

# Impact of convolutional neural networks on brain tumor classification: A systematic analysis

Fabricio Gutiérrez Juárez<sup>1</sup>, Evelyn Elizabeth Ayala Níquen<sup>2</sup>; Renzo Omar Ballero Dávila<sup>3</sup>

<sup>1,2,3</sup> Universidad Tecnológica del Perú, Perú, [u21227995@utp.edu.pe](mailto:u21227995@utp.edu.pe), [c26915@utp.edu.pe](mailto:c26915@utp.edu.pe), [c22056@utp.edu.pe](mailto:c22056@utp.edu.pe)

**Abstract—** This systematic literature review assessed the impact of brain tumor classification on magnetic resonance imaging using convolutional neural networks (CNN). The PRISMA strategy was used to organize and document the study selection and evaluation process. From an initial total of 448 articles identified in Scopus and Web of Science, duplicates were eliminated, and inclusion and exclusion criteria were applied, resulting in the evaluation of 103 highly relevant and quality studies. The most used architectures, including ResNet-50, VGG16 and EfficientNet-B4, were identified and analyzed, assessing their effectiveness in terms of accuracy, sensitivity and F1-score. The results showed that these architectures can achieve accuracy levels above 98%, making them effective for potential implementation in clinical settings. In addition, key pre-processing techniques, such as normalization and denoising, were highlighted as contributing to improved image quality and reduced variability. However, important barriers were identified, such as the scarcity of high-quality data and privacy constraints, which limit the generalizability and robustness of the models. The review concludes that the creation of standardized datasets and the development of innovative methodological approaches are essential to advance the clinical applicability of CNNs in brain tumor diagnosis.

**Keywords**—Brain tumors, CNN, magnetic resonance imaging, classification.

# Impacto de redes neuronales convolucionales en la clasificación de tumores cerebrales: Un análisis sistemático

Fabricio Gutiérrez Juárez<sup>1</sup>; Evelyn Elizabeth Ayala Ñíquen<sup>2</sup>; Renzo Omar Ballero Davila<sup>3</sup>

<sup>1,2,3</sup>Universidad Tecnológica del Perú, Perú, [u21227995@utp.edu.pe](mailto:u21227995@utp.edu.pe), [c26915@utp.edu.pe](mailto:c26915@utp.edu.pe), [c22056@utp.edu.pe](mailto:c22056@utp.edu.pe)

**Resumen—** En esta revisión sistemática de la literatura se evaluó el impacto de la clasificación de los tumores cerebrales en imágenes de resonancia magnética mediante el uso de redes neuronales convolucionales (CNN). Se utilizó la estrategia PRISMA para organizar y documentar el proceso de selección y evaluación de estudios. De un total inicial de 448 artículos identificados en Scopus y Web of Science, se eliminaron duplicados y se aplicaron criterios de inclusión y exclusión, resultando en la evaluación de 103 estudios altamente pertinentes y de calidad. Se identificaron y analizaron las arquitecturas más utilizadas, incluyendo ResNet-50, VGG16 y EfficientNet-B4, evaluando su efectividad en términos de precisión, sensibilidad y F1-score. Los resultados mostraron que estas arquitecturas pueden alcanzar niveles de precisión superiores al 98%, lo que las hace efectivas para su posible implementación en contextos clínicos. Además, se destacaron las principales técnicas de preprocesamiento, como la normalización y eliminación de ruido, que contribuyen a la mejora de la calidad de las imágenes y la reducción de la variabilidad. Sin embargo, se identificaron barreras importantes, como la escasez de datos de alta calidad y las restricciones de privacidad, que limitan la capacidad de generalización y consistencia de los modelos. La revisión concluye que la creación de conjuntos de datos estandarizados y el desarrollo de enfoques metodológicos innovadores son esenciales para avanzar en la aplicabilidad clínica de las CNN en el diagnóstico de tumores cerebrales.

**Palabras clave—**Tumores cerebrales, CNN, imágenes de resonancia magnética, clasificación.

## I. INTRODUCCIÓN

El uso de redes neuronales convolucionales (CNN) ha emergido como una herramienta clave para la detección y clasificación de tumores cerebrales, impulsada por el crecimiento exponencial de la inteligencia artificial orientada al análisis de imágenes médicas. Estas redes han demostrado una notable capacidad para identificar patrones en imágenes de resonancia magnética (MRI, por sus siglas en inglés), facilitando la detección automatizada de anomalías en el cerebro y mejorando la precisión y eficiencia del diagnóstico clínico [1]. Desde su adopción en el campo de la neuroimagen en 2015, diversas investigaciones han explorado arquitecturas y configuraciones de CNN, logrando avances prometedores en el análisis de imágenes médicas [2].

A pesar de estos avances, la investigación en este ámbito enfrenta desafíos significativos. Entre ellos, destaca la falta de conjuntos de datos adecuados para el entrenamiento de los modelos. Además, los estudios presentan una notable

variabilidad en cuanto a las arquitecturas de CNN empleadas, las técnicas de preprocesamiento de las imágenes y las métricas de evaluación utilizadas para medir el desempeño de los modelos [3]. Esta heterogeneidad dificulta la comparación de resultados entre estudios, impide la replicabilidad de los experimentos y limita la identificación de mejores prácticas en la utilización de CNN para el diagnóstico de tumores cerebrales [4]. Por otro lado, las bases de datos utilizadas, como BraTS y Figshare, presentan diferencias significativas en tamaño, calidad y características de las imágenes, lo que afecta directamente el desempeño de los modelos y la consistencia de los resultados reportados [2, 5]. Asimismo, la ausencia de un marco estandarizado para evaluar el desempeño de diferentes arquitecturas de CNN y técnicas de preprocesamiento de imágenes sigue siendo una barrera importante para obtener conclusiones sólidas sobre su efectividad en este contexto [6].

Por lo tanto, esta revisión sistemática de la literatura busca mejorar los hallazgos de estudios previos, como el realizado por [1], que proporciona una base inicial, pero carece de una visión más amplia, específica y estandarizada del uso de CNN en la clasificación de tumores cerebrales. Este trabajo se propone consolidar y sintetizar la información clave que permita identificar las prácticas más efectivas y los desafíos principales en este campo. Los resultados de esta revisión no solo podrán orientar futuras investigaciones hacia enfoques más sólidos, sino que también facilitarán la aplicabilidad clínica de estas redes, contribuyendo al diagnóstico médico.

El objetivo de esta revisión es ofrecer una visión clara del estado del arte y mostrar las prácticas actuales en la clasificación de tumores cerebrales mediante CNN, facilitando así el avance continuo y riguroso en futuras investigaciones.

La revisión comienza con una descripción de las estrategias de búsqueda y selección de estudios realizadas bajo la metodología PRISMA. Posteriormente, se analizan las técnicas de preprocesamiento más utilizadas, las arquitecturas predominantes de CNN y las métricas de evaluación empleadas. Finalmente, se discuten las principales limitaciones de los estudios actuales, se proponen recomendaciones para superar las barreras identificadas y se concluye con una síntesis de los hallazgos clave.

## II. METODOLOGÍA

### A. Estrategia de búsqueda

Con el propósito de examinar el impacto de diversas técnicas de preprocessamiento de imágenes y comparar el rendimiento de distintas arquitecturas de CNN en la clasificación de tumores cerebrales utilizando imágenes de resonancia magnética, esta revisión se enfocó en la exploración de enfoques metodológicos. No se realizó un metaanálisis, ya que el objetivo principal fue evaluar la replicabilidad y la precisión de los resultados obtenidos en los estudios analizados.

La estrategia de búsqueda se estructuró utilizando el modelo PICO, que consiste en definir cuatro componentes fundamentales para desarrollar una pregunta de investigación sólida y guiar el proceso de selección de estudios relevantes. PICO se compone de Problema (P), que describe el contexto o situación que se aborda en la investigación; Intervención (I), que detalla las estrategias o metodologías empleadas para enfrentar el problema; Comparación (C), que especifica las alternativas frente a las cuales se compara la intervención, y Resultado (O), que se refiere a los efectos o resultados que se esperan medir. Esta estructura permite una selección sistemática de los estudios y facilita la organización de la información relevante para la revisión.

Para guiar esta revisión, se formuló una pregunta de investigación utilizando la estrategia PICO, que se desglosa en los siguientes componentes:

TABLA I  
COMPONENTES DE LA ESTRATEGIA

Acrónimo	Componente
(P)roblema	Clasificación de tumores cerebrales
(I)ntervención	Técnicas de preprocessamiento (normalización, eliminación de ruido) y arquitecturas de CNN (ResNet, VGG, DenseNet).
(C)omparación	Comparación entre arquitecturas de CNN.
(O)utcome	Mejora en la precisión diagnóstica y la capacidad de clasificación.

Con base en estos componentes, se formula la siguiente interrogante de investigación: ¿Cómo influyen las técnicas de preprocessamiento y arquitecturas de CNN (I) para la clasificación de tumores cerebrales (P) en la precisión diagnóstica (O)?

Dado que la pregunta PICO abarca múltiples aspectos del problema de investigación, se formularon las siguientes subpreguntas PICO para abordar de manera detallada cada componente:

TABLA II  
SUBPREGUNTAS PICO

Acrónimo	RQ
P	¿Cuáles son las barreras que afectan la precisión y eficacia en la clasificación de tumores cerebrales?
I	¿Qué técnicas de preprocessamiento y arquitecturas de CNN se utilizan con mayor frecuencia en la clasificación de tumores cerebrales?
C	¿Cómo se comparan las diferentes arquitecturas de CNN en términos de precisión en la clasificación de tumores cerebrales?
O	¿Qué métricas se utilizan para evaluar la precisión diagnóstica y la capacidad de clasificación de las CNN en la clasificación de tumores cerebrales?

Con base en las subpreguntas PICO formuladas, se identificaron las siguientes palabras clave para guiar la búsqueda y selección de estudios relevantes:

TABLA III  
PALABRAS CLAVE DE LOS COMPONENTES DE LA PREGUNTA PICO

Acrónimo	Palabras claves
P	"brain tumors**"
I	"CNN" OR "Convolutional neural networks" OR "ResNet" OR "VGG" OR "DenseNet" OR "Preprocessing techniques"
C	"CNN architectures" OR "Preprocessing" OR "Model comparison" OR "Model performance" OR "ResNet comparison" OR "VGG comparison" OR "DenseNet comparison" OR "CNN evaluation"
O	"Accuracy" OR "Precision" OR "Evaluation metrics" OR "Specificity" OR "F1-score" OR "ROC-AUC" OR "Confusion matrix"

### B. Ecuación de búsqueda

A partir de las palabras clave identificadas, se desarrolló una ecuación de búsqueda que permitió estructurar y optimizar la recuperación de estudios relevantes de bases de datos científicas, las cuales fueron Scopus y Web of Science. Esta ecuación combina términos específicos con operadores booleanos (AND, OR, NOT) para identificar de manera precisa los artículos que abordan los componentes del modelo PICO. La búsqueda se realizó el 7 de octubre de 2024.

TABLA IV  
ECUACIÓN DE BÚSQUEDA

Scopus	Web of Science
( TITLE-ABS-KEY ( "brain tumors*" ) AND TITLE-ABS-KEY ( "CNN" OR "Convolutional neural networks" OR "ResNet" OR "VGG" OR "DenseNet" OR "Preprocessing techniques" ) AND TITLE-ABS-KEY ( "CNN architectures" OR "Preprocessing" OR "Model comparison" OR "Model performance" OR "ResNet comparison" OR "VGG comparison" OR "DenseNet comparison" OR "CNN evaluation" ) AND TITLE-ABS-KEY ( "Accuracy" OR "Precision" OR "Evaluation metrics" OR "Specificity" OR "F1-score" OR "ROC-AUC" OR "Confusion matrix" ))	( TITLE-ABS-KEY ( "brain tumors*" ) AND TITLE-ABS-KEY ( "CNN" OR "Convolutional neural networks" OR "ResNet" OR "VGG" OR "DenseNet" OR "Preprocessing techniques" ) AND TITLE-ABS-KEY ( "CNN architectures" OR "Preprocessing" OR "Model comparison" OR "Model performance" OR "ResNet comparison" OR "VGG comparison" OR "DenseNet comparison" OR "CNN evaluation" ) AND TITLE-ABS-KEY ( "Accuracy" OR "Precision" OR "Evaluation metrics" OR "Specificity" OR "F1-score" OR "ROC-AUC" OR "Confusion matrix" ))

### C. Criterios de inclusión y exclusión

Para asegurar la calidad y relevancia de los estudios seleccionados, se establecieron criterios de inclusión y exclusión. Estos criterios se diseñaron para identificar los trabajos que cumplieran con los objetivos de la investigación y garantizar la coherencia en el análisis de resultados.

**TABLA V**  
**CRITERIOS DE INCLUSIÓN Y EXCLUSIÓN**

Criterios de Inclusión	Criterios de Exclusión
CI1: Se aborda la clasificación de tumores cerebrales con arquitecturas CNN	CE1: Estudios que no presenten información suficiente sobre los datos utilizados o el procedimiento metodológico.
CI2: Los estudios utilizan metodologías de preprocesamiento antes de la intervención de los modelos	CE2: Tipos de publicaciones no originales como conferencia paper, tesis, revisiones sistemáticas de la literatura, libros universitarios o material no indexado.
CI3: Los estudios deben reportar resultados medibles como precisión, sensibilidad o especificidad de los modelos de CNN.	CE3: Estudios que solo presentan teorías o propuestas sin experimentos prácticos que respalden los resultados.

#### D. Proceso de selección de estudios

Se empleó la estrategia PRISMA, un método estandarizado que facilita la organización y documentación del proceso de identificación, selección y evaluación de estudios en revisiones sistemáticas.

En el proceso inicial de búsqueda, se identificaron un total de 373 artículos en Scopus y 75 en Web of Science, sumando un total de 448 documentos relevantes al tema de investigación. Posteriormente, se implementó la metodología PRISMA.

En la primera etapa, se identificaron y eliminaron 72 documentos duplicados, lo que resultó en 376 registros para su evaluación.

Posteriormente, se examinó el título y resumen de los 376 artículos restantes para determinar su pertinencia con la pregunta de investigación. Durante este proceso, se excluyeron 57 documentos que no cumplían con los criterios de inclusión, reduciendo así el número de estudios a 319, los cuales fueron evaluados en su totalidad.

De las 319 publicaciones evaluadas, 24 no se recuperaron a texto completo, por lo que se estableció 295 estudios para la evaluación final. Posteriormente, se aplicaron los criterios de inclusión y exclusión, lo que resultó en 103 estudios. El proceso completo de selección y filtrado se describe en detalle en la figura 1.

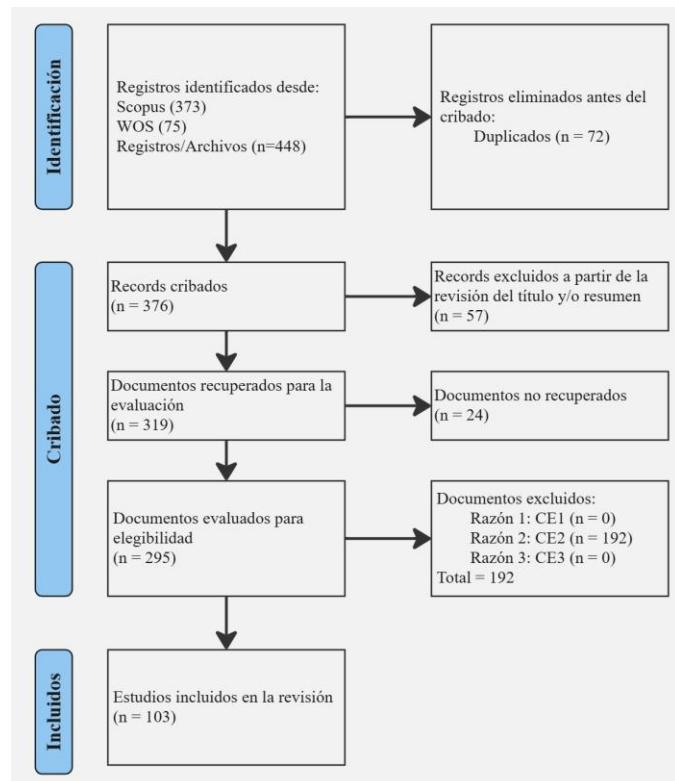


Fig. 1 Diagrama de flujo PRISMA.

### III. RESULTADOS

Los estudios revisados evidencian que el término 'CNN architecture' actúa como el nodo central en la red de palabras clave (ver Fig. 2), conectando conceptos asociados a la segmentación y clasificación de tumores cerebrales, como algorithm, sensitivity y brain tumor segmentation. Los clusters identificados en la figura destacan tres áreas principales: las arquitecturas CNN (rojo) como eje metodológico, los modelos de deep learning y métricas de evaluación (verde) con énfasis en precisión y recall, y los tipos de tumores y tratamientos (azul). Esta estructura revela la interconexión entre el desarrollo de técnicas avanzadas de aprendizaje automático y su aplicación en el diagnóstico temprano y preciso de tumores cerebrales.

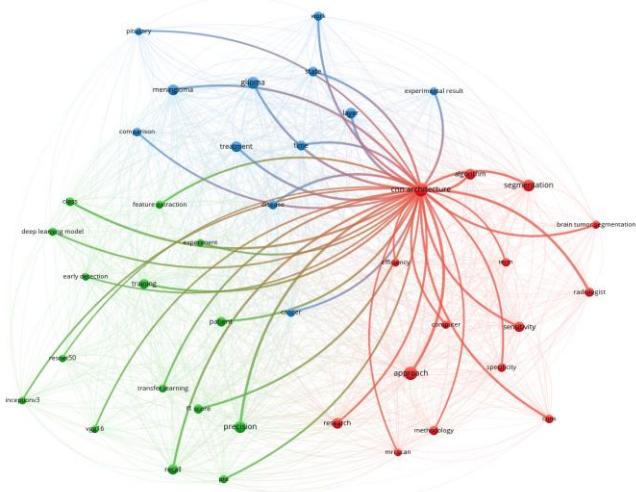


Fig. 2 Red de co-ocurrencias de palabras clave.

## A. Barreras en la precisión y eficacia de la clasificación de tumores cerebrales

En la clasificación de tumores cerebrales, los estudios han identificado diversas barreras que afectan la precisión y eficacia de los métodos actuales. La principal barrera es la variabilidad en las MRI y en los tumores, en términos de tipo, tamaño y ubicación. Esta variabilidad presenta un desafío significativo para los modelos de diagnóstico, que no siempre logran capturar la complejidad inherente a estas imágenes [7]-[71].

Además, los métodos manuales de análisis presentan limitaciones significativas, dado que son lentos y propensos a errores, lo cual restringe su eficacia en contextos donde se requiere un diagnóstico rápido y preciso [32], [34], [36], [57], [60], [62], [65], [72]-[102].

Otra barrera es la escasez de datos de calidad y las restricciones de privacidad, que dificultan el desarrollo de modelos robustos y generalizables, especialmente en el ámbito del aprendizaje profundo. La falta de acceso a datos médicos de alta calidad y las preocupaciones de privacidad asociadas limitan el potencial de los modelos de clasificación [19], [103], [104], [105].

La Fig. 3 muestra la distribución de artículos que abordan las principales barreras identificadas, destacando la dificultad en la clasificación como la más reportada.

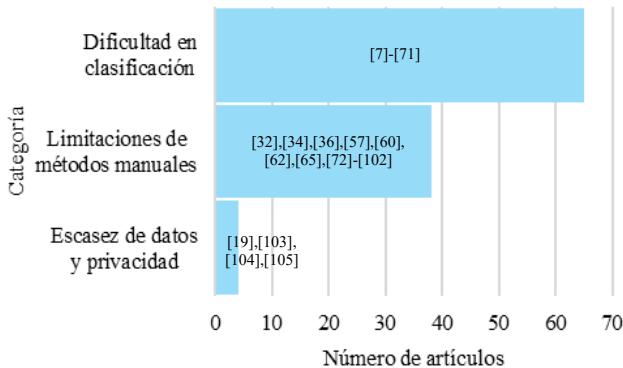


Fig. 3 Distribución de artículos por barreras en la clasificación.

#### B. Técnicas de preprocesamiento de imágenes y arquitecturas de redes neuronales convolucionales

En los estudios de clasificación de tumores cerebrales mediante CNN, se emplean diversas técnicas de preprocesamiento que mejoran la calidad de las imágenes y optimizan la precisión del modelo. La metodología más utilizadas es la normalización, que ajusta los valores de píxeles para estandarizar la apariencia de las imágenes y reducir la variabilidad entre ellas [7], [8], [10]-[12], [14], [15], [17], [19], [20], [22], [24], [27], [28], [29], [30], [41], [46], [47], [50], [52], [55]-[57], [59], [62], [65]-[69], [72]-[79], [81]-[83], [87], [89], [93], [95], [99], [100], [102]-[106].

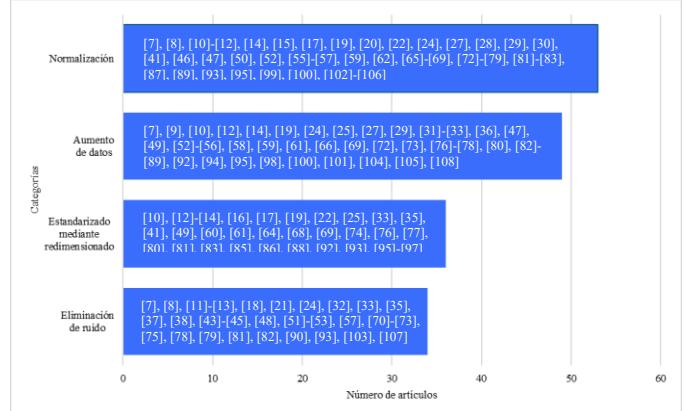


Fig. 4 Proporción de técnicas de preprocesamiento más utilizadas.

En el ámbito de las CNN, las arquitecturas más utilizadas para el procesamiento de imágenes destacan por su versatilidad y eficacia en diferentes tareas de visión por computadora. Entre estas, la CNN básica es la más común, citada en numerosos estudios. Su simplicidad y capacidad para extraer características relevantes la hacen una opción fundamental en muchos enfoques de clasificación de imágenes [7], [11]-[13], [17], [20], [24], [27], [30], [35], [36], [38], [41]-[43], [51]-[58], [62]-[64], [70], [73], [74], [78], [80], [81], [83], [84], [88], [89], [92], [94], [95], [97], [98], [101], [102], [107], [109].

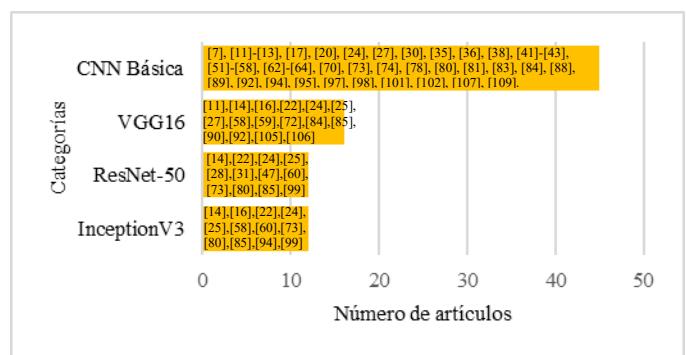


Fig. 5 Arquitecturas de redes neuronales convolucionales más utilizadas

Estos modelos representan un equilibrio entre profundidad, eficiencia y precisión, adaptándose a las crecientes demandas de procesamiento en el análisis de imágenes.

*C. Evaluación de la precisión de distintas arquitecturas CNN en la clasificación de tumores cerebrales*

La clasificación precisa de tumores cerebrales es fundamental para mejorar el diagnóstico y tratamiento en oncología. La aplicación de arquitecturas de redes neuronales convolucionales (CNN) ha mostrado avances significativos en esta tarea, permitiendo identificar patrones complejos en imágenes médicas con alta precisión. En esta evaluación, se analizan múltiples arquitecturas CNN empleadas en estudios recientes, todas con una precisión superior al 98%, resaltando su efectividad y variabilidad en métricas como la exactitud, precisión, sensibilidad (recall) y F1-score.

A continuación, se presenta una comparación detallada de estas arquitecturas de alto rendimiento. Entre los modelos destacados, se encuentran el C-DCNN con una precisión del 99% y excelentes valores en recall y F1-score, así como el EfficientNet-B4 que alcanza una exactitud de 99.33% junto con una sensibilidad perfecta (100%) y un F1-score de 99.34%. Otros modelos relevantes incluyen EfficientNetV2-M + Inception-V3 (98.41% de precisión), Res-BRNet (98.22%) y ETL\_BMRI con una precisión de 98.70%. Estos modelos no solo alcanzan altos niveles de exactitud, sino que en muchos casos presentan valores destacados en otras métricas, lo cual refuerza su potencial para aplicaciones clínicas en la clasificación de tumores cerebrales.

TABLA VI  
MODELOS SUPERIORES

Artículo	Modelo	Accuracy	Precision	Recall	F1-Score
[9]	EfficientNetV2-M + Inception-V3	98.41%	98%	98%	98%
[10]	Brain-GCN-Net	99.33%	-	-	-
[12]	CNN personalizado	-	99%	100%	-
[13]	BCNN	99.40%	99.32%	99.45%	99.34%
[14]	MobileNetV2	-	99.96%	-	-
[15]	EfficientNetB2	-	99.83%	-	-
[16]	VGG16 ajustado	98%	98%	98%	97%
[17]	CNN optimizada	-	98.20%	99.20%	-
[18]	VGG-19	98.15%	98.30%	98.70%	98.10%
[19]	VGG16	98%	-	-	-
[21]	PDCNN	-	98.67%	-	-
[26]	FE1-UT	-	98.19%	96.18%	98.19%
[30]	CNN	-	99.30%	99.15%	99.78%
[38]	GoogLeNet	99.45%	-	-	-
[41]	Modelo Optimizado CNN	98.70%	-	98.66%	98.66%
[44]	BrainNet-7	-	98.43%	-	-
[45]	BTFSC-Net	-	99.46%	-	-
[46]	U-Net based	-	98.74%	92.30%	-
[47]	ResNet50 based	99.80%	99.10%	99.70%	99.40%

[49]	MIDNet18	-	98.78%	98.78%	98.79%
[53]	Dense EfficientNet	-	98.78%	-	-
[60]	NASNet	-	99.60%	-	-
[61]	Multicanal basada en Faster R-CNN	-	99.80%	-	-
[68]	MobileNet	98.66%	99%	98.36%	98.68%
[71]	BTNet	98.23%	-	-	-
[76]	EfficientNet-B4	99.33%	98.68%	100%	99.34%
[78]	IPC-CNN	99.70%	99.40%	99.40%	98.90%
[79]	CNN hibrida	98.64%	-	-	-
[81]	Whale + CNN	98.90%	98%	100%	99%
[82]	EfficientNetv2+Ranger	-	99.85%	-	98.21%
[85]	BrainTumorNet	-	98.66%	-	97.69%
[88]	CNN propuesto	98.69%	98.32%	98.96%	98.63%
[89]	CNN-KNN	99.59%	99.59%	99.58%	99.58%
[93]	BW-VGG19	98%	-	-	-
[96]	Modified-VGGNet	99.50%	99.70%	98.80%	98.50%
[97]	CNN modificado	98.27%	98.20%	-	-
[98]	NN+FL-MSCM	99.58%	-	-	99.68%
[99]	Xception	98.51%	98.79%	-	98.67%
[100]	MIDNet18	-	98.78%	98.78%	98.79%
[102]	U-Net CNN 3D	-	98.98%	-	-
[103]	C-DCNN	99%	-	99%	99%
[104]	ETL_BMRI - Accuracy	98.70%	-	-	-
[106]	VGG16	-	98.92%	-	-
[108]	Res-BRNet	98.22%	-	98.11%	96.41%

Este análisis permite identificar los modelos más prometedores y comprender cómo sus características específicas contribuyen al éxito en la tarea de clasificación de tumores, proporcionando un marco comparativo útil para futuras implementaciones en entornos médicos.

*D. Principales métricas para evaluar la precisión diagnóstica y la eficacia de clasificación*

Para evaluar las CNN en la clasificación de tumores cerebrales, se emplean diversas métricas que permiten medir la precisión diagnóstica y la capacidad de clasificación del modelo. La precisión (accuracy), ampliamente utilizada, indica la proporción de predicciones correctas sobre el total [7]-[31], [32]-[44], [46]-[49], [51]-[56], [58]-[64], [66]-[99], [101]-[109].

Entre las menos comunes, Dice Score mide la superposición de áreas en segmentación, útil en la detección de regiones tumorales específicas pero menos en clasificación general [20], [26], [29], [46], [50], [55], [57], [62], [63], [65], [66], [70], [71], [91], [98]. Igualmente, el Índice Kappa evalúa

la concordancia entre las predicciones del modelo y las etiquetas reales, ajustando por el azar y brindando una medida de consistencia en modelos de clasificación [26], [29], [35], [60], [82], [90].

Seleccionar métricas adecuadas como precisión, sensibilidad, especificidad y AUC permite una evaluación completa de las CNN en diagnóstico de tumores cerebrales, mientras que métricas como el Dice Score e Índice de Jaccard, aunque menos frecuentes, resultan útiles en tareas específicas de segmentación.

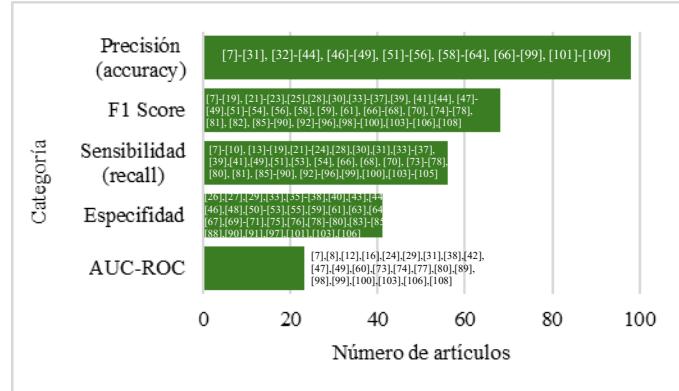


Fig. 6 Número de artículos con las métricas más utilizadas

#### IV. DISCUSIÓN

Este estudio ha evaluado el impacto de la clasificación de los tumores cerebrales en imágenes de resonancia magnética mediante el uso de diversas redes neuronales convolucionales (CNN). Las arquitecturas más destacadas, como ResNet-50, VGG16 y EfficientNet-B4, han demostrado una alta precisión en la clasificación, alcanzando niveles superiores al 98%. Estos resultados subrayan la eficacia de las CNN en el diagnóstico de tumores cerebrales, lo que sugiere su potencial para ser implementadas en entornos clínicos.

Los hallazgos de este estudio son significativos porque demuestran que las CNN pueden mejorar considerablemente la precisión y eficiencia del diagnóstico de tumores cerebrales. La alta precisión alcanzada por las arquitecturas evaluadas indica que estas redes pueden identificar patrones complejos en las imágenes de MRI, lo que es crucial para la detección temprana y el tratamiento efectivo de los tumores cerebrales.

En comparación con otros estudios, este trabajo identificó que EfficientNet-B4 alcanzó una precisión del 99.33%, mientras que [110] reportó una precisión ligeramente superior (99.5%) al combinar EfficientNetB0 con Support Vector Machine (SVM). Esta diferencia puede atribuirse a que en [110] se utilizaron técnicas avanzadas de extracción de características mediante modelos adicionales, como Random Forest y K-Nearest Neighbours. Sin embargo, en dicho estudio no se empleó normalización, lo que podría haber afectado la capacidad del modelo para generalizar a otros conjuntos de datos. En contraste, este estudio implementó normalización y

aumento de datos, lo que contribuyó a una mejor estabilidad y precisión del modelo en contextos más variados.

Por otro lado, ResNet-50 alcanzó una precisión del 98% en este estudio, mientras que [111] reportó un rendimiento comparable utilizando VGG16 con el optimizador Adam (98%). Esta similitud se debe a que ambos trabajos optimizaron los hiperparámetros del modelo y emplearon técnicas de aumento de datos, mejorando la calidad de las imágenes y maximizando la extracción de características relevantes. Sin embargo, [111] también destaca que la dependencia del modelo en configuraciones específicas de hiperparámetros podría haber limitado su adaptabilidad a otros conjuntos de datos, lo que refuerza la importancia de validar estas configuraciones en múltiples contextos clínicos.

En [112], se evaluaron EfficientNetB3, ResNet-50 y VGG19, mostrando diferencias significativas en sus desempeños. EfficientNetB3 alcanzó una precisión de entrenamiento del 99.44%, pero su precisión de validación cayó al 89.47%, evidenciando problemas de sobreajuste. En contraste, ResNet-50 mostró un desempeño más consistente con una precisión de validación del 89.47%, mientras que VGG19 obtuvo solo un 62% de precisión. Estas diferencias se deben, en parte, al diseño de las arquitecturas y a la implementación de técnicas de preprocesamiento. En este estudio, EfficientNet-B4 y ResNet-50 superaron significativamente estos resultados, debido a la integración de técnicas avanzadas de normalización y aumento de datos que mitigaron los problemas de sobreajuste y mejoraron la capacidad de los modelos para generalizar en imágenes de resonancia magnética más variadas.

Además, esta revisión identificó barreras importantes, como la escasez de datos de alta calidad y las restricciones de privacidad, que limitan la capacidad de generalización de los modelos. Estas limitaciones también fueron señaladas en [110], [111] y [112], resaltando la necesidad de crear conjuntos de datos estandarizados y accesibles. En particular, las diferencias en la calidad y el tamaño de las bases de datos utilizadas en estos estudios explican parte de las variaciones observadas en los resultados.

Por último, la falta de normalización en algunos estudios revisados podría haber contribuido a una menor precisión, ya que los modelos tienen dificultades para aprender características relevantes si los datos de entrada no están estandarizados. En este estudio, la implementación de normalización y técnicas avanzadas de preprocesamiento fue clave para mejorar la precisión y la capacidad de generalización de los modelos.

En resumen, esta investigación demuestra que las arquitecturas de CNN como ResNet-50 y EfficientNet-B4 son altamente efectivas para la clasificación de tumores cerebrales cuando se combinan con técnicas de preprocesamiento adecuadas. Sin embargo, superar las barreras relacionadas con la calidad y disponibilidad de datos sigue siendo un reto fundamental. Las futuras investigaciones deben centrarse en mejorar la disponibilidad de datos, optimizar las técnicas de

preprocesamiento y validar los modelos en múltiples contextos para lograr una clasificación más precisa y generalizable.

## V. CONCLUSIONES

En esta revisión sistemática se analizaron las arquitecturas de redes neuronales convolucionales y las técnicas de preprocesamiento más utilizadas en la clasificación de tumores cerebrales mediante imágenes de resonancia magnética. Se identificaron barreras, metodologías y métricas que permiten evaluar el rendimiento de estas arquitecturas en contextos médicos.

Entre los principales resultados, se identificó que las arquitecturas ResNet-50 y EfficientNet-B4 son las más eficientes, alcanzando niveles de precisión entre el 98% y el 99.33%, mientras que otras arquitecturas como VGG16 ajustado lograron precisiones de hasta el 98%. Además, el uso de técnicas de normalización y eliminación de ruido mejoró significativamente la calidad de las imágenes, facilitando la reducción de la variabilidad en las mismas, lo que a su vez aumentó la precisión de los modelos. En este contexto, la normalización se refiere al ajuste de los valores de las imágenes para que estén dentro de un rango estándar, mientras que la eliminación de ruido se enfoca en eliminar detalles innecesarios o defectos que pueden dificultar la interpretación de la imagen. En imágenes médicas, el ruido puede ser cualquier cosa que haga más difícil ver claramente las estructuras importantes, como interferencias causadas por el equipo o las condiciones del entorno durante la captura.

El aumento de datos mediante transformaciones como rotación y escalado también contribuyó a mejorar la generalización de los modelos, disminuyendo el riesgo de sobreajuste. Estos resultados subrayan la importancia de las técnicas de preprocesamiento en el éxito de las arquitecturas de redes neuronales convolucionales para la clasificación de tumores cerebrales.

Aunque se observaron avances significativos en el uso de arquitecturas CNN para la clasificación de tumores, existen barreras importantes que deben abordarse. La escasez de datos de alta calidad, debido a restricciones de privacidad, y la variabilidad en las imágenes representan limitaciones que afectan la consistencia y la capacidad de generalización de los modelos. En consecuencia, se sugiere que futuras investigaciones se enfoquen en el desarrollo de conjuntos de datos estandarizados y en la aplicación de enfoques colaborativos para superar las restricciones de acceso a datos.

En conclusión, la revisión muestra que las arquitecturas ResNet-50 y EfficientNet-B4 presentan un rendimiento destacado en la clasificación de tumores cerebrales, especialmente cuando se combinan con técnicas de preprocesamiento adecuadas. Sin embargo, la necesidad de superar las barreras relacionadas con la calidad y disponibilidad de datos sigue siendo un reto fundamental para la aplicabilidad clínica de estos modelos. Las futuras investigaciones deben centrarse en mejorar la disponibilidad

de datos y en optimizar las técnicas de preprocesamiento para lograr una clasificación más precisa y generalizable.

## REFERENCIAS

- [1] H. Yu, L. T. Yang, Q. Zhang, D. Armstrong, and M. J. Deen, “Convolutional neural networks for medical image analysis: State-of-the-art, comparisons, improvement and perspectives,” *Neurocomputing*, vol. 444, pp. 92–110, Jul. 2021, doi: 10.1016/j.neucom.2020.04.157.
- [2] Y. Xie et al., “Convolutional Neural Network Techniques for Brain Tumor Classification (from 2015 to 2022): Review, Challenges, and Future Perspectives,” *Diagnostics*, vol. 12, no. 8, pp. 1850–1895, Jul. 2022, doi: 10.3390/diagnostics12081850.
- [3] D. Reyes and J. Sánchez, “Performance of convolutional neural networks for the classification of brain tumors using magnetic resonance imaging,” *Heliyon*, vol. 10, no. 3, pp. e25468–e25489, Feb. 2024, doi: 10.1016/J.HELIYON.2024.E25468.
- [4] K. N. Rao et al., “An efficient brain tumor detection and classification using pre-trained convolutional neural network models,” *Heliyon*, vol. 10, no. 17, pp. e36773–e36790, Sep. 2024, doi: 10.1016/J.HELIYON.2024.E36773.
- [5] A. Muis, S. Sunardi, and A. Yudhana, “CNN-based Approach for Enhancing Brain Tumor Image Classification Accuracy,” *International Journal of Engineering*, vol. 37, no. 5, pp. 984–996, 2024, doi: 10.5829/IJE.2024.37.05B.15.
- [6] B. H. Menze et al., “The Multimodal Brain Tumor Image Segmentation Benchmark (BRATS),” *IEEE Transactions on Medical Imaging*, vol. 34, no. 10, pp. 1993–2024, Oct. 2015, doi: 10.1109/TMI.2014.2377694.
- [7] M. Aamir et al., “Brain Tumor Detection and Classification Using an Optimized Convolutional Neural Network,” *Diagnostics*, vol. 14, no. 16, pp. 1714–1732, Aug. 2024, doi: 10.3390/diagnostics14161714.
- [8] K. S. and A. S., “Improved Glioma Detection and Classification through the EVGG19 Model,” *International Journal of Electronics and Communication Engineering*, vol. 11, no. 8, pp. 282–293, Aug. 2024, doi: 10.14445/23488549/IJECE-V11I8P127.
- [9] R. İncir and F. Bozkurt, “Improving brain tumor classification with combined convolutional neural networks and transfer learning,” *Knowledge-Based Systems*, vol. 299, pp. 111981–111995, Sep. 2024, doi: 10.1016/j.knosys.2024.111981.
- [10] E. Gürsoy and Y. Kaya, “Brain-GCN-Net: Graph-Convolutional Neural Networks for brain tumor identification,” *Computers in Biology and Medicine*, vol. 180, pp. 108971–108988, Sep. 2024, doi: 10.1016/j.combiomed.2024.108971.
- [11] S. ben Brahim, S. Dardouri, and R. Bouallegue, “Brain Tumor Detection Using a Deep CNN Model,” *Applied Computational Intelligence and Soft Computing*, vol. 2024, no. 1, pp. 1–15, Jan. 2024, doi: 10.1155/2024/7634426.
- [12] E. Albalawi et al., “Enhancing brain tumor classification in MRI scans with a multi-layer customized convolutional neural network approach,” *Frontiers in Computational Neuroscience*, vol. 18, pp. 1–19, Jun. 2024, doi: 10.3389/fncom.2024.1418546.
- [13] L. Kiran et al., “An enhanced pattern detection and segmentation of brain tumors in MRI images using deep learning technique,” *Frontiers in Computational Neuroscience*, vol. 18, pp. 1–17, Jun. 2024, doi: 10.3389/fncom.2024.1418280.
- [14] S. M. Rasa et al., “Brain tumor classification using fine-tuned transfer learning models on magnetic resonance imaging (MRI) images,” *DIGITAL HEALTH*, vol. 10, pp. 1–31, Jan. 2024, doi: 10.1177/20552076241286140.
- [15] A. M. J. Zubair Rahman et al., “Advanced AI-driven approach for enhanced brain tumor detection from MRI images utilizing EfficientNetB2 with equalization and homomorphic filtering,” *BMC Medical Informatics and Decision Making*, vol. 24, no. 1, p. 113–131, Apr. 2024, doi: 10.1186/s12911-024-02519-x.
- [16] M. Z. Khaliki and M. S. Başarşlan, “Brain tumor detection from images and comparison with transfer learning methods and 3-layer CNN,” *Scientific Reports*, vol. 14, no. 1, pp. 2664–2673, Feb. 2024, doi: 10.1038/s41598-024-52823-9.
- [17] R. Martínez-Del-Río-Ortega, J. Civit-Masot, F. Luna-Perejón, and M. Domínguez-Morales, “Brain Tumor Detection Using Magnetic Resonance Imaging and Convolutional Neural Networks,” *Big Data and*

- Cognitive Computing*, vol. 8, no. 9, pp. 123–139, Sep. 2024, doi: 10.3390/bdcc8090123.
- [18] J. Paul, J. C. J. and S. T.S, “Enhancing Brain Tumor Classification with VGG-19 in Deep Learning Paradigms,” *International Journal of Electronics and Communication Engineering*, vol. 11, no. 4, pp. 41–50, Apr. 2024, doi: 10.14445/23488549/IJCE-V11I4P105.
- [19] E. Albalawi *et al.*, “Integrated approach of federated learning with transfer learning for classification and diagnosis of brain tumor,” *BMC Medical Imaging*, vol. 24, no. 1, pp. 110–124, May 2024, doi: 10.1186/s12880-024-01261-0.
- [20] R. K., S. Rajagopal, M. B. Kulkarni, and H. Poddar, “A hyperdimensional framework: Unveiling the interplay of RBP and GSN within CNNs for ultra-precise brain tumor classification,” *Biomedical Signal Processing and Control*, vol. 96, pp. 106565–106572, Oct. 2024, doi: 10.1016/j.bspc.2024.106565.
- [21] T. Rahman, M. S. Islam, and J. Uddin, “MRI-Based Brain Tumor Classification Using a Dilated Parallel Deep Convolutional Neural Network,” *Digital*, vol. 4, no. 3, pp. 529–554, Jun. 2024, doi: 10.3390/digital4030027.
- [22] D. S. Wankhede, C. J. Shelke, V. K. Shrivastava, R. Achary, and S. N. Mohanty, “Brain Tumor Detection and Classification Using Adjusted InceptionV3, AlexNet, VGG16, VGG19 with ResNet50-152 CNN Model,” *EAI Endorsed Transactions on Pervasive Health and Technology*, vol. 10, pp. 1–10 Jun. 2024, doi: 10.4108/eptph.10.6377.
- [23] S. Tabatabaei, K. Rezaee, and M. Zhu, “Attention transformer mechanism and fusion-based deep learning architecture for MRI brain tumor classification system,” *Biomedical Signal Processing and Control*, vol. 86, pp. 105119–105131, Sep. 2023, doi: 10.1016/j.bspc.2023.105119.
- [24] M. I. Mahmud, M. Mamun, and A. Abdalgawad, “A Deep Analysis of Brain Tumor Detection from MR Images Using Deep Learning Networks,” *Algorithms*, vol. 16, no. 4, p. 176–194, Mar. 2023, doi: 10.3390/a16040176.
- [25] A. K. Bitto, Md. H. I. Bijoy, S. Yesmin, I. Mahmud, Md. J. Mia, and K. B. B. Biplob, “Tumor-Net: convolutional neural network modeling for classifying brain tumors from MRI images,” *International Journal of Advances in Intelligent Informatics*, vol. 9, no. 2, pp. 148–160, Apr. 2023, doi: 10.26555/ijain.v9i2.872.
- [26] A. H. Nizamani, Z. Chen, A. A. Nizamani, and K. Shaheed, “Feature-enhanced fusion of U-NET-based improved brain tumor images segmentation,” *Journal of Cloud Computing*, vol. 12, no. 1, pp. 170–187, Dec. 2023, doi: 10.1186/s13677-023-00554-z.
- [27] T. N. Papadomanolakis *et al.*, “Tumor Diagnosis against Other Brain Diseases Using T2 MRI Brain Images and CNN Binary Classifier and DWT,” *Brain Sciences*, vol. 13, no. 2, pp. 348–372, Feb. 2023, doi: 10.3390/brainsci13020348.
- [28] A. A. Asiri *et al.*, “Brain Tumor Detection and Classification Using Fine-Tuned CNN with ResNet50 and U-Net Model: A Study on TCGA-LGG and TCIA Dataset for MRI Applications,” *Life*, vol. 13, no. 7, pp. 1449–1464, Jun. 2023, doi: 10.3390/life13071449.
- [29] S. J. Malebary, “Intelligent Machine Learning Based Brain Tumor Segmentation through Multi-Layer Hybrid U-Net with CNN Feature Integration,” *Computers, Materials & Continua*, vol. 79, no. 1, pp. 1301–1317, 2024, doi: 10.32604/cmc.2024.047917.
- [30] “Batch Normalization Based Convolutional Neural Network for Segmentation and Classification of Brain Tumor MRI Images,” *International Journal of Intelligent Engineering and Systems*, vol. 17, no. 2, pp. 39–49, Apr. 2024, doi: 10.22266/ijies2024.0430.04.
- [31] M. Angurala, “Augmented MRI Images for Classification of Normal and Tumors Brain through Transfer Learning Techniques,” *International Journal on Recent and Innovation Trends in Computing and Communication*, vol. 11, no. 5s, pp. 536–542, Jun. 2023, doi: 10.17762/ijritcc.v11i5s.7130.
- [32] V. S. Yilmaz, M. Akdag, Y. Dalveren, R. O. Doruk, A. Kara, and A. Soylu, “Investigating the Impact of Two Major Programming Environments on the Accuracy of Deep Learning-Based Glioma Detection from MRI Images,” *Diagnostics*, vol. 13, no. 4, p. 651–665, Feb. 2023, doi: 10.3390/diagnostics13040651.
- [33] H. M. T. Khushi, T. Masood, A. Jaffar, M. Rashid, and S. Akram, “Improved Multiclass Brain Tumor Detection via Customized Pretrained EfficientNetB7 Model,” *IEEE Access*, vol. 11, pp. 117210–117230, 2023, doi: 10.1109/ACCESS.2023.3325883.
- [34] A. Mahesh, D. Banerjee, A. Saha, M. Ranjan Prusty, and A. Balasundaram, “CE-EEN-B0: Contour Extraction Based Extended EfficientNet-B0 for Brain Tumor Classification Using MRI Images,” *Computers, Materials & Continua*, vol. 74, no. 3, pp. 5967–5982, 2023, doi: 10.32604/cmc.2023.033920.
- [35] A. Sarkar, Md. Maniruzzaman, M. A. Alahe, and M. Ahmad, “An Effective and Novel Approach for Brain Tumor Classification Using AlexNet CNN Feature Extractor and Multiple Eminent Machine Learning Classifiers in MRIs,” *Journal of Sensors*, vol. 2023, no. 1, pp. 1–19, Jan. 2023, doi: 10.1155/2023/1224619.
- [36] “MRI Brain Tumor Detection Using Boosted Crossbred Random Forests and Chimp Optimization Algorithm Based Convolutional Neural Networks,” *International Journal of Intelligent Engineering and Systems*, vol. 15, no. 2, pp. 36–46, Apr. 2022, doi: 10.22266/ijies2022.0430.04.
- [37] G. S. Sunsuhi and S. Albin Jose, “An Adaptive Eroded Deep Convolutional neural network for brain image segmentation and classification using Inception ResnetV2,” *Biomedical Signal Processing and Control*, vol. 78, pp. 103863–103875, Sep. 2022, doi: 10.1016/j.bspc.2022.103863.
- [38] C. Swarup, K. Udhām Singh, A. Kumar, S. Kumar Pandey, N. Varshney, and T. Singh, “Brain tumor detection using CNN, AlexNet & GoogLeNet ensembling learning approaches,” *Electronic Research Archive*, vol. 31, no. 5, pp. 2900–2924, 2023, doi: 10.3934/era.2023146.
- [39] A. Raza *et al.*, “A Hybrid Deep Learning-Based Approach for Brain Tumor Classification,” *Electronics*, vol. 11, no. 7, pp. 1146–1162, Apr. 2022, doi: 10.3390/electronics11071146.
- [40] R. Vankdethu, M. A. Hameed, A. Ameen, and R. Unnisa, “Brain image identification and classification on Internet of Medical Things in healthcare system using support value based deep neural network,” *Computers and Electrical Engineering*, vol. 102, p. 108196–108211, Sep. 2022, doi: 10.1016/j.compeleceng.2022.108196.
- [41] M. Ait Amou, K. Xia, S. Kamhi, and M. Mouhafid, “A Novel MRI Diagnosis Method for Brain Tumor Classification Based on CNN and Bayesian Optimization,” *Healthcare*, vol. 10, no. 3, pp. 494–514, Mar. 2022, doi: 10.3390/healthcare10030494.
- [42] A. A. Mahmood, S. Sadeq, Y. I. Aljanabi, and A. H. Sabry, “Developing a convolutional neural network for classifying tumor images using Inception v3,” *Eastern-European Journal of Enterprise Technologies*, vol. 3, no. 9 (123), pp. 86–93, Jun. 2023, doi: 10.15587/1729-4061.2023.281227.
- [43] R. Vankdethu and M. A. Hameed, “Brain tumor MRI images identification and classification based on the recurrent convolutional neural network,” *Measurement: Sensors*, vol. 24, pp. 100412–100422, Dec. 2022, doi: 10.1016/j.measen.2022.100412.
- [44] M. H. or Rashid, S. Akter, and A. B. Akhi, “BrainNet-7: A CNN Model for Diagnosing Brain Tumors from MRI Images based on an Ablation Study,” *International Journal of Advanced Computer Science and Applications*, vol. 13, no. 12, pp. 514–581, 2022, doi: 10.14569/IJACSA.2022.0131270.
- [45] A. S. Yadav *et al.*, “A Feature Extraction Using Probabilistic Neural Network and BTFS-Net Model with Deep Learning for Brain Tumor Classification,” *Journal of Imaging*, vol. 9, no. 1, pp. 10–31, Dec. 2022, doi: 10.3390/jimaging9010010.
- [46] R. Ghulam *et al.*, “A U-Net-Based CNN Model for Detection and Segmentation of Brain Tumor,” *Computers, Materials & Continua*, vol. 74, no. 1, pp. 1333–1349, 2023, doi: 10.32604/cmc.2023.031695.
- [47] M. Ahmed, F. Khalifa, H. El-Din Moustafa, G. Ahmed Saleh, and E. AbdElhalim, “A deep learning based system for accurate diagnosis of brain tumors using T1-w MRI,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 28, no. 2, p. 1192, Nov. 2022, doi: 10.11591/ijeeics.v28.i2.pp1192-1202.
- [48] A. S. Musallam, A. S. Sherif, and M. K. Hussein, “A New Convolutional Neural Network Architecture for Automatic Detection of Brain Tumors in Magnetic Resonance Imaging Images,” *IEEE Access*, vol. 10, pp. 2775–2782, 2022, doi: 10.1109/ACCESS.2022.3140289.
- [49] “Brain tumour classification of Magnetic resonance images using a novel CNN based Medical Image Analysis and Detection network in comparison with VGG16,” *Journal of Population Therapeutics and*

- Clinical Pharmacology*, vol. 28, no. 2, pp. e113–e125 Jan. 2022, doi: 10.47750/jptcp.2022.873.
- [50] S. Sajid, S. Hussain, and A. Sarwar, “Brain Tumor Detection and Segmentation in MR Images Using Deep Learning,” *Arabian Journal for Science and Engineering*, vol. 44, no. 11, pp. 9249–9261, Nov. 2019, doi: 10.1007/s13369-019-03967-8.
- [51] H. Abdullah Mengash and H. A. Hosni Mahmoud, “Brain Cancer Tumor Classification from Motion-Corrected MRI Images Using Convolutional Neural Network,” *Computers, Materials & Continua*, vol. 68, no. 2, pp. 1551–1563, 2021, doi: 10.32604/cmc.2021.016907.
- [52] A. Gurunathan and B. Krishnan, “Detection and diagnosis of brain tumors using deep learning convolutional neural networks,” *International Journal of Imaging Systems and Technology*, vol. 31, no. 3, pp. 1174–1184, Sep. 2021, doi: 10.1002/ima.22532.
- [53] D. R. Nayak, N. Padhy, P. K. Mallick, M. Zymbler, and S. Kumar, “Brain Tumor Classification Using Dense Efficient-Net,” *Axioms*, vol. 11, no. 1, pp. 34–46, Jan. 2022, doi: 10.3390/axioms11010034.
- [54] S. S. Roy, N. Rodrigues, and Y. Taguchi, “Incremental Dilations Using CNN for Brain Tumor Classification,” *Applied Sciences*, vol. 10, no. 14, pp. 4915–4928, Jul. 2020, doi: 10.3390/app10144915.
- [55] A. Rehman, M. A. Khan, T. Saba, Z. Mehmood, U. Tariq, and N. Ayesha, “Microscopic brain tumor detection and classification using 3D CNN and feature selection architecture,” *Microscopy Research and Technique*, vol. 84, no. 1, pp. 133–149, Jan. 2021, doi: 10.1002/jemt.23597.
- [56] M. M. Badža and M. Č. Barjaktarović, “Classification of Brain Tumors from MRI Images Using a Convolutional Neural Network,” *Applied Sciences*, vol. 10, no. 6, pp. 1999–2011, Mar. 2020, doi: 10.3390/app10061999.
- [57] J. Chang *et al.*, “A mix-pooling CNN architecture with FCRF for brain tumor segmentation,” *Journal of Visual Communication and Image Representation*, vol. 58, pp. 316–322, Jan. 2019, doi: 10.1016/j.jvcir.2018.11.047.
- [58] H. el Hamdaoui *et al.*, “High precision brain tumor classification model based on deep transfer learning and stacking concepts,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 24, no. 1, pp. 167–177, Oct. 2021, doi: 10.11591/ijeecs.v24.i1.pp167-177.
- [59] M. Purnomo, “Brain Tumor Classification in MRI Images Using En-CNN,” *International Journal of Intelligent Engineering and Systems*, vol. 14, no. 4, pp. 437–451, Aug. 2021, doi: 10.22266/ijies2021.0831.38.
- [60] T. Sadad *et al.*, “Brain tumor detection and multi-classification using advanced deep learning techniques,” *Microscopy Research and Technique*, vol. 84, no. 6, pp. 1296–1308, Jun. 2021, doi: 10.1002/jemt.23688.
- [61] A. YILMAZ, “Brain tumor detection from MRI images with using proposed deep learning model: the partial correlation-based channel selection,” *TURKISH JOURNAL OF ELECTRICAL ENGINEERING & COMPUTER SCIENCES*, vol. 29, no. SI-1, pp. 2615–2633, Oct. 2021, doi: 10.3906/elk-2103-37.
- [62] M. I. Razzak, M. Imran, and G. Xu, “Efficient Brain Tumor Segmentation With Multiscale Two-Pathway-Group Conventional Neural Networks,” *IEEE Journal of Biomedical and Health Informatics*, vol. 23, no. 5, pp. 1911–1919, Sep. 2019, doi: 10.1109/JBHI.2018.2874033.
- [63] I. A. el Kader, G. Xu, Z. Shuai, and S. Saminu, “Brain Tumor Detection and Classification by Hybrid CNN-DWA Model Using MR Images,” *Current Medical Imaging Formerly Current Medical Imaging Reviews*, vol. 17, no. 10, pp. 1248–1255, Oct. 2021, doi: 10.2174/1573405617666210224113315.
- [64] T. A. Sadoon and M. H. Ali, “Deep learning model for glioma, meningioma and pituitary classification,” *International Journal of Advances in Applied Sciences*, vol. 10, no. 1, p. 88–98, Mar. 2021, doi: 10.11591/ijaas.v10.i1.pp88-98.
- [65] Y. Zhuge *et al.*, “Brain tumor segmentation using holistically nested neural networks in MRI images,” *Medical Physics*, vol. 44, no. 10, pp. 5234–5243, Oct. 2017, doi: 10.1002/mp.12481.
- [66] H. M. Rai, K. Chatterjee, and S. Dashkevich, “Automatic and accurate abnormality detection from brain MR images using a novel hybrid UnetResNext-50 deep CNN model,” *Biomedical Signal Processing and Control*, vol. 66, pp. 102477–102490, Apr. 2021, doi: 10.1016/j.bspc.2021.102477.
- [67] I. Abd El Kader, G. Xu, Z. Shuai, S. Saminu, I. Javaid, and I. Salim Ahmad, “Differential Deep Convolutional Neural Network Model for Brain Tumor Classification,” *Brain Sciences*, vol. 11, no. 3, pp. 352–367, Mar. 2021, doi: 10.3390/brainsci11030352.
- [68] M. Bhasin *et al.*, “Unveiling the Hidden: Leveraging Medical Imaging Data for Enhanced Brain Tumor Detection Using CNN Architectures,” *Traitemen du Signal*, vol. 41, no. 03, pp. 1575–1582, Jun. 2024, doi: 10.18280/ts.410345.
- [69] M. Alnowami, E. Taha, S. Alsebaeai, S. Muhammad Anwar, and A. Alhawsawi, “MR image normalization dilemma and the accuracy of brain tumor classification model,” *Journal of Radiation Research and Applied Sciences*, vol. 15, no. 3, pp. 33–39, Sep. 2022, doi: 10.1016/j.jrras.2022.05.014.
- [70] “Brain Tumor Detection Based on Amended Convolution Neural Network Using MRI Images,” *KSII Transactions on Internet and Information Systems*, vol. 17, no. 10, pp. 2788–2808 Oct. 2023, doi: 10.3837/tiis.2023.10.011.
- [71] M. Almukhtar, A. H. Morad, H. L. Hussein, and M. H. Al-hashimi, “Brain Tumor Segmentation Using Enhancement Convolved and Deconvolved CNN Model,” *ARO-THE SCIENTIFIC JOURNAL OF KOYA UNIVERSITY*, vol. 12, no. 1, pp. 88–99, Mar. 2024, doi: 10.14500/aro.11333.
- [72] S. S. Dip, Md. H. Rahman, N. Islam, Md. E. Arafat, P. K. Bhowmick, and M. A. Yousuf, “Enhancing Brain Tumor Classification in MRI: Leveraging Deep Convolutional Neural Networks for Improved Accuracy,” *International Journal of Information Technology and Computer Science*, vol. 16, no. 3, pp. 12–21, Jun. 2024, doi: 10.5815/ijitcs.2024.03.02.
- [73] L. C. Sekhar Reddy, M. Elangovan, M. Vamsikrishna, and C. Ravindra, “Brain Tumor Detection and Classification Using Deep Learning Models on MRI Scans,” *EAI Endorsed Transactions on Pervasive Health and Technology*, vol. 10, pp. 1–7, Mar. 2024, doi: 10.4108/eetph.10.5553.
- [74] R. Kaifi, “Enhancing brain tumor detection: a novel CNN approach with advanced activation functions for accurate medical imaging analysis,” *Frontiers in Oncology*, vol. 14, pp. 1–17, Sep. 2024, doi: 10.3389/fonc.2024.1437185.
- [75] S. Kakarwal *et al.*, “Enhanced Detection and Segmentation of Brain Tumors Using a Dense BW-CNN Approach,” *Journal of Engineering*, vol. 2024, no. 1, pp. 1–14 Jan. 2024, doi: 10.1155/2024/1622294.
- [76] R. Preetha, M. J. P. Priyadarsini, and J. S. Nisha, “Automated Brain Tumor Detection From Magnetic Resonance Images Using Fine-Tuned EfficientNet-B4 Convolutional Neural Network,” *IEEE Access*, vol. 12, pp. 112181–112195, 2024, doi: 10.1109/ACCESS.2024.3442979.
- [77] A. Alshuhail *et al.*, “Refining neural network algorithms for accurate brain tumor classification in MRI imagery,” *BMC Medical Imaging*, vol. 24, no. 1, pp. 118–137, May 2024, doi: 10.1186/s12880-024-01285-6.
- [78] “IPC-CNN: A Robust Solution for Precise Brain Tumor Segmentation Using Improved Privacy-Preserving Collaborative Convolutional Neural Network,” *KSII Transactions on Internet and Information Systems*, vol. 18, no. 9, pp. 2589–2604 Sep. 2024, doi: 10.3837/tiis.2024.09.007.
- [79] S. Ponnupilla Omana, J. A. Dar, T. Rajesh Kumar, A. K. Sampath, and S. Sharma, “Henry gas bird swarm optimization algorithm-based deep learning for brain tumor classification using magnetic resonance imaging,” *Concurrency and Computation: Practice and Experience*, vol. 35, no. 4, Feb. 2023, doi: 10.1002/cpe.7541.
- [80] S. Fooladi, H. Farsi, and S. Mohamadzadeh, “Segmenting the Lesion Area of Brain Tumor using Convolutional Neural Networks and Fuzzy K-Means Clustering,” *International Journal of Engineering*, vol. 36, no. 8, pp. 1556–1568, 2023, doi: 10.5829/IJE.2023.36.08.B.15.
- [81] M. A. Gómez-Guzmán *et al.*, “Classifying Brain Tumors on Magnetic Resonance Imaging by Using Convolutional Neural Networks,” *Electronics*, vol. 12, no. 4, pp. 955–976, Feb. 2023, doi: 10.3390/electronics12040955.
- [82] Y. Anagun, “Smart brain tumor diagnosis system utilizing deep convolutional neural networks,” *Multimedia Tools and Applications*, vol. 82, no. 28, pp. 44527–44553, Nov. 2023, doi: 10.1007/s11042-023-15422-w.

- [83] N. Bhardwaj, M. Sood, and S. S. Gill, "Design and Development of Hypertuned Deep learning Frameworks for Detection and Severity Grading of Brain Tumor using Medical Brain MR images," *Current Medical Imaging Formerly Current Medical Imaging Reviews*, vol. 20, pp. 1–17 Apr. 2024, doi: 10.2174/0115734056288248240309044616.
- [84] P. Alagarsamy, B. Sridharan, and V. K. Kalimuthu, "A Deep Learning Based Glioma Tumour Detection Using Efficient Visual Geometry Group Convolutional Neural Networks Architecture," *Brazilian Archives of Biology and Technology*, vol. 67, pp. 1–12 2024, doi: 10.1590/1678-4324-2024230705.
- [85] S. Banik, N. G. Barai, and F. M. J. M. Shamrat, "Blockchain Integrated Neural Networks: A New Frontier in MRI-based Brain Tumor Detection," *International Journal of Advanced Computer Science and Applications*, vol. 14, no. 11, pp. 954–964 2023, doi: 10.14569/IJACSA.2023.0141197.
- [86] T. K. Dutta, D. R. Nayak, and Y.-D. Zhang, "ARM-Net: Attention-guided residual multiscale CNN for multiclass brain tumor classification using MR images," *Biomedical Signal Processing and Control*, vol. 87, p. 105421, pp. 1–9 Jan. 2024, doi: 10.1016/j.bspc.2023.105421.
- [87] S. Saeedi, S. Rezayi, H. Keshavarz, and S. R. Niakan Kalhorri, "MRI-based brain tumor detection using convolutional deep learning methods and chosen machine learning techniques," *BMC Medical Informatics and Decision Making*, vol. 23, no. 1, pp. 16–32, Jan. 2023, doi: 10.1186/s12911-023-02114-6.
- [88] C. Ozdemir, "Classification of Brain Tumors from MR Images Using a New CNN Architecture," *Traitemen du Signal*, vol. 40, no. 2, pp. 611–618, Apr. 2023, doi: 10.18280/ts.400219.
- [89] R. Agarwal, S. D. Pande, S. N. Mohanty, and S. K. Panda, "A Novel Hybrid System of Detecting Brain Tumors in MRI," *IEEE Access*, vol. 11, pp. 118372–118385, 2023, doi: 10.1109/ACCESS.2023.3326447.
- [90] R. Islam, A. B. Akhi, and F. Akter, "A fine tune robust transfer learning based approach for brain tumor detection using VGG-16," *Bulletin of Electrical Engineering and Informatics*, vol. 12, no. 6, pp. 3861–3868, Dec. 2023, doi: 10.11591/eei.v12i6.5646.
- [91] E. U. Haq, H. Jianjun, X. Huarong, K. Li, and L. Weng, "A Hybrid Approach Based on Deep CNN and Machine Learning Classifiers for the Tumor Segmentation and Classification in Brain MRI," *Computational and Mathematical Methods in Medicine*, vol. 2022, pp. 1–18, Aug. 2022, doi: 10.1155/2022/6446680.
- [92] Md. S. I. Khan *et al.*, "Accurate brain tumor detection using deep convolutional neural network," *Computational and Structural Biotechnology Journal*, vol. 20, pp. 4733–4745, 2022, doi: 10.1016/j.csbj.2022.08.039.
- [93] A. A. Asiri *et al.*, "Block-Wise Neural Network for Brain Tumor Identification in Magnetic Resonance Images," *Computers, Materials & Continua*, vol. 73, no. 3, pp. 5735–5753, 2022, doi: 10.32604/cmc.2022.031747.
- [94] Z. Ullah, A. Odeh, I. Khattak, and M. al Hasan, "Enhancement of Pre-Trained Deep Learning Models to Improve Brain Tumor," *Informatica*, vol. 47, no. 6, pp. 165–172, Jun. 2023, doi: 10.31449/inf.v47i6.4645.
- [95] R. Vankdothu, M. A. Hameed, and H. Fatima, "A Brain Tumor Identification and Classification Using Deep Learning based on CNN-LSTM Method," *Computers and Electrical Engineering*, vol. 101, pp. 107960–107975, Jul. 2022, doi: 10.1016/j.compeleceng.2022.107960.
- [96] A. W. Reza *et al.*, "A CNN-Based Strategy to Classify MRI-Based Brain Tumors Using Deep Convolutional Network," *Applied Sciences*, vol. 13, no. 1, pp. 312–325, Dec. 2022, doi: 10.3390/app13010312.
- [97] N. Remzani, K. Tahiry, and A. Farchi, "Brain tumor classification in magnetic resonance imaging images using convolutional neural network," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 12, no. 6, pp. 6664–6673, Dec. 2022, doi: 10.11591/ijece.v12i6.pp6664-6674.
- [98] K. R. Reddy and R. Dhuli, "A Novel Lightweight CNN Architecture for the Diagnosis of Brain Tumors Using MR Images," *Diagnostics*, vol. 13, no. 2, pp. 312–332, Jan. 2023, doi: 10.3390/diagnostics13020312.
- [99] A. Kujur, Z. Raza, A. A. Khan, and C. Wechtaisong, "Data Complexity Based Evaluation of the Model Dependence of Brain MRI Images for Classification of Brain Tumor and Alzheimer's Disease," *IEEE Access*, vol. 10, pp. 112117–112133, 2022, doi: 10.1109/ACCESS.2022.3216393.
- [100] Mohan Ramya, Ganapathy Kirupa, and A Rama, "Brain tumor classification of magnetic resonance Images using novel CNN-based medical image Analysis and Detection network in comparison with AlexNet," *Journal of Population Therapeutics and Clinical Pharmacology*, vol. 29, no. 1, pp. 97–108, Jan. 2022, doi: 10.47750/jptcp.2022.898.
- [101] S. Abbas and A. M. Mahmoud, "Deep Learning-aided Brain Tumor Detection: An Initial Experience based Cloud Framework," *Indonesian Journal of Electrical Engineering and Informatics (IJEEI)*, vol. 8, no. 4, pp. 770–780, Dec. 2020, doi: 10.11591/ijeei.v8i4.2436.
- [102] W. M. Jwaid, Z. S. M. Al-Husseini, and A. H. Sabry, "Development of brain tumor segmentation of magnetic resonance imaging (MRI) using U-Net deep learning," *Eastern-European Journal of Enterprise Technologies*, vol. 4, no. 9(112), pp. 23–31, Aug. 2021, doi: 10.15587/1729-4061.2021.238957.
- [103] E. P. Onakpojeruo, M. T. Mustapha, D. U. Ozsahin, and I. Ozsahin, "A Comparative Analysis of the Novel Conditional Deep Convolutional Neural Network Model, Using Conditional Deep Convolutional Generative Adversarial Network-Generated Synthetic and Augmented Brain Tumor Datasets for Image Classification," *Brain Sciences*, vol. 14, no. 6, pp. 559–583, May 2024, doi: 10.3390/brainsci14060559.
- [104] S. Natha, U. Laila, I. A. Gashim, K. Mahboob, M. N. Saeed, and K. M. Noaman, "Automated Brain Tumor Identification in Biomedical Radiology Images: A Multi-Model Ensemble Deep Learning Approach," *Applied Sciences*, vol. 14, no. 5, pp. 2210–2228, Mar. 2024, doi: 10.3390/app14052210.
- [105] H. Alsaif *et al.*, "A Novel Data Augmentation-Based Brain Tumor Detection Using Convolutional Neural Network," *Applied Sciences*, vol. 12, no. 8, pp. 3773–3788, Apr. 2022, doi: 10.3390/app12083773.
- [106] S. Alaraimi, K. E. Okedu, H. Tianfield, R. Holden, and O. Uthmani, "Transfer learning networks with skip connections for classification of brain tumors," *International Journal of Imaging Systems and Technology*, vol. 31, no. 3, pp. 1564–1582, Sep. 2021, doi: 10.1002/ima.22546.
- [107] M. Vimala and P. R. Kumar, "Real-time Multi Fractal Ensemble Analysis CNN Model for Optimizing Brain Tumor Classification and Survival Prediction Using SVM," *Biomedical and Pharmacology Journal*, vol. 16, no. 1, pp. 305–318, Mar. 2023, doi: 10.13005/bpj/2612.
- [108] M. M. Zahoor *et al.*, "Brain Tumor MRI Classification Using a Novel Deep Residual and Regional CNN," *Biomedicines*, vol. 12, no. 7, pp. 1395–1413, Jun. 2024, doi: 10.3390/biomedicines12071395.
- [109] A. Muis, S. Sunardi, and A. Yudhana, "Comparison Analysis of Brain Image Classification Based on Thresholding Segmentation With Convolutional Neural Network," *Journal of Applied Engineering and Technological Science (JAETS)*, vol. 4, no. 2, pp. 664–673, Jun. 2023, doi: 10.37385/jaets.v4i2.1583.
- [110] S. Moldovanu, G. Tabacaru, and M. Barbu, "Convolutional Neural Network–Machine Learning Model: Hybrid Model for Meningioma Tumour and Healthy Brain Classification," *Journal of Imaging*, vol. 10, no. 9, pp. 235–248, Sep. 2024, doi: 10.3390/jimaging10090235.
- [111] L. P. Lin and Z. H. Seow, "Classifying Brain Tumours: A Deep Learning Approach with Explainable AI," in *2024 14th International Conference on Biomedical Engineering and Technology*, New York, NY, USA: ACM, Jun. 2024, pp. 101–107. doi: 10.1145/3678935.3678953.
- [112] F. Mufic, M. Kadunic, A. Musinbegovic, A. A. Almisreb, and H. Jaafar, "Deep learning for magnetic resonance imaging brain tumor detection: evaluating ResNet, EfficientNet, and VGG-19," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 14, no. 6, pp. 6360–6372, Dec. 2024, doi: 10.11591/ijece.v14i6.pp6360-6372.