación en las evaluaciones.

6.6 ANÁLISIS DE DATOS DE LA VALIDACIÓN

Tabla 9- Numero de aciertos por clase.

Numero de Aciertos					
Modelos	Glioma	No tumor	Meningioma	T hipofisiario	total
EfficientNetBo	465	400	322	341	1524
Vgg16	393	399	253	322	1367
Resnet50	454	400	317	327	1498
InceptionV3	462	399	323	335	1519

Fuente: Elaboración Propia

Tabla 10- número de fallos.

Numero de fallos por clase					
Modelos	Glioma	Meningioma	No tumor	T hipofisiario	Total
EfficientNetBo	Meningioma:5 Notumor:0 Hipofisiario:0 Total:5	Glioma:7 No tumor:0 Hipofisiario:0 Total:7	Glioma:0 Meningioma:0 Hipofisiario:0 Total:0	Glioma:2 Meningioma:15 No Tumor:8 Total:25	37
Vgg16	Meningioma:61 Notumor:1 Hipofisiario:15 Total:77	Glioma:40 No tumor:23 Hipofisiario:13 Total:76	Glioma:0 Meningioma:1 Hipofisiario:0 Total:1	Glioma:7 Meningioma:27 No Tumor:10 Total:44	198
Resnet50	Meningioma: 14 Notumor:0	Glioma:6 No tumor:6 Hipofisiario:0	Glioma:0 Meningioma:0 Hipofisiario:0	Glioma:5 Meningioma:12 No Tumor:15	60

	Hipofisiario:2 Total:16	Total:12	Total:0	Total:32	
InceptionV3	Meningioma: 8 Notumor:0 Hipofisiario:0 Total:8	Glioma:6 No tumor:0 Hipofisiario:0 Total:6	Glioma:1 Meningioma:0 Hipofisiario:0 Total:1	Glioma:0 Meningioma:18 No Tumor:13 Total:31	46

Fuente: Elaboración Propia

Tabla 11- porcentaje de aciertos

Porcentaje de aciertos por clase				
Modelos	Glioma	No tumor	Meningioma	T hipofisiario
EfficientNetBo	99	100	98	93.16
Vgg16	83.16	99.8	76.89	88
Resnet50	96.5	100	96.35	91.09
InceptionV3	98.30	99.75	98.17	91.53

Fuente: Elaboración Propia

Tabla 12- Precisión Entrenamiento vs testeo

Modelos	Entrenamiento	Testeo
EfficientNetBo	100	97.54
Vgg16	99	87
Resnet50	100	96
InceptionV3	100	97

Fuente: Elaboración Propia

La red EfficientNetBo, cuenta con una precisión total de 97.54%.

La clase Glioma produce 465 aciertos y 5 diagnósticos erróneos. Esto equivale a un 99% de acierto en esta clase mientras que los 5 diagnósticos erróneos son confundidos con meningiomas

La clase No Tumor que hace referencia a cerebros sin patologías, obtiene un 100% de diagnósticos correctos siendo la más elevada de todos los modelos. Por lo que todas las imágenes son diagnosticadas de forma adecuada.

La clase meningioma obtiene un 98% produce 7 diagnósticos errados y 322 aciertos. Los diagnósticos equívocos son tratados como Gliomas

En cuanto a la clase T. Hipofisarios el error es más elevado en este y todos los modelos. Este predice 341 aciertos y 25 errores obteniendo un 93% de precision.2 errores con glioma, 15 con meningioma y 8 con no tumor.

Esto se traduce en que los modelos son muy buenos diagnosticando la clase No tumor y tienen más problemas con la clase T.hipofisarios.


6.6.1 INTERPRETACIÓN DE DATOS Y OBSERVACIONES CLAVE DEL INCREMENTO 2

Los hallazgos encontrados en la visita a los hospitales para la recolección de datos arrojan que no existe una clasificación de IRM de tumores cerebrales lo que dificulta aún más la recolección de las imágenes.

En la lima medical center se encontraron 6 estudios de RM de pacientes. Los cuales 4 eran mujeres y 2 eran hombres

En las imágenes Proporcionadas por INEQ medica de pacientes sanos 4 eran mujeres y 1 era hombre

Ilustración 12 Cantidad da pacientes distribuida por sexos



Estas imágenes fueron reclasificadas para la prueba de inferencia en 30 imágenes por clase de la siguiente manera: 10 para el plano sagital, 10 para el plano coronal y 10 para el plano transversal

6.6.2 INTERPRETACIÓN DE DATOS Y OBSERVACIONES CLAVE DEL INCREMENTO 3

El modelo EfficientNetBO realizó un total de 66 predicciones acertando en 60 y fracasando en 6 lo que deja un porcentaje de exactitud del 91.66 % en la prueba de inferencia.

5 de los 6 fallos fueron en la clase no tumor, la que fue más alta para todos los modelos en las pruebas de entrenamiento y validación la otra fue en el glioma diagnosticando erróneamente un Pituitario.

Tabla 11- Matriz de Observación de InceptionV3 con un entrenamiento de 30 épocas y un tamaño de lote de 64.

Clases	Mediciones			
	TP	TN	FP	FN
Glioma	29	91	5	1
No Tumor	25	95	1	5
Meningioma	30	90	0	0
T. Hipofisiario	30	90	0	0

A partir de la fórmula 1 presentada en el capítulo previo, se obtuvo la exactitud general de clasificación:

$$Exactitud\ General = \frac{29 + 25 + 30 + 30}{120} \times 100\% = 95\%$$

La fórmula 2 se utilizó para calcular la precisión de cada clase de la siguiente manera:

$$Precisión\ Clase\ Glioma = \frac{29}{29 + 5} \times 100\% = 85\%$$

$$\text{Precisión Clase No tumor} = \frac{25}{25 + 1} \times 100\% = 96.15\%$$

$$\text{Precisión Clase Meningioma} = \frac{30}{30 + 0} \times 100\% = 100\%$$

$$\text{Precisión Clase T. Hipofisario} = \frac{30}{30 + 0} \times 100\% = 100\%$$

Estos resultados se emplearon para calcular el promedio de la precisión general realizada por el clasificador y el promedio ponderado, considerando el número de imágenes del conjunto de pruebas para cada clase.

$$\text{Promedio de Precisión} = \frac{0.85 + 0.9615 + 1 + 1}{4} \times 100\% = 95\%$$

$$\text{Promedio Ponderado de Precisión} = \frac{0.85(29) + 0.9615(25) + 1(30) + 1(30)}{120} \times 100\% = 90.57\%$$

La fórmula 3 se utilizó para calcular la sensibilidad individual en cada clase:

$$\text{Sensibilidad Clase Glioma} = \frac{29}{29 + 1} \times 100\% = 97\%$$

$$\text{Sensibilidad Clase No tumor} = \frac{25}{25 + 5} \times 100\% = 83.33\%$$

$$\text{Sensibilidad Meningioma} = \frac{30}{30 + 0} \times 100\% = 100\%$$

$$\text{Sensibilidad Clase T. Hipofisario} = \frac{30}{30 + 0} \times 100\% = 100\%$$

Estos resultados se utilizaron para obtener el promedio de la sensibilidad general en la tarea de clasificación y el promedio ponderado considerando el número de imágenes del conjunto de pruebas para cada clase.

$$\text{Promedio de Sensibilidad} = \frac{0.97 + 0.8333 + 1 + 1}{4} \times 100\% = 95.08\%$$

$$\text{Promedio Ponderado de Sensibilidad} = \frac{0.97(29) + 0.83(25) + 1(30) + 0.1(30)}{120} \times 100\% = 90.1\%$$

Finalmente, utilizando la fórmula 4, se calculó el puntaje F1 para cada clase:

$$\text{Puntaje F1 Clase Glioma} = 2 \times \frac{0.97 \times 0.85}{0.97 + 0.85} \times 100\% = 90.7\%$$

$$\text{Puntaje F1 Clase No tumor} = 2 \times \frac{0.8333 \times 0.9615}{0.8333 + 0.9615} \times 100\% = 89.28\%$$

$$\text{Puntaje F1 Clase Meningioma} = 2 \times \frac{1 \times 1}{1 + 1} \times 100\% = 100\%$$

$$\text{Puntaje F1 Clase T. Hipofisiario} = 2 \times \frac{1 \times 1}{1 + 1} \times 100\% = 100\%$$


A partir de estos resultados, se calculó el promedio del puntaje F1 general obtenido en la clasificación con el conjunto de pruebas y el promedio ponderado del puntaje F1.

$$\text{Promedio de Puntaje F1} = \frac{0.907 + 0.8928 + 1 + 1}{4} \times 100\% = 95\%$$

$$\text{Promedio Ponderado de Puntaje F1} = \frac{0.907(29) + 0.8928(25) + 1(30) + 1(30)}{120} \times 100\% = 90.51\%$$


ERRORES EN LA CLASIFICACIÓN:

Anexo 86: Prueba de inferencia clase no tumor




Resultado: glioma 65%

Anexo 87: Prueba de inferencia clase no tumor




Resultado: glioma 20%

Anexo 88: Prueba de inferencia clase no tumor




Resultado: glioma 30 %

Anexo 89: Prueba de inferencia clase no tumor




Resultado: glioma 77%

Anexo 89: Prueba de inferencia clase no tumor



Resultado: glioma 57%

Anexo 101: Prueba de inferencia clase glioma



Resultado: T pituitario 70%

6.6.1 POSIBLES CAUSAS DEL DESCENSO DE LA EXACTITUD PRINCIPIO DEL FORMULARIO FINAL DEL FORMULARIO

La diversidad y representatividad del conjunto de datos de validación son factores críticos que inciden directamente en la capacidad del modelo para generalizar su aprendizaje. Si el conjunto de validación no abarca de manera adecuada la variabilidad de casos y condiciones presentes en situaciones del mundo real, existe el riesgo de que el modelo muestre un rendimiento excesivamente optimista durante la validación. Es fundamental que el conjunto de validación refleje fielmente la complejidad del problema para garantizar una evaluación precisa del modelo.

Cuando el conjunto de entrenamiento carece de representación adecuada de ciertos casos, como podría ser el caso de una subrepresentación de la clase "glioma", se generan dificultades significativas en la capacidad del modelo para realizar clasificaciones precisas en situaciones específicas. La falta de exposición suficiente a casos particulares durante el entrenamiento puede resultar en un rendimiento deficiente al enfrentar esas situaciones en aplicaciones del mundo real. En el ejemplo específico de la clasificación errónea de glioma como tumor pituitario, esto puede atribuirse a la insuficiente cantidad de datos relevantes y representativos en el conjunto de entrenamiento.

La carencia de una representación suficiente de ciertos casos dentro del conjunto de entrenamiento puede resultar en un rendimiento deficiente del modelo en situaciones específicas, como la clasificación errónea de glioma como tumor pituitario. Este problema se deriva de la importancia de proporcionar al modelo una exposición adecuada y variada a todas las clases y escenarios posibles que pueda encontrar en el mundo real.

Cuando se menciona la "falta de representación adecuada", nos referimos a la insuficiencia de ejemplos específicos o instancias de la clase "glioma" en el conjunto de datos de entrenamiento. El modelo de aprendizaje profundo necesita aprender patrones distintivos asociados con cada clase, y si la representación de una clase particular es limitada o incompleta durante la fase de entrenamiento, el modelo puede no adquirir un conocimiento completo y preciso sobre esa clase en particular.

En el contexto específico de la clasificación incorrecta de glioma como tumor pituitario, es posible que la ausencia de suficientes ejemplos de glioma durante el entrenamiento haya impedido al modelo capturar las sutilezas y características específicas que distinguen a gliomas de tumores pituitarios. Esta falta de representación puede llevar a una interpretación incorrecta de las características de gliomas durante la inferencia, especialmente si las imágenes de gliomas en el conjunto de prueba comparten similitudes visuales con las de tumores pituitarios.

7.6.2 CONTRIBUCIÓN TÉCNICA Y CIENTÍFICA

El informe proporciona una contribución técnica y científica significativa en el ámbito de la clasificación de imágenes de resonancia magnética (IRM) de tumores cerebrales. Aquí se destacan varios aspectos clave que resaltan la importancia y el impacto de este trabajo:

VALIDACIÓN RIGUROSA DE MODELOS DE APRENDIZAJE PROFUNDO:

- Se establece la creación de conjuntos de prueba derivados del conjunto de entrenamiento para validar el rendimiento de modelos de aprendizaje profundo como VGG16, ResNet50, InceptionV3 y EfficientNetB0. Esta estrategia garantiza que los modelos no solo memoricen los datos de entrenamiento, sino que también generalicen correctamente con datos nuevos, evitando el sobreajuste.

AJUSTE DE PARÁMETROS PARA MEJORAR EL RENDIMIENTO:

- Se describe el ajuste de parámetros como épocas y tamaño del lote durante el entrenamiento de los modelos. Este enfoque demuestra un esfuerzo deliberado para optimizar el rendimiento de los modelos y garantizar resultados más precisos.

CONJUNTO DE DATOS DE VALIDACIÓN COLABORATIVO:

- La propuesta de un conjunto de datos de validación compuesto por imágenes colaboradas con el Instituto Hondureño de Seguridad Social y clínicas privadas destaca la colaboración efectiva con entidades locales. Este conjunto de datos es crucial para evaluar la

eficacia del algoritmo en un contexto real, demostrando la aplicabilidad de la investigación en el entorno hondureño.

EVALUACIÓN DE MODELOS:

- El primer incremento incluye la formación de modelos con transferencia de aprendizaje y la variación de parámetros. Aunque los resultados mostraron un rendimiento similar entre los modelos, la evaluación exhaustiva es esencial para prever datos no anticipados y revelar la capacidad de generalización de los modelos.

EVALUACIÓN DEL ALGORITMO:

- La evaluación del algoritmo se realiza mediante predicciones con el modelo mejor calificado. Se destaca la utilización de una base de datos recolectada localmente para validar el modelo, enfatizando la relevancia de los datos locales en la implementación práctica del algoritmo.

IMPORTANCIA DE LA CREACIÓN Y PUBLICACIÓN DE UNA BASE DE DATOS LOCAL:

- La creación y publicación de una base de datos de IRM cerebrales de pacientes hondureños se presenta como un hito crucial. Este acto no solo respalda la transparencia y reproducibilidad de la investigación, sino que también sienta las bases para futuros estudios y contribuye al avance global en el campo de la clasificación de imágenes médicas.
- Se reconoce la importancia de crear una base de datos de IRM cerebrales de pacientes hondureños, incluyendo clases específicas. Esta colaboración con hospitales locales y la recopilación de imágenes demuestran un compromiso con la mejora de la representatividad de los datos, crucial para la efectividad de los algoritmos en entornos específicos.

Este informe no solo presenta avances técnicos en el desarrollo de algoritmos de clasificación de tumores cerebrales, sino que también destaca la importancia de la colaboración local y la creación de bases de datos específicas para validar y mejorar la aplicabilidad de dichos algoritmos en entornos clínicos específicos.

7.6.3 COMPARATIVA CON LOS RESULTADOS DEL ESTADO DEL ARTE PRINCIPIO DEL FORMULARIO FINAL DEL FORMULARIO

Como se mostró anteriormente en los resultados para el primer incremento, entre los diferentes modelos como EfficientNetBO, Resnet 50 e InceptionV3 se alcanzó una exactitud de 100% durante el entrenamiento y VGG16 del 95, que paso al 97.55 para efficientNetBO durante la validación y al 87% para VGG16. Por otro lado, para el Tercer incremento, existe una exactitud en la prueba de inferencia del 95% para EfficientNetBO.

VII. CONCLUSIONES

A lo largo del estudio, se llevó a cabo una evaluación del aprendizaje de transferencia profunda para asistir en el diagnóstico de Tumores cerebrales, como glioma, meningioma y tumores pituitarios en respuesta al problema planteado.

Los resultados de las 36 pruebas realizadas en diferentes fases del estudio lograron mejorar las métricas de rendimiento de un algoritmo de clasificación de cuatro clases de IRM cerebral. Se obtuvo un promedio de 95% de precisión en el modelo mejor evaluado del entrenamiento EfficientNetB0. La precisión se consideró la métrica clave en la tarea de clasificación.

Se identificó a lo largo del estudio que los parámetros críticos para optimizar el entrenamiento de los modelos preentrenados eran el número de épocas y el tamaño de lote. Al modificar estos parámetros, se observaron cambios en las métricas de rendimiento, incluyendo precisión, sensibilidad y puntaje F1, fundamentales para evaluar el rendimiento del algoritmo.

Se emplearon IRM de pacientes hondureños proporcionadas por el IHSS y dos hospitales de la zona norte del país además de una empresa de venta de equipos de resonancia magnética. Estas imágenes se utilizaron para evaluar la aplicabilidad del algoritmo en un conjunto de validación, que incluía clases de gliomas, meningiomas y cerebros sin tumores. El modelo preentrenado EfficientNetB0 presentó 6 errores en 120 predicciones.

Se creó una base de datos de imágenes de IRM cerebrales, y tomografías computarizadas, a partir de visitas a varios hospitales. Esta base de datos abrió nuevas posibilidades de investigación en el procesamiento de imágenes médicas de pacientes hondureños.

VIII. AGRADECIMIENTOS

A mis padres, quienes con amor infinito y apoyo incondicional han sido mi roca en este viaje académico. A mi madre, que a pesar de que nunca estuve en el cuadro de honor dejó de creer en mí. Su fe inquebrantable y su constante aliento fueron mi fuerza. A mis hermanos y familia, por su paciencia, comprensión y apoyo continuo. A mis amigos y compañeros de trabajo, por sus risas, ánimo y apoyo incansable. A todos aquellos que, de una forma u otra, han iluminado mi camino y han sido parte fundamental de este logro. Gracias por ser mi inspiración y motivación constante en la culminación de este importante capítulo académico.

IX. REFERENCIAS BIBLIOGRÁFICAS

Sartaj Bhuvaji, Ankita Kadam, Prajakta Bhumkar, Sameer Dedge, & Swati Kanchan. (2020). *Brain Tumor Classification (MRI)* [Data set]. Kaggle. Ahmed, H. (s. f.). *Br35H :: Brain Tumor Detection 2020*. Recuperado 7 de noviembre de 2023, de <https://www.kaggle.com/datasets/ahmedhamada0/brain-tumor-detection>

Al-Azzwi, Z. H. N., & Nazarov, A. N. (2023). Brain Tumor Classification based on Improved Stacked Ensemble Deep Learning Methods. *Asian Pacific Journal of Cancer Prevention: APJCP*, 24(6), 2141-2148. <https://doi.org/10.31557/APJCP.2023.24.6.2141>

An Efficient Method for Brain Tumor Detection Using Texture Features and SVM Classifier in MR Images. (s. f.). Recuperado 7 de diciembre de 2023, de https://journal.waocp.org/article_69798.html

Deepak, S., & Ameer, P. M. (2019). Brain tumor classification using deep CNN features via transfer learning. *Computers in Biology and Medicine*, 111, 103345. <https://doi.org/10.1016/j.combiomed.2019.103345>

Entre 6,000 y 9,000 personas con cáncer se detectan cada año en Honduras. (s. f.). Recuperado 29 de agosto de 2023, de <https://www.elheraldo.hn/honduras/entre-6-000-9-000-personas-cancer-detectan-honduras-CE12344420#>

Error in Radiology—Clinical Radiology. (s. f.). Recuperado 1 de septiembre de 2023, de [https://www.clinicalradiologyonline.net/article/S0009-9260\(01\)90858-X/pdf](https://www.clinicalradiologyonline.net/article/S0009-9260(01)90858-X/pdf)

Funciones de Pérdida en Aprendizaje Automático—Guía Completa. (s. f.). Recuperado 21 de marzo de 2024, de <https://www.gyata.ai/es/machine-learning/machine-learning-loss-functions/>

Kadam, A. (2021). Brain Tumor Classification using Deep Learning Algorithms. *International Journal for Research in Applied Science and Engineering Technology*, 9(12), 417-426. <https://doi.org/10.22214/ijraset.2021.39280>

Kadam—2021—Brain Tumor Classification using Deep Learning Alg.pdf.

(s. f.).

KeepCoding, R. (2022, agosto 16). *¿Qué es la entropía cruzada en Deep Learning?* <https://keepcoding.io/blog/entropia-cruzada-deep-learning/>

Kibriya, H., Amin, R., Alshehri, A. H., Masood, M., Alshamrani, S. S., & Alshehri, A. (2022a). A Novel and Effective Brain Tumor Classification Model Using Deep Feature Fusion and Famous Machine Learning Classifiers. *Computational Intelligence and Neuroscience*, 2022, 7897669. <https://doi.org/10.1155/2022/7897669>

Kibriya, H., Amin, R., Alshehri, A. H., Masood, M., Alshamrani, S. S., & Alshehri, A. (2022b). A Novel and Effective Brain Tumor Classification Model Using Deep Feature Fusion and Famous Machine Learning Classifiers. *Computational Intelligence and Neuroscience*, 2022, 7897669. <https://doi.org/10.1155/2022/7897669>

Komninos, J., Vlassopoulou, V., Protopapa, D., Korfiatis, S., Kontogeorgos, G., Sakas, D. E., & Thalassinou, N. C. (2004). Tumors Metastatic to the Pituitary Gland: Case Report and Literature Review. *The Journal of Clinical Endocrinology & Metabolism*, 89(2), 574-580. <https://doi.org/10.1210/jc.2003-030395>

Low, J. T., Ostrom, Q. T., Cioffi, G., Neff, C., Waite, K. A., Kruchko, C., & Barnholtz-Sloan, J. S. (2022). Primary brain and other central nervous system tumors in the United States (2014-2018): A summary of the CBTRUS statistical report for clinicians. *Neuro-Oncology Practice*, 9(3), 165-182. <https://doi.org/10.1093/nop/npac015>

Max Pooling. (2019, mayo 17). DeepAI. <https://deepai.org/machine-learning-glossary-and-terms/max-pooling>

Musallam, A. S., Sherif, A. S., & Hussein, M. K. (2022). A New Convolutional Neural Network Architecture for Automatic Detection of Brain Tumors in Magnetic Resonance Imaging Images. *IEEE Access*, 10, 2775-2782. <https://doi.org/10.1109/ACCESS.2022.3140289>

¿Qué es Epoch en Machine Learning? | Ciberseguridad. (s. f.). Recuperado 21 de marzo de 2024, de <https://ciberseguridad.com/guias/nuevas-tecnologias/machine-learning/epoch/>

¿Qué son las redes neuronales convolucionales? | IBM. (s. f.). Recuperado

21 de marzo de 2024, de <https://www.ibm.com/mx-es/topics/convolutional-neural-networks#>

Rasheed, S., Rehman, K., & Akash, M. S. H. (2021). An insight into the risk factors of brain tumors and their therapeutic interventions. *Biomedicine & Pharmacotherapy = Biomedecine & Pharmacotherapie*, *143*, 112119. <https://doi.org/10.1016/j.biopha.2021.112119>

Reyes, D. (2022). *Clasificación Automática de Tumores Cerebrales Haciendo Uso de Redes Neuronales*. https://accedacris.ulpgc.es/bitstream/10553/115607/1/P%C3%A1ginas%20desdeMemoria_signed.pdf

Sartaj, B. (s. f.). *Brain-Tumor-Classification-DataSet: This repository is part of the Brain Tumor Classification Project. The repo contains the unaugmented dataset used for the project* [dataset]. <https://doi.org/doi.org/10.34740/KAGGLE/DSV/1183165>

Shah, H. A., Faisal Saeed, & Sangseok, yun. (2022). *A Robust Approach for Brain Tumor Detection in Magnetic Resonance Images Using Finetuned EfficientNet*. <https://ieeexplore.ieee.org/document/9798829/>

Srinivas, C., K. S., N. P., Zakariah, M., Alothaibi, Y. A., Shaukat, K., Partibane, B., & Awal, H. (2022). Deep Transfer Learning Approaches in Performance Analysis of Brain Tumor Classification Using MRI Images. *Journal of Healthcare Engineering*, *2022*, e3264367. <https://doi.org/10.1155/2022/3264367>

Sultan et al. - 2019—Multi-Classification of Brain Tumor Images Using D.pdf. (s. f.).

Sultan, H. H., Salem, N. M., & Al-Atabany, W. (2019). Multi-Classification of Brain Tumor Images Using Deep Neural Network. *IEEE Access*, *7*, 69215-69225. <https://doi.org/10.1109/ACCESS.2019.2919122>

Surawicz, T. S., Davis, F., Freels, S., Laws, E. R., & Menck, H. R. (1998). Brain tumor survival: Results from the National Cancer Data Base. *Journal of Neuro-Oncology*, *40*(2), 151-160. <https://doi.org/10.1023/a:1006091608586>

Team, K. (s. f.). *Keras documentation: Keras Applications*. Recuperado 3 de septiembre de 2023, de <https://keras.io/api/applications/>

Willemink, M. J., Koszek, W. A., Hardell, C., Wu, J., Fleischmann, D., Harvey, H., Folio, L. R., Summers, R. M., Rubin, D. L., & Lungren, M. P. (2020). Preparing Medical Imaging Data for Machine Learning. *Radiology*, 295(1), 4-15. <https://doi.org/10.1148/radiol.2020192224>


-

- Cheng, Jun (2017). brain tumor dataset. figshare. Dataset. <https://doi.org/10.6084/m9.figshare.1512427.v5>


X. ANEXOS

Anexo 1 Gráficos de desempeño EfficientNetB0 época 12, lote 32

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 2 Matriz de confusión EfficientNetB0 época 12, lote 32




Anexo 3 Gráficos de desempeño EfficientNetB0 época 12, lote 64

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 4 Matriz de confusión EfficientNetB0 época 12, lote 64




Anexo 5 Gráficos de desempeño EfficientNetB0 época 12, lote 96

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 6 Matriz de confusión EfficientNetB0 época 12, lote 96




Anexo 7 Gráficos de desempeño EfficientNetB0 época 30, lote 32

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 8 Matriz de confusión EfficientNetB0 época 30, lote 32




Anexo 9 Gráficos de desempeño EfficientNetB0 época 30, lote 64

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 10 Matriz de confusión EfficientNetB0 época 30, lote 64




Anexo 11 Graficos de desempeño EfficientNetB0 época 30, lote 96

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 12 Matriz de confusión EfficientNetB0 época 30, lote 96




Anexo 13 Gráficos de desempeño EfficientNetB0 época 50, lote 32

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 14 Matriz de confusión EfficientNetB0 época 50, lote 32




Anexo 15 Gráficos de desempeño EfficientNetB0 época 50, lote 64

Epocas vs. Precisión de Entrenamiento y Validation





Anexo 16 Matriz de confusión EfficientNetB0 época 50, lote 64




Anexo 17 Gráficos de desempeño EfficientNetB0 época 50, lote 96

Epocas vs. Precisión de Entrenamiento y Validation




Anexo 18 Matriz de confusión EfficientNetB0 época 50, lote 96




Anexo 19 Gráficos de desempeño VGG16 época 12, lote 32

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 20 Matriz de confusión VGG16 época 12, lote 32




Anexo 21 Gráficos de desempeño VGG16 época 12, lote 64

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 22 Matriz de confusión VGG16 época 12, lote 64




Anexo 23 Gráficos de desempeño VGG16 época 12, lote 96

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 24 Matriz de confusión VGG16 época 12, lote 96




Anexo 25 Gráficos de desempeño VGG16 época 30, lote 32

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 26 Matriz de confusión VGG16 época 30, lote 32




Anexo 27 Gráficos de desempeño VGG16 época 30, lote 64

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 28 Matriz de confusión VGG16 época 30, lote 64




Anexo 29 Gráficos de desempeño VGG16 época 30, lote 96

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 30 Matriz de confusión VGG16 época 30, lote 96




Anexo 31 Gráficos de desempeño VGG16 época 50, lote 32

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 32 Matriz de confusión VGG16 época 50, lote 32




Anexo 33 Gráficos de desempeño VGG16 época 50, lote 64

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 34 Matriz de confusión VGG16 época 50, lote 64




Anexo 35 Gráficos de desempeño VGG16 época 50, lote 96

Epocas vs. exactitud de Entrenamiento y Validation





Anexo 36 Matriz de confusión VGG16 época 50, lote 96





Anexo 37 Graficos de desempeño InceptionV3 época 12, lote 32

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 38 Matriz de confusión InceptionV3 época 12, lote 32




Anexo 39 Gráficos de desempeño InceptionV3 época 12, lote 64

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 40 Matriz de confusión InceptionV3 época 12, lote 64




Anexo 41 Gráficos de desempeño InceptionV3 época 12, lote 96

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 42 Matriz de confusión InceptionV3 época 12, lote 96




Anexo 43 Gráficos de desempeño InceptionV3 época 30, lote 32

Epocas vs. exactitud de Entrenamiento y Validation





Anexo 44 Matriz de confusión InceptionV3 época 30, lote 32




Anexo 45 Gráficos de desempeño InceptionV3 época 30, lote 64

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 46 Matriz de confusión InceptionV3 época 30, lote 64




Anexo 47 Gráficos de desempeño InceptionV3 época 30, lote 96

Epocas vs. exactitud de Entrenamiento y Validation





Anexo 48 Matriz de confusión InceptionV3 época 30, lote 96





Anexo 49 Gráficos de desempeño InceptionV3 época 50, lote 32

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 50 Gráficos de desempeño InceptionV3 época 50, lote 64

Epocas vs. exactitud de Entrenamiento y Validation


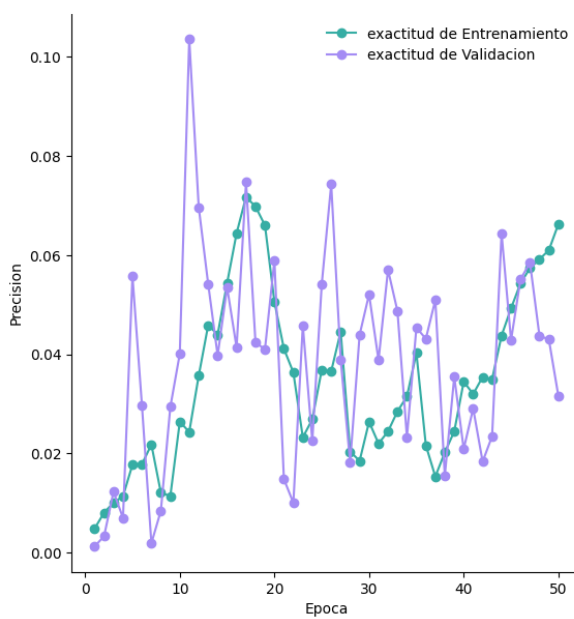


Anexo 51 Matriz de confusión InceptionV3 época 50, lote 64




Anexo 52 Gráficos de desempeño InceptionV3 época 50, lote 96

Epocas vs. exactitud de Entrenamiento y Validation

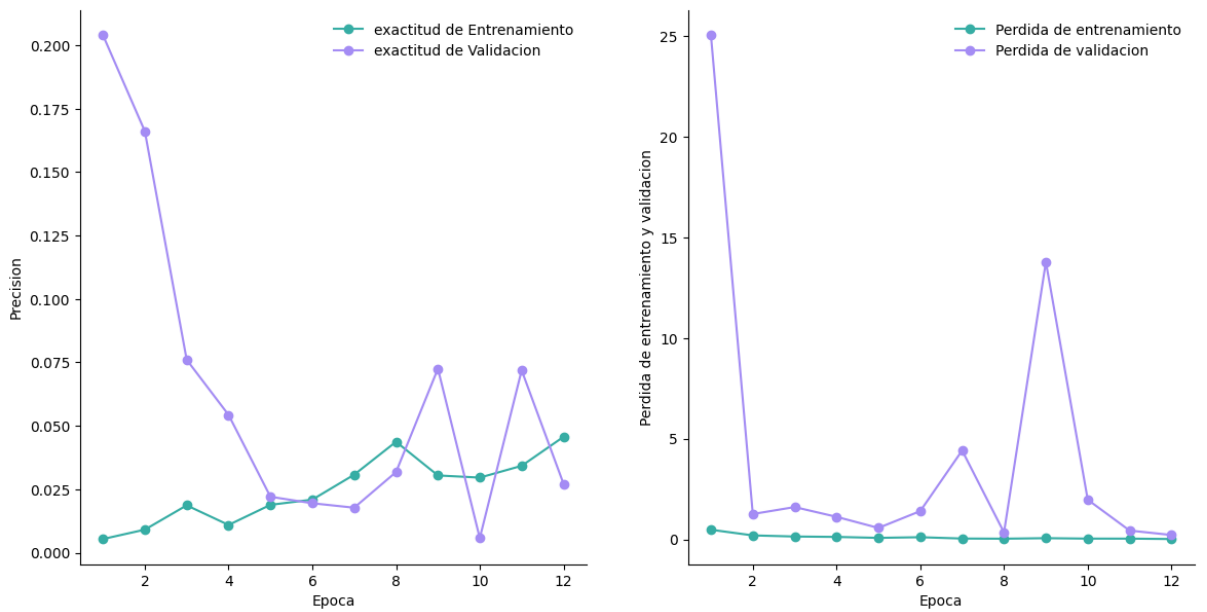


Anexo 53 Matriz de confusión InceptionV3 época 50, lote 96




Anexo 54 Gráficos de desempeño Resnet50 época 12, lote 32

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 55 Matriz de confusión Resnet50 época 12, lote 32




Anexo 56 Gráficos de desempeño Resnet50 época 12, lote 64

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 57 Matriz de confusión Resnet50 época 12, lote 64




Anexo 58 Gráficos de desempeño Resnet50 época 12, lote 96

Epocas vs. exactitud de Entrenamiento y Validation

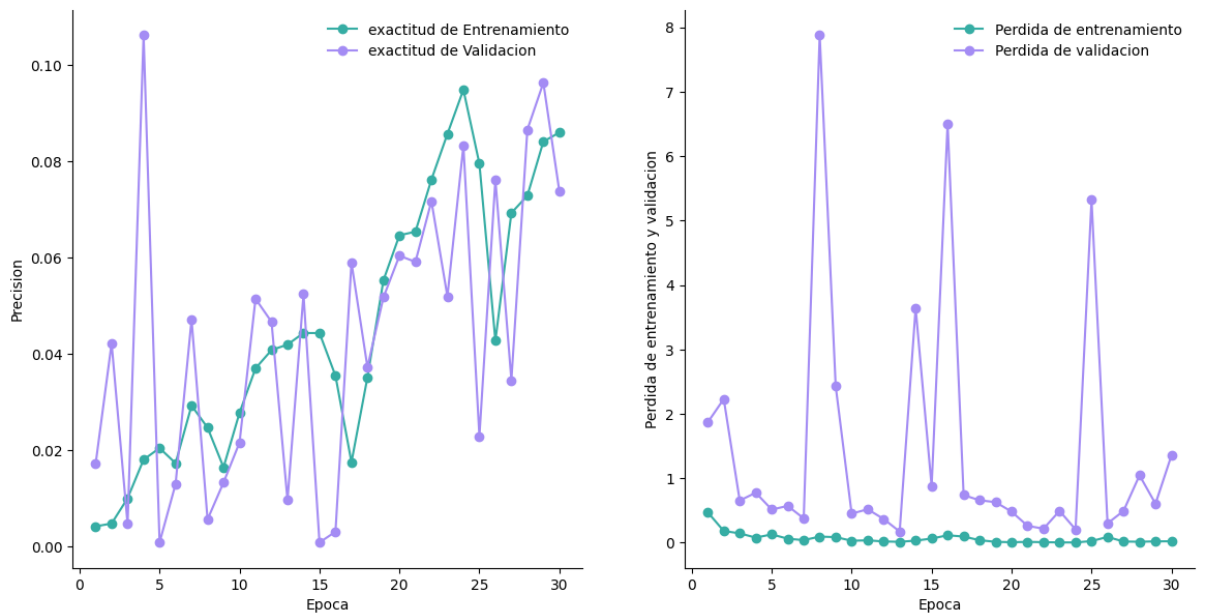


Anexo 59 Matriz de confusión Resnet50 época 12, lote 96




Anexo 60 Gráficos de desempeño Resnet50 época 30, lote 32

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 61 Matriz de confusión Resnet50 época 30, lote 32




Anexo 62 Gráficos de desempeño Resnet50 época 30, lote 64

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 63 Matriz de confusión Resnet50 época 30, lote 64




Anexo 64 Gráficos de desempeño Resnet50 época 30, lote 96

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 65 Matriz de confusión Resnet50 época 30, lote 96




Anexo 66 Gráficos de desempeño Resnet50 época 50, lote 32

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 67 Matriz de confusión Resnet50 época 50, lote 32




Anexo 68 Gráficos de desempeño Resnet50 época 50, lote 64

Epocas vs. exactitud de Entrenamiento y Validation




Anexo 69 Matriz de confusión Resnet50 época 50, lote 64




Anexo 70 Gráficos de desempeño Resnet50 época 50, lote 96


Epocas vs. exactitud de Entrenamiento y Validation



Anexo 71 Matriz de confusión Resnet50 época 50, lote 96




Anexo 72 Prueba de inferencia clase no tumor




Resultado: No tumor 99.7%

Anexo 73 Prueba de inferencia clase no tumor




Resultado: No tumor 99.9%

Anexo 74 Prueba de inferencia clase no tumor




Resultado: No tumor 99.9%

Anexo 75 Prueba de inferencia clase no tumor




Resultado: No tumor 99.9%

Anexo 76 Prueba de inferencia clase no tumor




Resultado: No tumor 100%

Anexo 77 Prueba de inferencia clase no tumor




Resultado: No tumor 100%

Anexo 78 Prueba de inferencia clase no tumor




Resultado: No tumor 100%

Anexo 79 Prueba de inferencia clase no tumor




Resultado: No tumor 100%

Anexo 80 Prueba de inferencia clase no tumor




Resultado: No tumor 100%

Anexo 81 Prueba de inferencia clase no tumor




Resultado: No tumor 99%

Anexo 82 Prueba de inferencia clase no tumor




Resultado: No tumor 99%

Anexo 83 Prueba de inferencia clase no tumor




Resultado: No tumor 100%

Anexo 84 Prueba de inferencia clase no tumor




Resultado: No tumor 100%

Anexo 85 Prueba de inferencia clase no tumor




Resultado: No tumor 100%

Anexo 86 Prueba de inferencia clase no tumor




Resultado: glioma 99%

Anexo 87 Prueba de inferencia clase no tumor




Resultado: glioma 99%

Anexo 88 Prueba de inferencia clase no tumor




Resultado: glioma 99 %

Anexo 89 Prueba de inferencia clase no tumor




Resultado: glioma 99%

Anexo 90 Prueba de inferencia clase no tumor




Resultado: No tumor 99.9%

Anexo 91 Prueba de inferencia clase no tumor




Resultado: No tumor 99.7%

Anexo 92 Prueba de inferencia clase no tumor




Resultado: No tumor 100%

Anexo 93 Prueba de inferencia clase no tumor




Resultado: No tumor 99.9%

Anexo 94 Prueba de inferencia clase no tumor




Resultado: No tumor 99.9%

Anexo 95 Prueba de inferencia clase no tumor




Resultado: glioma 77%

Anexo 96 Prueba de inferencia clase no tumor



Resultado: No tumor 100%

Anexo 97 Prueba de inferencia clase no tumor




Resultado: No tumor 100%

Anexo 98 Prueba de inferencia clase no tumor




Resultado: No tumor 100%

Anexo 99 Prueba de inferencia clase glioma




Resultado: glioma 99%

Anexo 100 Prueba de inferencia clase glioma




Resultado: glioma 99%

Anexo 101 Prueba de inferencia clase glioma




Resultado: glioma 99%

Anexo 102 Prueba de inferencia clase glioma




Resultado: glioma 99%

Anexo 103 Prueba de inferencia clase glioma




Resultado: glioma 99%

Anexo 104 Prueba de inferencia clase glioma




Resultado: glioma 99%

Anexo 105 Prueba de inferencia clase glioma




Resultado: glioma 99%

Anexo 106 Prueba de inferencia clase glioma



Resultado: glioma 99%

Anexo 107 Prueba de inferencia clase glioma




Resultado: glioma 99%

Anexo 108 Prueba de inferencia clase glioma




Resultado: glioma 99%

Anexo 109 Prueba de inferencia clase glioma




Resultado: glioma 99%

Anexo 110 Prueba de inferencia clase glioma




Resultado: glioma 99%

Anexo 111 Prueba de inferencia clase glioma




Resultado: glioma 99%

Anexo 112 Prueba de inferencia clase glioma




Resultado: glioma 99%

Anexo 113 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 114 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 115 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 116 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 117 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 118 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 119 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 120 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 121 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 122 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 123 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 124 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 125 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 126 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 127 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 128 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 129 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 130 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 131 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 132 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 133 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 134 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 135 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 136 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 137 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 138 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 139 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 140 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 141 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 142 Prueba de inferencia clase meningioma




Resultado: meningioma 99%

Anexo 143 Prueba de inferencia clase T pituitario



Resultado: meningioma 99%

Anexo 144 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 145 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 146 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 147 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 148 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 149 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 150 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 151 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 152 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 153 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 154 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 155 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 156 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 157 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 158 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 159 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 160 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 161 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 162 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 163 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 164 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 165 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 166 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 167 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 168 Prueba de inferencia clase T pituitario



Resultado: meningioma 99%

Anexo 169 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 170 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 171 Prueba de inferencia clase T pituitario




Resultado: meningioma 99%

Anexo 172 Prueba de inferencia clase T pituitario



Resultado: meningioma 99%

Anexo 173 Prueba de inferencia clase T pituitario



Resultado: meningioma 99%