

Machine Learning for Brain Cancer Diagnosis: Systematic Literature Review

Ari Coaquira, Roly Antony¹, Martinez Saldaña, Sandra Carolina², Alarcon Vasquez, Segundo Felipe³,
Sanchez Anastacio, Katherine Rosemary⁴
^{1,2,3,4} Universidad Tecnológica del Perú, Lima, Perú
U19217167@utp.edu.pe¹, U23260922@utp.edu.pe², c23460@utp.edu.pe³, c21317@utp.edu.pe⁴

Abstract

The diagnosis of brain tumors remains one of the greatest challenges in modern medicine due to the complexity and subjectivity of medical imaging interpretation methods. The purpose of this review is to evaluate the accuracy of machine learning techniques in diagnosing brain tumors and compare them with the manual interpretation of medical images performed by radiologists. Thirty original articles from Scopus and IEEE Xplore were selected, all of which were no older than five years. The review followed the PICO and PRISMA methodologies for the collection and analysis of the studies. The results show that machine learning techniques, particularly convolutional neural networks (CNN), achieve high accuracy, in some cases exceeding 90%, outperforming traditional methods such as Support Vector Machines (SVM) and K-Nearest Neighbors (KNN). Hybrid models like MobileNetV2 combined with VGG19 have demonstrated an accuracy of 92-95%, with advantages in processing speed. Additionally, it was identified that the availability and quality of labeled data significantly influence the accuracy of the models, with optimal performance in studies with large volumes of data. Among the most commonly detected tumors using these techniques are gliomas, meningiomas, and glioblastomas, although results have also been achieved in less frequent tumors such as ependymomas and medulloblastomas. In conclusion, machine learning techniques, particularly CNNs, show high potential for improving the accuracy of brain tumor diagnosis. Further research is needed to optimize their application and integration into clinical practice.

Keywords: machine learning, convolutional neural networks, brain tumor diagnosis, medical images, diagnostic accuracy

Machine learning para el diagnóstico de cáncer de cerebro: Revisión sistemática de literatura

Ari Coaquira, Roly Antony¹, Martinez Saldaña, Sandra Carolina², Alarcon Vasquez, Segundo Felipe³,

Sanchez Anastacio, Katherine Rosemary⁴

^{1,2,3,4} Universidad Tecnológica del Perú, Lima, Perú

U19217167@utp.edu.pe¹, U23260922@utp.edu.pe², c23460@utp.edu.pe³, c21317@utp.edu.pe⁴

Resumen

El diagnóstico de tumores cerebrales continúa siendo uno de los mayores desafíos en la medicina moderna debido a la complejidad y subjetividad de los métodos de interpretación de imágenes médicas. El propósito de esta revisión es evaluar la precisión de las técnicas de aprendizaje automático en el diagnóstico de tumores cerebrales y compararlas con la interpretación manual de imágenes médicas realizadas por radiólogos. Se seleccionaron 30 artículos originales de Scopus e IEEE Xplore, todos con una antigüedad no menor a cinco años. La revisión siguió las metodologías PICO y PRISMA para la recolección y análisis de los estudios. Los resultados muestran que las técnicas de machine learning, especialmente las redes neuronales convolucionales (CNN), logran una alta precisión, en algunos casos superior al 90%, superando métodos tradicionales como Support Vector Machines (SVM) y K-Nearest Neighbors (KNN). Modelos híbridos como MobileNetV2 combinado con VGG19 han demostrado una precisión del 92-95%, con ventajas en velocidad de procesamiento. Además, se identificó que la disponibilidad y calidad de datos etiquetados influyen significativamente en la precisión de los modelos, con un rendimiento óptimo en estudios con grandes volúmenes de datos. Entre los tumores más comúnmente detectados con estas técnicas se encuentran los gliomas, meningiomas y glioblastomas, aunque también se han logrado resultados en tumores menos frecuentes como ependimomas y meduloblastomas. En conclusión, las técnicas de machine learning, especialmente las CNN, muestran un alto potencial para mejorar la precisión en el diagnóstico de tumores cerebrales. Se necesitan más investigaciones para optimizar su aplicación e integración en la práctica clínica.

Palabras clave: aprendizaje automático, redes neuronales convolucionales, diagnóstico de tumores cerebrales, imágenes médicas, precisión diagnóstica

I. INTRODUCCIÓN

El diagnóstico de tumores cerebrales representa uno de los desafíos más grandes en la medicina moderna debido a la complejidad de los métodos actuales, como la resonancia magnética (MRI) y la tomografía computarizada (CT). Aunque estas técnicas de imagen médica han avanzado significativamente, la interpretación de los resultados sigue siendo subjetiva y depende en gran medida de la experiencia del radiólogo, lo que puede llevar a diagnósticos tardíos o erróneos [1]. En este contexto, el machine learning ha surgido como una herramienta que permite procesar grandes volúmenes de datos e identificar patrones complejos, facilitando la detección temprana y precisa de tumores [2], [3]. Investigaciones recientes han demostrado que los modelos de aprendizaje

profundo, como las redes neuronales convolucionales (CNN), han mejorado notablemente la precisión en la clasificación de distintos tipos de tumores cerebrales [2], [4].

Los avances en el uso de machine learning en la detección de cáncer cerebral son notables, pero aún persisten desafíos significativos. Uno de los principales problemas es la necesidad de grandes conjuntos de datos etiquetados, esenciales para entrenar modelos efectivos [1]. Además, la falta de estandarización en los métodos y la limitada interpretabilidad de los modelos plantean barreras para su implementación clínica a gran escala [3]. Por otro lado, los estudios han demostrado variaciones en los resultados dependiendo de las técnicas de segmentación y las características de los algoritmos utilizados, lo que evidencia una falta de consenso en las mejores prácticas para su aplicación [3], [4]. Además, el cáncer cerebral es altamente heterogéneo, lo que significa que existen diferentes subtipos de tumores con características biológicas únicas [1]. Esta heterogeneidad hace que el diagnóstico y la predicción de resultados sean particularmente difíciles, incluso con tecnologías avanzadas [1]. El cáncer de cerebro, especialmente los tumores malignos como los gliomas de alto grado, representa uno de los tipos más letales y agresivos de cáncer [1]. Estas cuestiones subrayan la necesidad de realizar una revisión sistemática para consolidar el conocimiento actual y explorar estrategias para abordar estos problemas.

Las herramientas automatizadas basadas en machine learning para la detección de cáncer cerebral podría revolucionar el campo de la oncología, mejorando la precisión diagnóstica y reduciendo los tiempos de respuesta [3], [5]. Además, al reducir la subjetividad en la interpretación de las imágenes, se podría lograr un diagnóstico más consistente y preciso, lo que a su vez mejoraría las tasas de supervivencia de los pacientes [4]. Esta revisión sistemática es necesaria para identificar los métodos más efectivos, destacar las limitaciones actuales y proponer mejores prácticas que puedan ser adoptadas en entornos clínicos.

En la presente revisión, se pretende comprender la precisión de las técnicas de machine learning en el diagnóstico de tumores cerebrales y analizar cómo estas se comparan con la interpretación manual de imágenes médicas. Por lo tanto, el objetivo de este documento es identificar los diferentes tipos de tumores cerebrales diagnosticados mediante machine learning,

así como evaluar las metodologías y resultados obtenidos en comparación con los métodos tradicionales [1][2][4].

El documento está organizado de la siguiente manera: La sección 2, Metodología, describe el proceso de realización de la Revisión Sistemática de Literatura (RSL), incluyendo los criterios de selección de estudios y las preguntas de investigación propuestas, que orientan el análisis de los métodos de machine learning en la detección de tumores cerebrales. La sección 3, Resultados, presenta y analiza los hallazgos de las investigaciones, abarcando los tipos de machine learning utilizados, las diferentes técnicas aplicadas en los estudios, y los niveles de precisión y eficacia en el diagnóstico de tumores cerebrales. En la sección 4, Discusión, se examina la importancia de estas técnicas en el entorno clínico, se analizan los desafíos actuales y se destacan las estrategias para mejorar su aplicación. Finalmente, en la sección 5, Conclusiones, se resumen los principales hallazgos de la revisión, subrayando las ventajas y limitaciones de los métodos de machine learning, y se sugieren posibles líneas de investigación futuras para optimizar su uso en el diagnóstico de tumores cerebrales.

II. METODOLOGÍA

A. PIOC

Para esta investigación se utilizó la metodología PIOC, que facilita la búsqueda de información relevante y precisa. El primer paso consiste en establecer claramente la pregunta de investigación, identificando los componentes clave: problema, intervención, resultados y contexto. Esta metodología ayuda a optimizar la investigación al orientar la recopilación de datos y permitir una toma de decisiones fundamentada [7].

La pregunta principal que se formula siguiendo la metodología PIOC es: ¿Qué niveles de precisión y eficacia han obtenido estas técnicas de machine learning en comparación con la interpretación manual de las imágenes?

Posteriormente, esta pregunta se desglosó en preguntas específicas asociadas a cada componente de PIOC:

- RQ1: ¿Cómo se ha definido el diagnóstico de cáncer cerebral en estudios que utilizan machine learning?
- RQ2: ¿En qué tipos de clínicas se han aplicado técnicas de machine learning para el diagnóstico del cáncer de cerebro?
- RQ3: ¿Qué técnicas de machine learning se han utilizado para el análisis de imágenes médicas en el diagnóstico de cáncer de cerebro?
- RQ4: ¿Qué niveles de precisión y eficacia han obtenido estas técnicas de machine learning en comparación con la interpretación manual de las imágenes?

Palabra Clave:
Se seleccionaron palabras clave para cada componente de la metodología PIOC, lo que facilita la búsqueda en fuentes especializadas. Estas palabras clave se establecen tanto en español como en inglés para abarcar una mayor cantidad de artículos científicos relevantes.




Figura 1: Cuadro PIOC

Ecuación de búsqueda:
Se utilizó una fórmula de búsqueda sistemática en las bases de datos de Scopus e IEEE.

("brain cancer" OR "cerebral cancer" OR "diagnosis" OR "complexity" OR "late detection" OR "subjective interpretation" OR "current limitations" OR "brain tumor") AND ("machine learning" OR "medical image analysis" OR "neural networks" OR "artificial intelligence" OR "learning algorithms" OR "automated diagnosis") AND ("diagnostic accuracy" OR "early detection" OR "consistency" OR "error reduction" OR "clinical improvement" OR "diagnostic effectiveness") AND ("clinics" OR "hospital environment" OR "medical research" OR "diagnostic centers" OR "oncology" OR "healthcare systems")

Cuadro PIOC

El siguiente cuadro presenta los cuatro componentes esenciales que se han determinado:

TABLA 1
MÉTODO PIOC

P	Cáncer de cerebro	"brain cancer" OR "cerebral cancer" OR "diagnosis" OR "complexity" OR "late detection" OR "subjective interpretation" OR "current limitations" OR "brain tumor"
I	Técnicas de machine learning para el análisis de imágenes médicas	"machine learning" OR "medical image analysis" OR "neural networks" OR "artificial intelligence" OR "learning algorithms" OR "automated diagnosis"
O	Nivel de precisión en	"diagnostic accuracy" OR "early detection" OR "consistency" OR "error

	los diagnósticos	reduction" OR "clinical improvement" OR "diagnostic effectiveness"
C	Clínicas	"clinics" OR "hospital environment" OR "medical research" OR "diagnostic centers" OR "oncology" OR "healthcare systems"

B. PRISMA

Se aplicó la metodología PRISMA con el propósito de realizar una búsqueda más eficiente en la Revisión Sistemática de Literatura (RSL). La Declaración PRISMA, que fue publicada en 2009, tiene como finalidad asistir a los investigadores en la elaboración de un informe detallado y transparente sobre su revisión sistemática, así como en la descripción de los métodos empleados y los artículos identificados por los autores [8].

Para la evaluación de los artículos y la elaboración del diagrama PRISMA, se aplicaron los siguientes criterios, los cuales se dividen en tres etapas: Identificación, Cribado e Inclusión.

Criterios de Inclusión:

- CI 1 Estudios sobre técnicas de machine learning aplicadas al diagnóstico de cáncer de cerebro.
- CI 2 Los estudios deben incluir métodos y modelos de machine learning aplicados a imágenes médicas (resonancias magnéticas, tomografías, etc.).
- CI 3 Investigaciones realizadas en entornos clínicos o que utilicen datos reales de pacientes.
- CI 4 Publicaciones en inglés y español, de los últimos 5 años.
- CI 5 Estudios de bases de datos científicas de Scopus e IEEE Xplore.
- CI 6 Se incluyó documentos de tipo artículos científicos.

Criterios de Exclusión:

- CE 1 Estudios que no se enfoquen en machine learning aplicado al cáncer de cerebro.
- CE 2 Estudios que no presenten resultados sobre qué tan precisas son las técnicas utilizadas.
- CE 3 Investigaciones basadas en simulaciones o datos sintéticos, sin pruebas en entornos clínicos o datos reales de pacientes.
- CE 4 Publicaciones anteriores a 2019 o que no sean artículos originales.
- CE 5 Estudios que no son de acceso libre.

Durante la fase de identificación, se encontraron 1,792 registros en total, recopilados de diversas bases de datos, siendo Scopus (1,619 registros) e IEEE (173 registros) las principales fuentes. Tras llevar a cabo el proceso de detección, no se eliminaron registros duplicados, ya que no se identificó ninguno. Por lo tanto, se pasó a la etapa de cribado con 1,792 registros. Posteriormente, al revisar los títulos y resúmenes de los

artículos seleccionados, se descartaron 750 registros que no cumplían con el objetivo de la investigación, siguiendo los criterios de inclusión previamente definidos. Esto dejó un total de 1,042 publicaciones para una evaluación más detallada. En esta fase, 449 publicaciones no pudieron ser recuperadas, probablemente debido a problemas de acceso o disponibilidad. Las restantes 593 publicaciones fueron evaluadas en la etapa de elegibilidad. En esta última fase, se llevó a cabo un filtro adicional que resultó en la exclusión de 563 publicaciones por las siguientes razones: 126 artículos no correspondían a los últimos 5 años, 430 no eran de acceso libre, y 7 no estaban disponibles en inglés o español. Finalmente, en la fase de inclusión, se seleccionaron 30 estudios que mostraron relevancia y validez para ser incluidos en la revisión.

Este proceso se presenta de forma gráfica y secuencial para mostrar todos los pasos de búsqueda, identificación y selección de artículos que fueron relevantes para la investigación.




Figura 2: Diagrama de Flujo Prisma

III. RESULTADOS

3.1. Resultados obtenidos de los Algoritmos de Machine Learning con Mayor Precisión en el Diagnóstico de Cáncer Cerebral

En el análisis de las investigaciones seleccionadas, se identificaron diversos algoritmos de machine learning aplicados al diagnóstico de cáncer cerebral, destacando aquellos que obtuvieron los mejores resultados en términos de

precisión. La comparación incluye algoritmos como Support Vector Machine (SVM), Extreme Learning Machine (ELM), K-Nearest Neighbors (KNN) y redes neuronales convolucionales, entre otros. [9], [11] [14], [15],[17] [18], [20], [23]. Ver Fig.3




Figura 3: Tipos de algoritmos de machine learning

3.2. Resultados de la eficacia de modelos de machine learning en la detección de tumores cerebrales

Se seleccionaron diferentes modelos de machine learning en estudios recientes que comparan su capacidad para identificar diversos tipos de tumores cerebrales frente a métodos tradicionales. Estos modelos incluyen técnicas como TPOT, CNN con optimización por políticas, ELM, y diversas arquitecturas avanzadas como ConNet-ResNet101 y MobileNetV2 combinada con VGG19, que fueron evaluadas en términos de precisión, sensibilidad, especificidad y eficacia promedio para asegurar un diagnóstico confiable y preciso en el contexto clínico. [13] [16], [18], [22],[24][30]. Ver Fig.4




Figura 4: Eficacia de modelos de machine learning

3.3. Resultados de la disponibilidad y calidad de datos etiquetados en la precisión de modelos de machine learning

La disponibilidad y calidad de los datos etiquetados son factores cruciales que afectan directamente la precisión de los modelos de machine learning en aplicaciones médicas, como el diagnóstico de cáncer cerebral. En la siguiente tabla se presentan varios modelos de machine learning evaluados en función del conjunto de datos utilizado, el volumen y la calidad de etiquetado, así como métricas de rendimiento clave, tales como la precisión, el índice de Jaccard y el recall. Esta información es fundamental para comprender cómo la calidad de los datos etiquetados influye en el rendimiento y confiabilidad de cada modelo. [17], [19], [23], [24], [25],[27],[30]. Ver Tabla 2.

Tabla 2: Disponibilidad y calidad de datos etiquetados

Modelo	Conjunto de datos	Volumenes de datos	Calidad de etiquetado	Precisión	Jaccard index	Recall(%)
CNN	Figshare	Grande	Alta	92.5	0.85	91.2
GANS	Datos Sinécticos	Grande	Sinética(generada)	90.8	0.83	89.5
TD-CNN-LSTM	BRATS 2018-2020	Grande	Alta	93.2	0.87	92.1
Radom Forest	SEER	Moderado	Alta	88.7	0.8	86.9
RELM	MRI fisiologicos	Moderado	Alta	89.4	0.82	88.3
FED-CNN	Variados	Grande	Moderada	87	0.78	85.4

3.4. Resultados de la metodologías de machine learning que se han utilizado en la detección de tumores cerebrales y cómo se comparan con los métodos tradicionales

La tabla resume métodos de machine learning aplicados en el diagnóstico de cáncer cerebral, señalando sus principales ventajas y limitaciones. Las Convolutional Neural Networks (CNN) destacan por su precisión en clasificación y segmentación de imágenes complejas, aunque requieren gran capacidad computacional. Métodos como Support Vector Machine (SVM) y Random Forest ofrecen buena precisión en

clasificación, siendo SVM sensible a imágenes complejas y Random Forest dependiente de datos bien estructurados. Otros modelos como Naïve Bayes y K-means son rápidos pero limitados en robustez o aplicabilidad en imágenes simples. Modelos avanzados como ResNet-101 y DenseNet-121 mejoran la precisión para estructuras complejas, adaptándose a datos voluminosos. [12], [14],[16], [21], [22],[29],[31] Ver Tabla 3.

TABLA 3
COMPARACIÓN DE METODOLOGÍAS DE MACHINE LEARNING EN LA DETECCIÓN DE TUMORES CEREBRALES

Nº	Metodología	Ventajas frente a métodos tradicionales	Limitaciones
1	Convolutional Neural Network (CNN)	Alta precisión en clasificación y segmentación, capaz de capturar características complejas en imágenes de MRI.	Requiere gran capacidad computacional; menos efectivo en pequeñas bases de datos.
2	Support Vector Machine (SVM)	Buena clasificación en imágenes, aunque depende del tipo de características radiológicas seleccionadas.	Sensibilidad limitada a la variabilidad en imágenes complejas.
3	Random Forest	Ofrece una clasificación rápida y precisa, ideal para predicciones en MRI de meningiomas.	Requiere datos bien estructurados para máxima precisión.
4	Naïve Bayes	Método rápido, pero menos preciso en comparación con CNN y Random Forest.	Menor robustez en bases de datos heterogéneas.
5	K-means	Adecuado para segmentación simple, pero menos efectivo en complejidad de tumores.	Limitada en imágenes complejas.
6	Fuzzy C-Means (FCM)	Mejora de precisión en segmentación compleja comparado con K-means.	Puede ser computacionalmente costoso.
7	Advanced Whale Optimization (AWO)	Optimiza la selección de características, aumentando precisión en imágenes complejas.	Aplicación restringida a entornos con alta potencia computacional.
8	ResNet-101	Alta precisión en clasificación y extracción de características en MRI.	Requiere optimización específica para cada aplicación.
9	DenseNet-201	Modelos profundos que permiten segmentación y clasificación sin necesidad de selección manual.	Sensibilidad alta a la configuración de parámetros y volumen de datos.
10	TimeDistributed-CNN-LSTM	Capacidad para analizar múltiples secuencias de imágenes en 3D simultáneamente, mejorando precisión en clasificación.	Alta demanda computacional y complejidad en el entrenamiento.

3.5. Resultados de tipos de Tumores Cerebrales Diagnosticados con Técnicas de Machine Learning

En la siguiente figura se presentan los resultados obtenidos sobre los tipos de tumores cerebrales diagnosticados mediante técnicas de machine learning en estudios revisados. Se observa una variedad de tumores con diferentes frecuencias de diagnóstico, destacando aquellos que presentan una incidencia más alta en estos estudios. Los gliomas, meningiomas y glioblastomas aparecen como los tipos de tumores más comunes en los análisis realizados, lo que refleja la capacidad de las técnicas de machine learning para detectar de forma eficaz estos tipos específicos de tumores. Por otro lado, los diagnósticos de tumores menos frecuentes, como ependimomas y meduloblastomas, también muestran la versatilidad de estas herramientas para abarcar una gama amplia de condiciones cerebrales. Este análisis contribuye a una mejor comprensión de la aplicabilidad del machine learning en el diagnóstico oncológico y subraya la importancia de estas técnicas para

mejorar la precisión en la detección temprana de tumores cerebrales. [22] [23], [26] [27], [28], [30] [32]. Ver Fig.5.




Figura 5 Tipos de tumores cerebrales

3.6. Resultados del tamaño de muestra utilizado en los estudios que emplean machine learning para el diagnóstico de cáncer cerebral

La gráfica circular muestra la distribución del tamaño de muestra empleado en los estudios que utilizan técnicas de machine learning para el diagnóstico de cáncer cerebral. En ella, se observa una diversidad en el tamaño de las muestras, siendo los grupos de 101 a 500 y 501 a 1000 los más comunes, representando un 33% y un 27% de los estudios, respectivamente. Los estudios que no especifican el tamaño de muestra constituyen el 3%, mientras que el resto se divide en muestras menores de 50 (10%), entre 51 y 100 (7%), y aquellos con más de 1000 muestras (20%). Este análisis permite comprender la escala de datos utilizada en la investigación sobre diagnósticos de cáncer cerebral mediante machine learning, destacando que una gran proporción de estudios emplea tamaños de muestra moderados a grandes, lo que podría influir en la robustez de los resultados obtenidos en estas investigaciones. [14], [16] [18] [22], [24], [26], [30]. Ver Fig.6




Figura 6 Tamaño de muestra utilizada en los estudios que emplean Machine Learning

IV. DISCUSIÓN

Las investigaciones previas han señalado que las redes neuronales convolucionales (CNN) son herramientas altamente efectivas para la clasificación de imágenes médicas, particularmente en el diagnóstico de glioblastomas [1] [15] [18]. Los resultados corroboran estas afirmaciones, mostrando que las CNN alcanzaron, en promedio, precisiones superiores al 90%, superando tanto a los métodos tradicionales como a otros algoritmos, como las máquinas de soporte vectorial (SVM) [10] [20] [28]. Este desempeño confirma su potencial como herramientas complementarias en el ámbito clínico.

Además, la investigación destacó que los métodos híbridos, como la combinación de MobileNetV2 con VGG19, no solo obtuvieron niveles de precisión elevados (92-95%), sino que también demostraron ventajas en términos de velocidad de procesamiento, lo que los hace particularmente útiles en escenarios con limitaciones de recursos computacionales [10] [17] [29]. Estos resultados resaltan la importancia de optimizar el rendimiento computacional en entornos reales, consolidando su viabilidad en aplicaciones prácticas [15] [16] [18] [23].

Por otra parte, se identificó que tanto la calidad como la cantidad de los datos etiquetados juegan un papel crucial en el rendimiento de los algoritmos [1] [4] [9] [11]. En particular, el uso de conjuntos de datos heterogéneos con representaciones adecuadas de casos clínicos complejos contribuyó significativamente a mejorar la sensibilidad y especificidad de los modelos [2] [3] [15] [25] [27] [28] [30] [31].

IV. CONCLUSIONES

Las técnicas de Machine Learning, especialmente las redes neuronales convolucionales (CNN), han demostrado altas tasas de precisión en el diagnóstico de tumores cerebrales, superando en algunos casos el 90%. Las CNN son especialmente eficaces para detectar gliomas, meningiomas y glioblastomas, aunque también han mostrado buenos resultados en tumores menos comunes como ependimomas y meduloblastomas, evidenciando su versatilidad.

En comparación con otros métodos de Machine Learning, como Support Vector Machine (SVM), Extreme Learning Machine (ELM) y K-Nearest Neighbors (KNN), las CNN destacan por su superior precisión, particularmente con imágenes complejas. No obstante, requieren mayor capacidad computacional. Aunque otros métodos como SVM y Random Forest también son efectivos, su rendimiento depende de la calidad de los datos y la simplicidad de las imágenes.

Se requieren más estudios para evaluar el potencial del Machine Learning en la predicción de la respuesta al tratamiento, la supervivencia, y su aplicación en la planificación quirúrgica y la radioterapia. Además, es esencial desarrollar herramientas

que integren estas técnicas en la práctica clínica, optimizando su uso por los radiólogos. Finalmente, es necesario seguir investigando para abordar las limitaciones actuales, como la necesidad de grandes conjuntos de datos y la falta de interpretabilidad de algunos modelos. El desarrollo de modelos más robustos y comprensibles facilitará la integración de las técnicas de machine learning en la práctica clínica, lo que podría tener un impacto significativo en la atención a pacientes con tumores cerebrales.

REFERENCES

- [1] F. Pacchiano, M. Tortora, C. Doneda, G. Izzo, F. Arrigoni, L. Ugga, R. Cuocolo, C. Parazzini, A. Righini, and A. Brunetti, "Radiomics and artificial intelligence applications in pediatric brain tumors," *World Journal of Pediatrics*, vol. 20, no. 4, pp. 1-14, 2024, doi: 10.1007/s12519-024-00823-0.
- [2] P. Wu and J. Shen, "Brain tumor diagnosis based on convolutional neural network improved by a new version of political optimizer," *Biomedical Signal Processing and Control*, vol. 85, pp. 104853, 2023, doi: 10.1016/j.bspc.2023.104853.
- [3] U. Bhimavarapu, N. Chintalapudi, and G. Battineni, "Brain Tumor Detection and Categorization with Segmentation of Improved Unsupervised Clustering Approach and Machine Learning Classifier," *Bioengineering*, vol. 11, no. 266, pp. 1-25, 2024, doi: 10.3390/bioengineering11030266.
- [4] G. Kumar and H. Alqahtani, "Deep Learning-Based Cancer Detection: Recent Developments, Trends and Challenges," *Computer Modeling in Engineering & Sciences*, vol. 130, no. 3, pp. 1272-1300, 2022, doi: 10.32604/cmescs.2022.018418.
- [5] K. Munir, H. Elahi, A. Ayub, F. Frezza, and A. Rizzi, "Cancer Diagnosis Using Deep Learning: A Bibliographic Review," *Cancers*, vol. 11, no. 9, pp. 1235, 2019, doi: 10.3390/cancers11091235.
- [6] R. Kaifi, "A Review of Recent Advances in Brain Tumor Diagnosis Based on AI-Based Classification," *Diagnostics*, vol. 13, no. 3007, pp. 1-32, 2023, doi: 10.3390/diagnostics13183007.
- [7] Quispe, A. M., Hinojosa-Ticona, Y., Miranda, H. A., & Sedano, C. A. (2021). Scientific writing series: Systematic review. In *Revista del Cuerpo Médico Hospital Nacional Almanzor Aguinaga Asenjo* (Vol. 14, Issue 1, pp. 94-99). Medical Body of the Almanzor Aguinaga Asenjo National Hospital. <https://doi.org/10.35434/rcmhnaaa.2021.141.906>.
- [8] Rethlefsen, M. L., & Page, M. J. (2022). PRISMA 2020 and PRISMA-S: common questions on tracking records and the flow diagram. In *Journal of the Medical Library Association* (Vol. 110, Issue 2, pp. 253-257). Medical Library Association. <https://doi.org/10.5195/jmla.2022.1449>.
- [9] Gunasekaran, S., Mercy Bai, P. S. M., Mathivanan, S. K., Rajadurai, H., Shivahare, B. D., & Shah, M. A. (2024). Automated brain tumor diagnostics: Empowering neuro-oncology with deep learning-based MRI image analysis. *PLOS ONE*, 19(8), e0306493. <https://doi.org/10.1371/journal.pone.0306493>
- [10] Wageh, M., Amin, K., Algarni, A. D., Hamad, A. M., & Ibrahim, M. (2024). Brain tumor detection based on deep features concatenation and machine learning classifiers with genetic selection. *IEEE Access*, 12, 123456-123467. <https://doi.org/10.1109/ACCESS.2024.3446190>
- [11] Montaha, S., Azam, S., Rafid, A. K. M. R. H., Hasan, M. Z., Karim, A., & Islam, A. (2022). TimeDistributed-CNN-LSTM: A Hybrid Approach Combining CNN and LSTM to Classify Brain Tumor on 3D MRI Scans Performing Ablation Study. *IEEE Access*, 10, 60039-60059. <https://doi.org/10.1109/ACCESS.2022.3179577>
- [12] Gumaei, A., Hassan, M. M., Hassan, M. R., Alelaiwi, A., & Fortino, G. (2019). A Hybrid Feature Extraction Method With Regularized Extreme Learning Machine for Brain Tumor Classification. *IEEE Access*, 7, 36266-36273. <https://doi.org/10.1109/ACCESS.2019.2904145>
- [13] Kertels, O., Delbridge, C., Sahm, F., Ehret, F., Acker, G., Capper, D., Peeken, J. C., Diehl, C., Griessmair, M., Metz, M.-C., Negwer, C., Krieg,

- S. M., Onken, J., Yakushev, I., Vajkoczy, P., Meyer, B., Zips, D., Combs, S. E., Zimmer, C., Kaul, D., Bernhardt, D., & Wiestler, B. (2024). Imaging meningioma biology: Machine learning predicts integrated risk score in WHO grade 2/3 meningioma. *Neuro-Oncology Advances*, 6(1), vdae080. <https://doi.org/10.1093/noajnl/vdae080>
- [14] Stadlbauer, A., Marhold, F., Oberndorfer, S., Heinz, G., Buchfelder, M., Kinfe, T. M., & Meyer-Bäse, A. (2022). Radiophysics: Brain Tumors Classification by Machine Learning and Physiological MRI Data. *Cancers*, 14(10), 2363. <https://doi.org/10.3390/cancers14102363>
- [15] Kocher, M., Ruge, M. I., Galldiks, N., & Lohmann, P. (2020). Applications of radiomics and machine learning for radiotherapy of malignant brain tumors. *Strahlentherapie und Onkologie*, 196(10), 856–867. <https://doi.org/10.1007/s00066-020-01626-8>
- [16] Alalwan, N., Alwadain, A., Alzahrani, A. I., Al-Bayatti, A. H., Abozeid, A., & Abd El-Aziz, R. M. (2024). Advancements in brain tumor identification: Integrating synthetic GANs with federated-CNNs in medical imaging analysis. *Alexandria Engineering Journal*. <https://doi.org/10.1016/j.aej.2024.06.080>
- [17] Khan, M. M., Omeed, A. S., Tazin, T., Almalki, F. A., Aljohani, M., & Algethami, H. (2022). A novel approach to predict brain cancerous tumor using transfer learning. *Computational and Mathematical Methods in Medicine*, 2022, Article ID 2702328. <https://doi.org/10.1155/2022/2702328>
- [18] García-Ruiz, A., et al. (2024). An accessible deep learning tool for voxel-wise classification of brain malignancies from perfusion MRI. *Cell Reports Medicine*, 5(4), 101464. <https://doi.org/10.1016/j.xcrm.2024.101464>
- [19] Overcast, W. B., Davis, K. M., Ho, C. Y., Hutchins, G. D., Green, M. A., Graner, B. D., & Veronesi, M. C. (2021). Advanced imaging techniques for neuro-oncologic tumor diagnosis, with an emphasis on PET-MRI imaging of malignant brain tumors. *Current Oncology Reports*, 23(3), 34. <https://doi.org/10.1007/s11912-021-01020-2>
- [20] Lv, K., Chen, H., Cao, X., Du, P., Chen, J., Liu, X., Zhu, L., Geng, D., & Zhang, J. (2023). Development and validation of a machine learning algorithm for predicting diffuse midline glioma, H3 K27–altered, H3 K27 wild-type high-grade glioma, and primary CNS lymphoma of the brain midline in adults. *Journal of Neurosurgery*, 139(2), 393–401. <https://doi.org/10.3171/2022.11.JNS221544>
- [21] Bathla, G., Dhruva, D. D., et al. (2023). AI-based classification of three common malignant tumors in neuro-oncology: A multi-institutional comparison of machine learning and deep learning methods. *Journal of Neuroradiology*. <https://doi.org/10.1016/j.neurad.2023.08.007>
- [22] Booth, T. C., Williams, M., Luis, A., Cardoso, J., Ashkan, K., & Shuaib, H. (2020). Machine learning and glioma imaging biomarkers. *Clinical Radiology*, 75(1), 20–32. <https://doi.org/10.1016/j.crad.2019.07.001>
- [23] Aleid, A. M., Alrasheed, A. S., Aldanyowi, S. N., & Almalki, S. F. (2024). Advanced magnetic resonance imaging for glioblastoma: Oncology-radiology integration. *Surgical Neurology International*, 15, 309. https://doi.org/10.25259/SNI_498_2024
- [24] Kertels, O., Delbridge, C., Sahm, F., Ehret, F., Acker, G., Capper, D., Peeken, J. C., Diehl, C., Griessmair, M., Metz, M.-C., Negwer, C., Krieg, S. M., Onken, J., Yakushev, I., Vajkoczy, P., Meyer, B., Zips, D., Combs, S. E., Zimmer, C., Kaul, D., Bernhardt, D., & Wiestler, B. (2024). Imaging meningioma biology: Machine learning predicts integrated risk score in WHO grade 2/3 meningioma. *Neuro-Oncology Advances*, 6(1), vdae080. <https://doi.org/10.1093/noajnl/vdae080>
- [25] Nath, G., Coursey, A., Li, Y., Prabhu, S., Garg, H., et al. (2023). An interactive web-based tool for predicting and exploring brain cancer survivability. *Healthcare Analytics*, 3, 100132. <https://doi.org/10.1016/j.health.2022.100132>
- [26] Zhao, L., & Jia, K. (2016). Multiscale CNNs for Brain Tumor Segmentation and Diagnosis. *Computational and Mathematical Methods in Medicine*, 2016, Article ID 8356294. <https://doi.org/10.1155/2016/8356294>
- [27] Antoniou, G., Conn, J. J. A., Smith, B. R., Brennan, P. M., Baker, M. J., & Palmer, D. S. (2023). Recurrent neural networks for time domain modelling of FTIR spectra: application to brain tumour detection. *Analyst*, 148(8), 1770–1776. <https://doi.org/10.1039/d2an02041f>
- [28] Panesar, S. S., D'Souza, R. N., Yeh, F., & Fernandez-Miranda, J. C. (2019). Machine learning versus logistic regression methods for 2-year mortality prognostication in a small, heterogeneous glioma database. *World Neurosurgery*, 2, 100012. <https://doi.org/10.1016/j.wnsx.2019.100012>
- [29] Krishnapriya, S., & Karuna, Y. (2023). Pre-trained deep learning models for brain MRI image classification. *Frontiers in Human Neuroscience*, 17, 1150120. <https://doi.org/10.3389/fnhum.2023.1150120>
- [30] Ayomide, K. S., Aris, T. N. M., & Zolkepli, M. (2023). Improving Brain Tumor Segmentation in MRI Images through Enhanced Convolutional Neural Networks. *International Journal of Advanced Computer Science and Applications*, 14(4), 670–676. <https://doi.org/10.14569/IJACSA.2023.0140473>
- [31] Machura, B., Kucharski, D., Bozek, O., Eksner, B., Kokoszka, B., Pekala, T., Radom, M., Strzelczak, M., Zarudzki, L., Gutiérrez-Becker, B., Krason, A., Tessier, J., & Nalepa, J. (2024). Deep learning ensembles for detecting brain metastases in longitudinal multi-modal MRI studies. *Computerized Medical Imaging and Graphics*, 101, 102401. <https://doi.org/10.1016/j.compmedimag.2024.102401>
- [32] Park, J. E., Kickingereder, P., & Kim, H. S. (2020). Radiomics and deep learning from research to clinical workflow: neuro-oncologic imaging. *Korean Journal of Radiology*, 21(10), 1126–1137. <https://doi.org/10.3348/kjr.2019.0847>