

Red neuronal artificial para el reconocimiento de glioblastomas en imágenes de SPECT cerebral con ^{99m}Tc-MIBI

Artificial Neural Network for Recognition of Glioblastomas in Brain SPECT Images with 99mTc-MIBI

Roberto León Castellón^{1*} <https://orcid.org/0000-0002-6085-8565>

Juan Miguel Martín Escuela¹ <https://orcid.org/0000-0002-8710-0383>

Silvia Salva Camaño² <https://orcid.org/0000-0001-8631-1958>

Lisette Mejías Pérez¹ <https://orcid.org/0000-0003-2126-8375>

Lester Rodríguez Paleo¹ <https://orcid.org/0000-0003-1489-1310>

Yanaisa Sánchez Caballero¹ <https://orcid.org/0009-0009-9815-6989>

Denia Bonilla Padrón¹ <https://orcid.org/0000-0003-4035-2337>

Nelson Gómez Viera³ <https://orcid.org/0000-0001-7077-6347>

Adlín López Díaz⁴ <https://orcid.org/0000-0002-1020-8775>

¹Universidad de Ciencias Médicas de La Habana, Hospital Clínico Quirúrgico Hermanos Ameijeiras, Departamento de Medicina Nuclear. La Habana, Cuba.

²Clínica Misericordia Internacional. Barranquilla, Colombia.

³Universidad de Ciencias Médicas de La Habana, Hospital Clínico Quirúrgico Hermanos Ameijeiras, Servicio de Neurología. La Habana, Cuba.

⁴Universidad de La Habana, Instituto de Tecnologías y Ciencias Aplicadas. La Habana, Cuba.

*Autor para la correspondencia: robertoleonc82@gmail.com

RESUMEN

Introducción: Los gliomas representan aproximadamente el 25 % de todos los tumores cerebrales en adultos, siendo el glioblastoma el tumor cerebral primario maligno más frecuente. La inteligencia artificial y, dentro de ella, las técnicas de aprendizaje automático tienen el potencial de convertirse en herramientas de diagnóstico muy poderosas y ayudas confiables para los neurólogos clínicos.

Objetivo: Determinar el rendimiento de una red neuronal artificial entrenada para identificar glioblastomas mediante biomarcadores extraídos de imágenes de SPECT cerebral con ^{99m}Tc -MIBI utilizando el perceptrón multicapa.

Métodos: Se realizó un estudio observacional, transversal, cuantitativo, que tuvo lugar en el Hospital Clínico Quirúrgico Hermanos Ameijeiras, La Habana, Cuba, durante el período 2018-2020. Se utilizó como algoritmo el perceptrón multicapa y para su validación el método (*k-fold cross validation*). Se realizó un balance de clases en la *data* de entrenamiento mediante el algoritmo *Synthetic Minority Oversampling Technique* a fin de garantizar métricas de mayor calidad.

Resultados: Se analizaron 220 imágenes (estudios precoz y tardío) de tomografía por emisión de fotón único cerebral con ^{99m}Tc -MIBI de 110 pacientes con diagnóstico de glioma cerebral. La exactitud general del modelo fue elevada, tanto en el entrenamiento (97,3 %) como en la prueba (97,1 %) y el error fue bajo, tanto para el entrenamiento (2,7 %) como para la prueba (2,9 %). De todas las variables medidas la que mayor peso normalizado tuvo fue el índice de retención del radiofármaco.

Conclusiones: La red neuronal artificial propuesta y entrenada para reconocer glioblastomas utilizando el perceptrón multicapa mediante biomarcadores extraídos de imágenes de SPECT cerebral con ^{99m}Tc -MIBI en una base de datos de gliomas cerebrales tuvo un entrenamiento satisfactorio y excelentes métricas de rendimiento.

Palabras clave: glioblastoma; tomografía por emisión de fotón único; inteligencia artificial; red neuronal artificial.

ABSTRACT

Introduction: Gliomas represent approximately 25% of all brain tumors in adults, and glioblastoma is the most frequent malignant primary brain tumor. Artificial intelligence, particularly machine learning techniques have the potential to become very powerful diagnostic tools and reliable aids for clinical neurologists.

Objective: To determine the performance of an artificial neural network trained to identify glioblastomas by means of biomarkers extracted from brain SPECT images with ^{99m}Tc-MIBI using the multilayer perceptron.

Methods: An observational, cross-sectional, quantitative study was carried out, at Hermanos Ameijeiras Clinical Surgical Hospital, Havana, Cuba, from 2018 to 2020. The multilayer perceptron was used as algorithm and the k-fold cross validation method for validation. A class balance was performed on the training data using the Synthetic Minority Oversampling Technique algorithm in order to ensure higher quality metrics.

Results: Two hundred twenty images were analyzed, they were from early and late studies of brain single photon emission tomography with ^{99m}Tc-MIBI of 110 patients diagnosed with brain glioma. The general accuracy of the model was high, both in the training (97.3%) and in the test (97.1%) and the error was low, both for the training (2.7%) and for the test (2.9%). The retention index of the radiopharmaceutical was the variable with the greatest normalized weight from all the variables measured.

Conclusions: The proposed artificial neural network trained to recognize glioblastomas using the multilayer perceptron using biomarkers extracted from ^{99m}Tc-MIBI brain SPECT images in a database of brain gliomas had satisfactory training and excellent performance metrics.

Keywords: glioblastoma; single photon emission tomography; artificial intelligence; artificial neural network.

Recibido: 24/06/2023

Aceptado: 06/07/2023

Introducción

Los gliomas representan aproximadamente el 25 % de todos los tumores cerebrales en adultos,⁽¹⁾ siendo el glioblastoma el tumor cerebral primario maligno más frecuente, el cual representa aproximadamente el 57 % de todos los gliomas y el 48 % de todos los tumores malignos primarios del sistema nervioso central (SNC).⁽²⁾

El grado y clasificación de los gliomas han experimentado modificaciones debido a sustanciales aportes, logrados en los últimos años, con el uso de marcadores moleculares. Aun así, las neuroimágenes resultan esenciales para el estudio y seguimiento.⁽³⁾

La inteligencia artificial se está convirtiendo cada vez más en una parte de la vida cotidiana. Esto plantea la cuestión de si la neurología clínica puede beneficiarse de estos métodos novedosos para aumentar la precisión diagnóstica. Las técnicas de aprendizaje automático tienen el potencial de convertirse en herramientas de diagnóstico muy poderosas y confiables para los neurólogos clínicos.⁽⁴⁾

El objetivo de este trabajo fue determinar el rendimiento de una red neuronal artificial entrenada utilizando el perceptrón multicapa como clasificador de glioblastomas mediante biomarcadores extraídos de imágenes de SPECT cerebral con ^{99m}Tc-MIBI.

Métodos

Se realizó un estudio observacional, transversal, cuantitativo, que tuvo lugar en el Hospital Clínico Quirúrgico Hermanos Ameijeiras durante el período 2018-2020, en el cual se analizó una base de datos con imágenes de SPECT cerebral con ^{99m}Tc-MIBI de 110 pacientes que tenían diagnóstico confirmado de glioma cerebral; la cual contiene 220 imágenes con estudios inicial y tardío.

Se calcularon diferentes índices conformados por regiones de interés donde existe captación del radiofármaco (ecuaciones 1, 2, 3 y 4).

Ecuación 1 - Índice tumor entre corteza contralateral (*TCL*) en estudio inicial (*Te*) y tardío (*Ta*).

$$TCL = \frac{\text{cuentas máximas en la lesión tumoral}}{\text{cuentas máximas en la imagen en espejo de la corteza sana contralateral}} \dots\dots\dots (1)$$

Ecuación 2 - Índice tumor entre hipófisis (*THip*) en estudio inicial (*Te*) y tardío (*Ta*).

$$THip = \frac{\text{cuentas máximas en la lesión tumoral}}{\text{cuentas máximas en la hipófisis}} \dots\dots\dots (2)$$

Ecuación 3 - Índice tumor entre plexos coroides (*TPC*) en estudio inicial (*Te*) y tardío (*Ta*).

$$TPC = \frac{\text{cuentas máximas en la lesión tumoral}}{\text{cuentas máximas en los plexos coroides ipsilateral al tumor}} \dots\dots\dots (3)$$

Ecuación 4 - Índice de retención del radiofármaco (*IR*).

$$IR = \frac{TCL (Ta)}{TCL (Te)} \dots\dots\dots (4)$$

Se realizó un balance de clases en la *data* de entrenamiento mediante el algoritmo *Synthetic Minority Oversampling Technique (SMOTE)* a fin de garantizar las métricas de mayor calidad y se utilizó como algoritmo de clasificación el perceptrón multicapa.

Para el análisis de la *data* se utilizaron los programas informáticos SPSS versión 25 y Weka versión 3.9.5.

Resultados

Se analizaron 220 imágenes (estudios inicial y tardío) de SPECT cerebral con ^{99m}Tc -MIBI de 110 pacientes con diagnóstico de glioma cerebral donde la edad media \pm desviación estándar fue de $50,57 \pm 12,74$ años. La edad no sigue una distribución normal (prueba de Kolmogorov-Smirnov 0,100; $p = 0,009$); la media \pm desviación estándar de los pacientes con diagnóstico de glioblastoma fue de $46,36 \pm 9,62$ años y de los que tienen diagnóstico de otro tipo de glioma (no glioblastoma) fue de $51,13 \pm 13,40$ años, no demostrándose diferencias estadísticamente significativas (U de Mann-Whitney 853,000; $p = 0,389$). Tampoco existieron diferencias estadísticamente significativas entre sexo y presencia o no de glioblastoma (χ^2 cuadrado de Pearson 0,455, $p = 0,500$).

Se creó una red neuronal (fig. 1) utilizando como algoritmo clasificador el perceptrón multicapa, donde la capa de entrada está formada por 7 covariables que corresponden a los biomarcadores. Del total de instancias de la *data*, el 70 % fueron sometidas a entrenamiento y el 30 % realizaron la prueba.

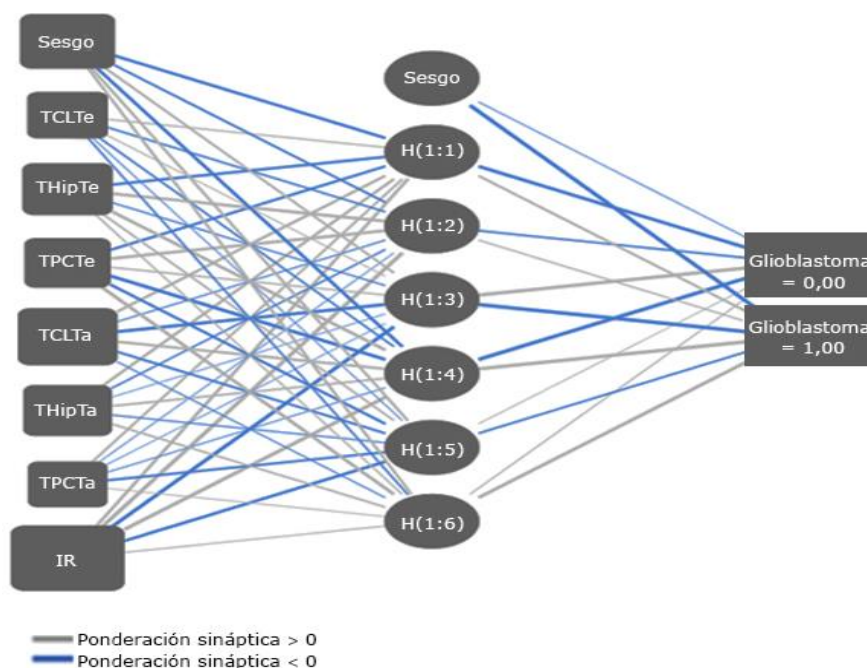


Fig. 1 Red neuronal con perceptrón multicapa para clasificar glioblastomas utilizando parámetros medidos con SPECT cerebral ^{99m}Tc -MIBI.

La exactitud general del modelo fue elevada tanto para el entrenamiento por lote (97,3 %) como para la prueba (97,1 %); de igual manera ocurre para glioblastomas y no glioblastomas; el porcentaje de pronósticos incorrectos es bajo, tanto para el entrenamiento (2,7 %) como para la prueba (2,9 %) (tabla 1). El área bajo la curva (AUC) *Receiver Operating Characteristic* (ROC) fue elevada tanto para la categoría glioblastoma como para la no glioblastoma (AUC = 0,995 en ambos casos) (fig. 2).

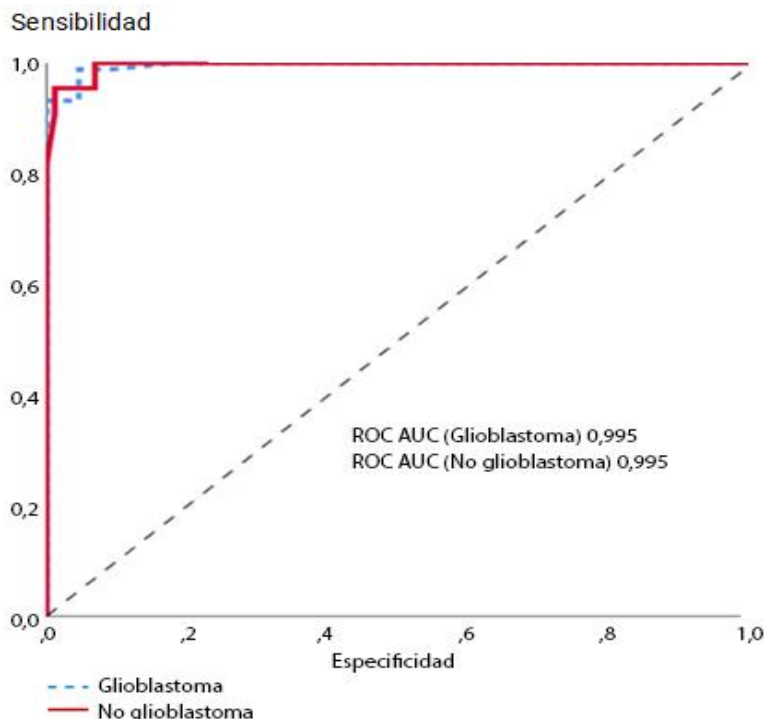


Fig. 2 Curvas ROC para clasificar las clases glioblastoma y no glioblastoma utilizando el perceptrón multicapa.

Tabla 1 - Resumen del modelo de clasificación de glioblastomas con el perceptrón multicapa

Métricas	Entrenamiento (0,03 segundos)	Prueba
Porcentaje correcto (no glioblastoma)	98,4	96,3
Porcentaje correcto (glioblastoma)	92,9	100
Porcentaje correcto (global)	97,3	97,1
Error (%)	2,7	2,9

La mediana de la seudoprobabilidad pronosticada para clasificar un glioma como un glioblastoma a través de este algoritmo cuando histológicamente no lo es, está por debajo del 3 %. De manera general la seudoprobabilidad pronosticada para los aciertos en la clasificación por el perceptrón multicapa es alta y muy baja para los errores de clasificación (fig. 3).

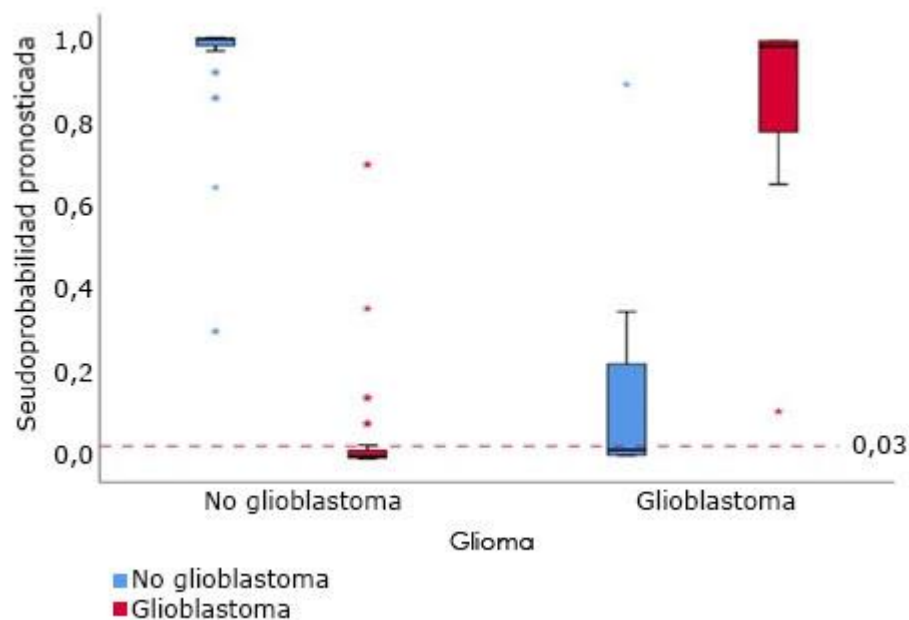


Fig. 3 Seudoprobabilidad pronosticada para la clasificación con el perceptrón multicapa en función de la clasificación histológica.

De todas las variables medidas con SPECT cerebral con ^{99m}Tc – MIBI, la que mayor peso normalizado tuvo en este modelo fue el índice de retención del radiofármaco, constituyendo de esta manera el marcador más importante para la clasificación de categorías (glioblastoma y no glioblastoma) mediante el perceptrón multicapa (fig. 4)

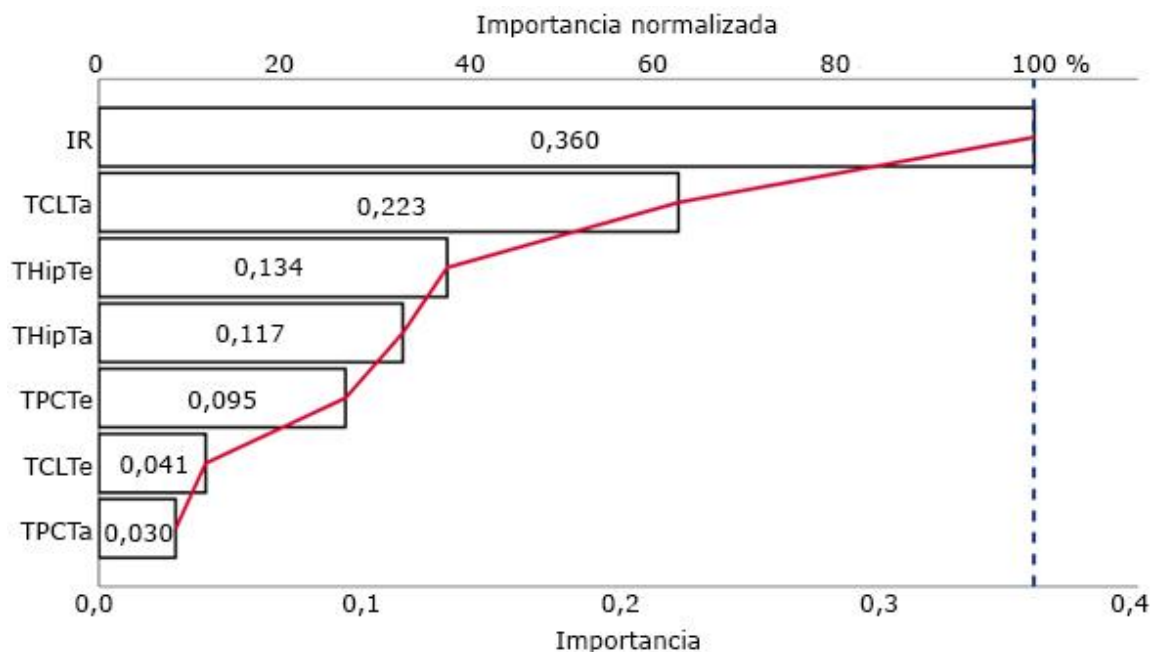


Fig. 4 Importancia normalizada de cada una de las variables consideradas en la clasificación de glioblastomas con el perceptrón multicapa.

Para la validación de este algoritmo la *data* general se dividió en una *data* de validación (70 %), la cual se entrenó, y otra de prueba (30 %). Se utilizó el método *k-fold cross validation*, en este caso se utilizaron 5 pliegues (*5 fold cross validation*). Se corroboró que este modelo aportó un elevado porcentaje de imágenes clasificadas correctamente, tanto para el entrenamiento como para la prueba, con bajo porcentaje de error, elevado índice de kappa y de las áreas bajo la curvas ROC y de precisión *recall*, que llegan a la unidad en la prueba (tabla 2). No existen diferencias, estadísticamente significativas, de la exactitud en la validación; con una diferencia entre estas inferior al 10 % (fig. 5).

Tabla 2 - Resultados de las métricas en la validación

Métricas	5-Fold-cross-validation (tiempo = 0,08 segundos)		Reevaluación del modelo con la data inicial de prueba
Exactitud (%)	(k1) 93,333	93,388	97,059
	(k2) 96,538		
	(k3) 92,942		
	(k4) 90,025		
	(k5) 93,852		
Error (%)	6,612		2,941
Kappa	0,868		0,905
Verdaderos positivos	0,934		0,971
Falsos positivos	0,067		0,113
Precisión	0,936		0,972
Sensibilidad	0,934		0,971
Valor F	0,934		0,970
Coefficiente de correlación de Matthews	0,870		0,909
AUC-ROC	0,984		1,000
AUC-Precision Recall	0,985		1,000

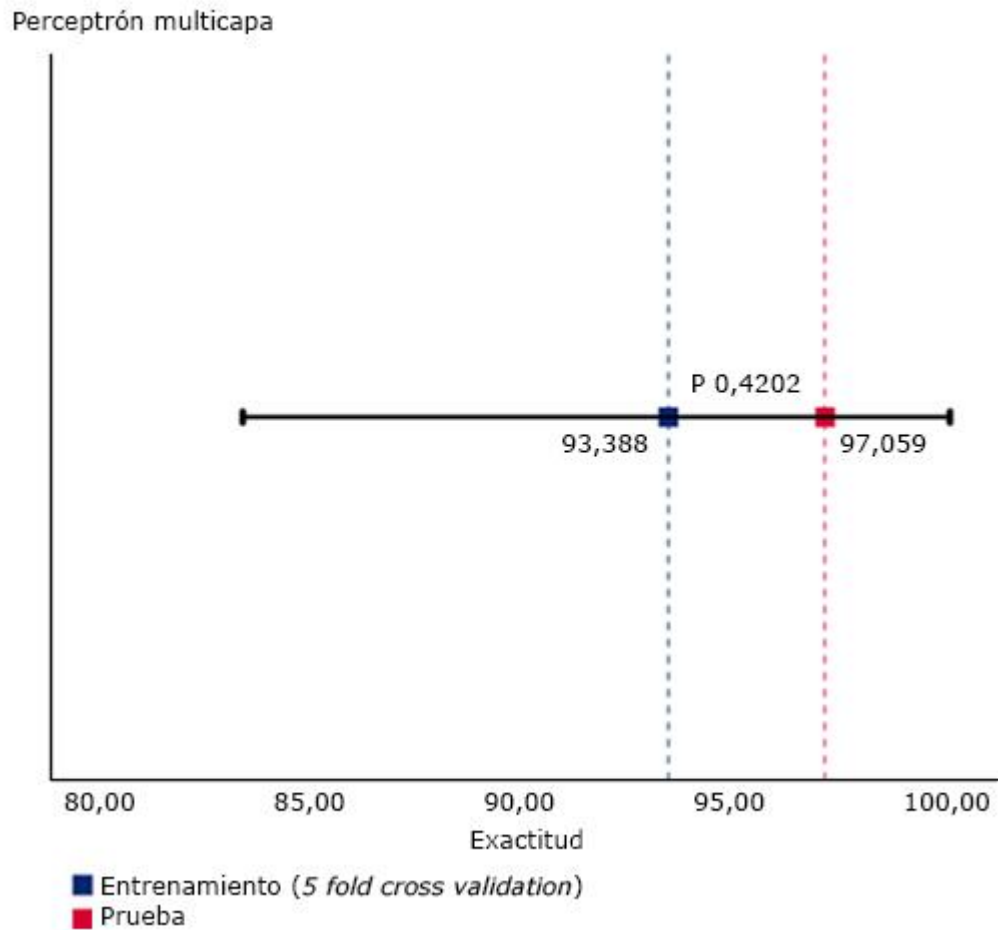


Fig. 5. Diferencia entre instancias correctamente clasificadas en el entrenamiento de la data de validación con 5 fold cross validation y de prueba con el perceptrón multicapa. (forest plot).

Discusión

En la práctica clínica, los datos que ofrecen las neuroimágenes de cada paciente se analizan por su fenotipo imagenológico o mediante el análisis de sus características (volúmenes, índices de referencias, características radiómicas, entre otras).⁽⁵⁾

En este sentido, la inteligencia artificial (IA) se utiliza en la investigación médica para encontrar biomarcadores de diagnóstico y la predicción de resultados del

tratamiento con el uso de datos de neuroimagen recopilados para grupos específicos de pacientes o voluntarios sanos.⁽⁵⁾

La investigación se limitó a resolver el problema de reconocimiento-clasificación de patrones diagnósticos de glioblastomas, a partir de datos de biomarcadores extraídos de las imágenes de SPECT cerebral con ^{99m}Tc-MIBI, para ser utilizados posteriormente en la práctica clínica con fines de diagnóstico.

La última década ha visto un aumento prodigioso de las técnicas de IA con impacto en la industria, incluida la conducción autónoma, la atención médica, las finanzas, la fabricación y la recolección de energía, entre otros. Se percibe en gran medida como una de las principales tecnologías disruptivas de nuestra era, como fueron las computadoras de los 80 y 90.⁽⁶⁾

El éxito de la IA ha estado marcado en un principio por mejoras significativas en algunas tecnologías existentes, por ejemplo, en el campo del reconocimiento de imágenes. En gran medida, estos avances constituyeron las primeras demostraciones del impacto que pueden tener los métodos de *machine learning* (ML) en tareas especializadas.⁽⁶⁾

El trabajo en redes neuronales artificiales, comúnmente denominadas “redes neuronales”, ha estado motivado desde su inicio por el reconocimiento de que el cerebro humano computa de una manera completamente diferente a la computadora digital convencional.⁽⁷⁾

La plasticidad permite que el sistema nervioso en desarrollo se adapte al entorno que lo rodea. Así como la plasticidad parece ser esencial para el funcionamiento de las neuronas como unidades de procesamiento de información en el cerebro humano, lo mismo ocurre con las redes neuronales formadas por neuronas artificiales.⁽⁷⁾

En su forma más general, una red neuronal es una herramienta diseñada para modelar la forma en que el cerebro realiza una tarea o función particular de interés; la red generalmente se implementa mediante el uso de componentes electrónicos o se simula en *software*.⁽⁷⁾

Zander y otros⁽⁷⁾ utilizaron datos cuantificables de imágenes, información genética y datos clínicos como la edad y escala de Karnofsky para conformar una red neuronal artificial que permitiera la evaluación prequirúrgica no invasiva de pacientes con glioblastoma. Esta red tuvo dos capas intermedias y una cuarta capa con salida binaria, asignando “1” a quienes tienen mayor supervivencia global y “0” a aquellos con menor supervivencia global. El empleo de datos de características de imagen como entradas proporcionó el mayor rendimiento (del 80 al 85 %).

Latif y otros⁽⁸⁾ utilizaron redes neuronales convolucionales (CNN) para extraer las características de las imágenes de resonancia magnética (RM) de gliomas cerebrales, las cuales dan entrada a varios clasificadores. Con el clasificador *Support Vector Machines* (SVM) alcanzaron la mayor precisión. Con la técnica propuesta, se logró una precisión del 96,19 % para los gliomas de alto grado y de 95,46 % para los gliomas de bajo grado. Para los gliomas de alto grado, la exactitud promedio, con el uso de las entradas que ofreció CNN, utilizando el clasificador *Random Forests*, osciló entre el 91,39 % y el 92,51 %. El clasificador *Naive Bayes*, con iguales entradas, tuvo el peor desempeño entre los cuatro clasificadores de este estudio. El SVM, con igual capa de entrada, tuvo el mejor desempeño entre los cuatro clasificadores probados, porque logró una exactitud promedio entre el 95,29 % y el 96,19 %, exactitud más alta lograda con la modalidad *Flair*, en la cual se obtuvo una precisión de 0,958, una sensibilidad de 0,851 y una medida F1 de 0,870.⁽⁸⁾

Cuando se aplicaron a imágenes de resonancia de gliomas de bajo grado, el rango de exactitud promedio para las cuatro clases (*Flair*, T1, T1c, T2) fue del 74,13 % a un máximo de 95,46 %. La aplicación del clasificador *Naive Bayes* logró la exactitud promedio más alta del 77,44 % para imágenes *Flair*; para SVM, la exactitud promedio más alta fue de 95,46 % con la modalidad T2. El SVM logró la exactitud promedio más alta (95,46 %) para las cuatro clases con una precisión de 0,890, una sensibilidad de 0,861 y una medida F1 de 0,889. En conclusión, el clasificador SVM utilizado junto con las características extraídas de CNN logró las exactitudes más altas de todos los clasificadores probados en ese trabajo.⁽⁸⁾

Un estudio propuso un enfoque totalmente automatizado en 3D para la segmentación del cerebro a partir de imágenes con ^{18}F -FET PET en pacientes con tumores gliales utilizando una arquitectura U-Net CNN, se reportó que hasta entonces probablemente sea la primera vez que este tipo de abordaje se utiliza con tomografía por emisión de positrones (PET).⁽⁹⁾ Este proceso se logró con un rendimiento relativamente alto dentro de los límites de la técnica, la cual incluyó a 37 pacientes (26 en el conjunto de entrenamiento, lo que representa el 70 %, y 11 en el conjunto de validación, lo que representa el 30 %). Las lesiones se detectaron con precisión sin falsos positivos, lo que resultó en una sensibilidad y una especificidad para la detección a nivel tumoral del 100 %. A nivel de vóxel, esta segmentación condujo a una sensibilidad de 0,88, una especificidad de 0,99, un valor predictivo positivo de 0,78 y un valor predictivo negativo de 0,99.⁽⁹⁾

Wei y otros⁽¹⁰⁾ diseñaron un estudio que tuvo como objetivo explorar el valor de la aplicación de la PET junto a la RM basada en la CNN en la biopsia y el tratamiento del glioma intracraneal. Se seleccionaron a 35 pacientes con diagnóstico preoperatorio de glioma cuyas imágenes fueron procesadas usando CNN para evaluar su desempeño. Los resultados sugirieron que la tecnología PET-MRI basada en CNN mostró una exactitud de reconocimiento del 97 %. Los autores concluyen que la fusión ^{11}C -MET PET-MRI basada en CNN puede mejorar el efecto de reconocimiento del glioma y determinar con mayor precisión el alcance de las lesiones. En ausencia de realce, hubo una ventaja significativa, especialmente en los gliomas de bajo grado. Sin embargo, debido al tamaño limitado de la muestra sugieren realizar futuros estudios sobre este particular.

Se diseñó un estudio con el propósito de desarrollar un método de clasificación basado en el aprendizaje profundo utilizando características radiómicas de los grados de gliomas con redes neuronales. Este estudio se centró principalmente en los cuatro aspectos principales del flujo de trabajo radiómico: la segmentación de tumores, la extracción de características, el análisis y la clasificación. El modelo propuesto fue eficaz para clasificar los gliomas con una exactitud del 96,15 %, una

precisión del 94,12 %, una sensibilidad del 100 %, una puntuación F1 del 96,97 % y un área bajo la curva ROC del 98,75 %.⁽¹¹⁾

Los métodos basados en el aprendizaje automático para diferenciar el linfoma primario del SNC de los gliomas mostraron un gran potencial, pero la mayoría de los estudios carecen de conjuntos de datos amplios, balance de clases y de validación externa. La evaluación de los estudios identificó múltiples deficiencias en la calidad del informe y el riesgo de sesgo. Estos factores reducen la generalización y la reproducibilidad de los resultados.⁽¹²⁾ La investigación que se presenta tiene en consideración las deficiencias que encontró esta revisión sistemática y realiza la validación cruzada por el método de *k fold cross validation* y el balance de clases a través de *Synthetic Minority Overampling Technique*.⁽¹³⁾

Un conjunto de datos estará desequilibrado si las categorías de clasificación no están representadas aproximadamente por igual. SMOTE es una técnica de sobremuestreo de minorías que funciona utilizando el algoritmo de *k*-vecino más cercano para crear datos sintéticos hasta que la clase minoritaria tenga aproximadamente la misma proporción que la clase mayoritaria.⁽¹³⁾

Ebrahimi y otros⁽¹⁴⁾ diseñaron un estudio con el objetivo de proporcionar un modelo calibrado para predecir la supervivencia de acuerdo con el esquema de tratamiento a pacientes con diagnóstico de glioblastoma. Propusieron un método basado en redes neuronales artificiales y algoritmos genéticos para predecir la supervivencia de pacientes con glioblastoma. Recopilaron e integraron datos de ocho ensayos clínicos para entrenar el modelo: de los 847 casos evaluables, 719 se usaron para entrenar y validar y los 128 casos restantes se usaron para prueba. El error absoluto medio de las predicciones sobre los datos de prueba fue de 0,087, lo que mostró un buen rendimiento del modelo propuesto para predecir la supervivencia de los pacientes. Además, los resultados mostraron que el algoritmo propuesto es superior a otros modelos existentes, tanto en la media como en la variabilidad del error de predicción.

La red neuronal artificial propuesta y entrenada para reconocer glioblastomas utilizando el perceptrón multicapa mediante biomarcadores extraídos de imágenes

de SPECT cerebral con ^{99m}Tc -MIBI en una base de datos de gliomas cerebrales tuvo un entrenamiento satisfactorio y excelentes métricas de rendimiento.

Referencias bibliográficas

1. Fordham AJ, Hacherl CC, Patel N, Jones K, Myers B, Abraham M, *et al.* Differentiating Glioblastomas from Solitary Brain Metastases: An Update on the Current Literature of Advanced Imaging Modalities. *Cancers*. 2021;13(12):2960. DOI: [10.3390/cancers13122960](https://doi.org/10.3390/cancers13122960)
2. Tan AC, Ashley DM, López GY, Malinzak M, Friedman HS, Khasraw M. Management of glioblastoma: State of the art and future directions. *CA: A Cancer Journal for Clinicians*. 2020;70(4):299-312. DOI: [10.3322/caac.21613](https://doi.org/10.3322/caac.21613)
3. Thust SC, Heiland S, Falini A, Jäger HR, Waldman AD, Sundgren PC, *et al.* Glioma imaging in Europe: A survey of 220 centres and recommendations for best clinical practice. *European Radiology*. 2018;28(8):3306-17. DOI: [10.1007/s00330-018-5314-5](https://doi.org/10.1007/s00330-018-5314-5).
4. Bruffaerts R. Machine learning in neurology: what neurologists can learn from machines and vice versa. *Journal of Neurology*. 2018;265(11):2745-8. DOI: [10.1007/s00415-018-8990-9](https://doi.org/10.1007/s00415-018-8990-9)
5. Bernstein A, Burnaev E, Kondratyeva E, Sushchinskaya S, Sharaev M, Andreev A, *et al.* Machine Learning pipeline for discovering neuroimaging-based biomarkers in neurology and psychiatry. *Proceedings of Machine Learning Research*, 2018;60:1-20. DOI: [10.48550/arXiv.1804.10163](https://doi.org/10.48550/arXiv.1804.10163)
6. Carleo G, Cirac I, Cranmer K, Daudet L, Schuld M, Tishby N, *et al.* Machine learning and the physical sciences. *Reviews of Modern Physics*. 2019;91(4). DOI: [10.1103/revmodphys.91.045002](https://doi.org/10.1103/revmodphys.91.045002)
7. Zander E, Ardeleanu A, Singleton R, Bede B, Wu Y, Zheng S. A functional artificial neural network for noninvasive pretreatment evaluation of glioblastoma patients. *Neuro-Oncology Advances*. 2021;4(1). DOI: [10.1093/noajnl/vdab167](https://doi.org/10.1093/noajnl/vdab167)

8. Latif G, Ben Brahim, G, Iskandar DNFA, Bashar A, Alghazo J. Glioma Tumors' classification using deep-neural-network-based features with SVM classifier. *Diagnostics*. 2022;1018. DOI: [10.3390/diagnostics12041018](https://doi.org/10.3390/diagnostics12041018)
9. Blanc Durand P, Van Der Gucht A, Schaefer N, Itti E, Prior JO. Automatic lesion detection and segmentation of 18F-FET PET in gliomas: A full 3D U-Net convolutional neural network study. Sherman JH, editor. *PLOS ONE*. 2018;13(4):e0195798. DOI: [10.1371/journal.pone.0195798](https://doi.org/10.1371/journal.pone.0195798)
10. Wei W, Ma L, Yang L, Lu R, Xi C. Artificial Intelligence Algorithm-Based Positron Emission Tomography (PET) and Magnetic Resonance Imaging (MRI) in the Treatment of Glioma Biopsy. Pallikonda Rajasekaran M, editor. *Contrast Media & Molecular Imaging*. 2022;2022:1-9. DOI: [10.1155/2022/5411801](https://doi.org/10.1155/2022/5411801)
11. Çınarer G, Emiroğlu BG, Yurttakal AH. Prediction of Glioma Grades Using Deep Learning with Wavelet Radiomic Features. *Applied Sciences*. 2020;10(18):6296. DOI: [10.3390/app10186296](https://doi.org/10.3390/app10186296)
12. Cassinelli Petersen GI, Shatalov J, Verma T, Brim WR, Subramanian H, Brackett A, et al. Machine Learning in Differentiating Gliomas from Primary CNS Lymphomas: A Systematic Review, Reporting Quality, and Risk of Bias Assessment. *American Journal of Neuroradiology*. 2022;43(4):526-33. DOI: [10.3174/ajnr.a7473](https://doi.org/10.3174/ajnr.a7473)
13. Chawla NV, Bowyer KW, Hall LO, Kegelmeyer WP. SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*. 2002;16:321-57. DOI: [10.1613/jair.953](https://doi.org/10.1613/jair.953)
14. Ebrahimi Zade A, Shahabi Haghighi S, Soltani M. A neuro evolutionary algorithm for patient calibrated prediction of survival in Glioblastoma patients. *Journal of Biomedical Informatics*. 2021;115:103694. DOI: [10.1016/j.jbi.2021.103694](https://doi.org/10.1016/j.jbi.2021.103694)

Conflicto de intereses

Los autores declaran no tener conflicto de intereses.

Contribución de los autores

Conceptualización: Roberto León Castellón, Juan Miguel Martin Escuela, Silvia Salva Camaño, Nelson Gómez Viera, Adlín López Díaz.

Confeción de la data: Roberto León Castellón, Juan Miguel Martin Escuela.

Análisis formal: Roberto León Castellón, Juan Miguel Martin Escuela.

Redacción: Roberto León Castellón, Juan Miguel Martin Escuela, Silvia Salva Camaño, Lisette Mejías Pérez, Lester Rodríguez Paleo, Yanaisa Sánchez Caballero, Denia Bonilla Padrón, Nelson Gómez Viera, Adlín López Díaz.

Revisión: Roberto León Castellón, Juan Miguel Martin Escuela, Silvia Salva Camaño, Lisette Mejías Pérez, Lester Rodríguez Paleo, Yanaisa Sánchez Caballero, Denia Bonilla Padrón, Nelson Gómez Viera, Adlín López Díaz.