


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

Roberto León Castellón, Juan Miguel Martín Escuela, Lester Rodríguez Paleo, Lissette Mejías Pérez, Yanaisa Sánchez Caballero, Denia Bonilla Padrón, Nelson Gómez Viera, Laura Herrera Prado, Gissel García Menéndez, Adlín López Díaz.



Machine learning and the physical sciences^{*}

Giuseppe Carleo, Ignacio Cirac, Kyle Cranmer, Laurent Daudet, Maria Schuld, Naftali Tishby, Leslie Vogt-Maranto, and Lenka Zdeborová

Rev. Mod. Phys. **91**, 045002 – Published 6 December 2019

La última década ha visto un aumento prodigioso de las técnicas basadas en el aprendizaje automático (ML), que han tenido un impacto en muchas áreas de la industria, incluida la conducción autónoma, la atención médica, las finanzas, la fabricación, la recolección de energía y más.

El éxito del ML en los últimos tiempos 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 ML en tareas especializadas



New York Boston San Francisco
London Toronto Sydney Tokyo Singapore Madrid
Mexico City Munich Paris Cape Town Hong Kong Montreal

Machine Learning pipeline for discovering neuroimaging-based biomarkers in neurology and psychiatry

Alexander Bernstein, Evgeny Burnaev, Ekaterina Kondratyeva, Svetlana Sushchinskaya, Maxim Sharaev, Alexander Andreev, Alexey Artemov, Renat Akzhigitov

Proceedings of Machine Learning Research 60:1–20, 2018

La inteligencia artificial (IA), el aprendizaje automático (ML) y las técnicas de análisis inteligente de datos se utilizan 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.

Los biomarcadores (características que se miden y evalúan objetivamente como indicador de procesos biológicos normales, procesos patogénicos o respuestas farmacológicas a una intervención terapéutica) son componentes clave de la medicina moderna.

State of the Art: Machine Learning Applications in Glioma Imaging

Keywords: brain lesion segmentation, deep learning, glioma, machine learning, radiomics

doi.org/10.2214/AJR.18.20218

Received June 4, 2018; accepted after revision August 2, 2018.

¹Department of Radiology, New York University Langone Medical Center, 660 1st Ave, Rm 336, New York, NY 10016. Address correspondence to Y. W. Lui (Yvonne.Lui@nyumc.org).

²Population Health Department, NYU Langone Medical Center, New York, NY.

This article is available for credit.

AJR 2019; 212:26–37

0361–803X/19/2121–26


© American Roentgen Ray Society

OBJECTIVE. Machine learning has recently gained considerable attention because of promising results for a wide range of radiology applications. Here we review recent work using machine learning in brain tumor imaging, specifically segmentation and MRI radiomics of gliomas.


CONCLUSION. We discuss available resources, state-of-the-art segmentation methods, and machine learning radiomics for glioma. We highlight the challenges of these techniques as well as the future potential in clinical diagnostics, prognostics, and decision making.

La inteligencia artificial se está convirtiendo cada vez más en una parte de la vida cotidiana. Esto plantea la cuestión de si la neurooncología puede beneficiarse de estos métodos novedosos para aumentar la precisión diagnóstica.

FUSION SPECT-MRI




COEXISTE RADIONECROSIS Y RECIDIVA TUMORAL





RADIONECCROSIS CEREBELOSA Y BULBO PROTUBERANCIAL



Panorama 0.23 T Power H Hosp. Calixto Garcia
Ex: 2014120913312812 FUENTES TAZA OSMANI
Se: 13414879 12/09/14
Im: 9 300 rows, 270 cols
DFOV 250.0 mm



Panorama 0.23 T Power H Hosp. Calixto Garcia
Ex: 2014120913312812 FUENTES TAZA OSMANI
Se: 13414879 12/09/14
Im: 11 300 rows, 270 cols
DFOV 250.0 mm



RADIONECROSIS CEREBELOSA Y BULBO PROTUBERANCIAL




100 %

5 %


CPS	Total	45 ROI A
Cuentas	Total	4.154 ROI A
%	ROI A	0:01:32

Max Ratio
---:---


CPS	Total	29 ROI A
Cuentas	Total	2.645 ROI A
%	ROI A	0:01:31




SPECT CEREBRAL CON 99 Tc- MIBI PARA DIFERENCIAR UNA LESIÓN VASCULAR DE UN TUMOR CEREBRAL








SPECT CEREBRAL CON 99 Tc- MIBI PARA DIFERENCIAR UNA LESIÓN VASCULAR DE UN TUMOR CEREBRAL




SPECT CEREBRAL CON 99 Tc- MIBI PARA DISCRIMINAR ENTRE INFILTRACIÓN TUMORAL Y ABSCESO CEREBRAL



SPECT CEREBRAL CON 99 Tc- MIBI PARA DISCRIMINAR ENTRE INFILTRACIÓN TUMORAL Y ABSCESO CEREBRAL







SPECT CEREBRAL CON 99 Tc- MIBI PARA DISCRIMINAR ENTRE INFILTRACIÓN TUMORAL Y ABSCESO CEREBRAL







SPECT – CT


Junio 2017



SPECT – CT

Junio 2017





OBJETIVO

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.

SMOTE: Synthetic Minority Over-sampling Technique

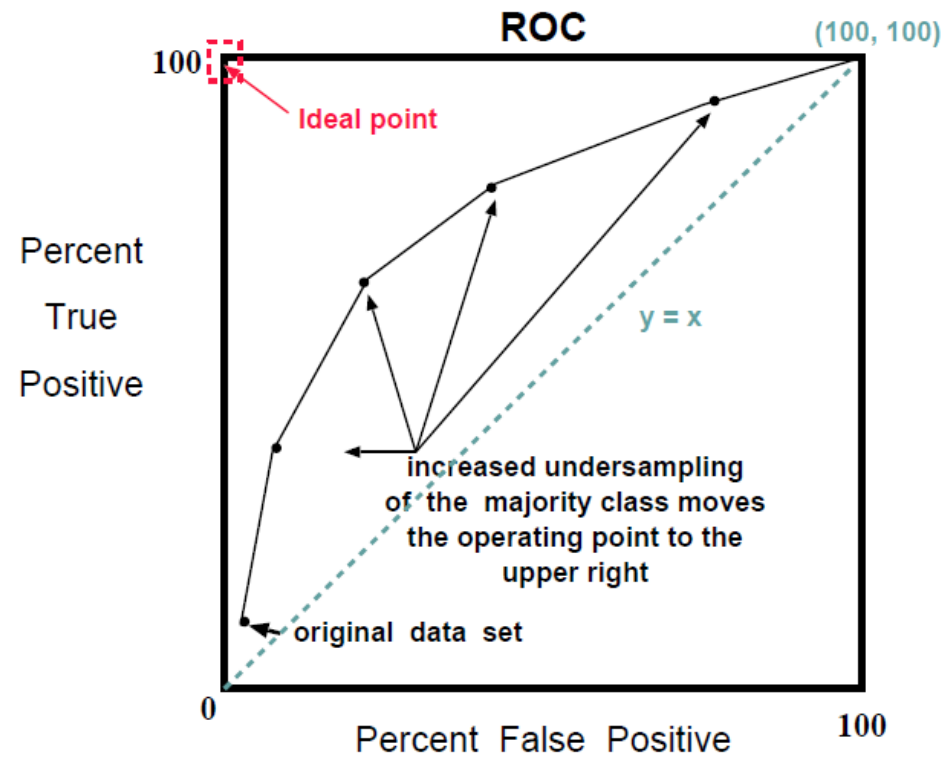
CHAWLA, BOWYER, HALL & KEGELMEYER

Abstract


An approach to the construction of classifiers from imbalanced datasets is described.

The performance of machine learning algorithms is typically evaluated using predictive accuracy. However, this is not appropriate when the data is imbalanced and/or the costs of different errors vary markedly. As an example, consider the classification of pixels in mammogram images as possibly cancerous (Woods, Doss, Bowyer, Solka, Priebe, & Kegelmeyer,

ROC




Mammography ROC with C4.5



k-fold cross-validation explained in plain English (For evaluating a model's performance and hyperparameter tuning)

Rukshan Manorathna
University of Colombo






Figura 1. Red neuronal con perceptrón multicapa para clasificar glioblastomas utilizando parámetros medidos con 99mTc-MIBI SPECT Cerebral.

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

	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

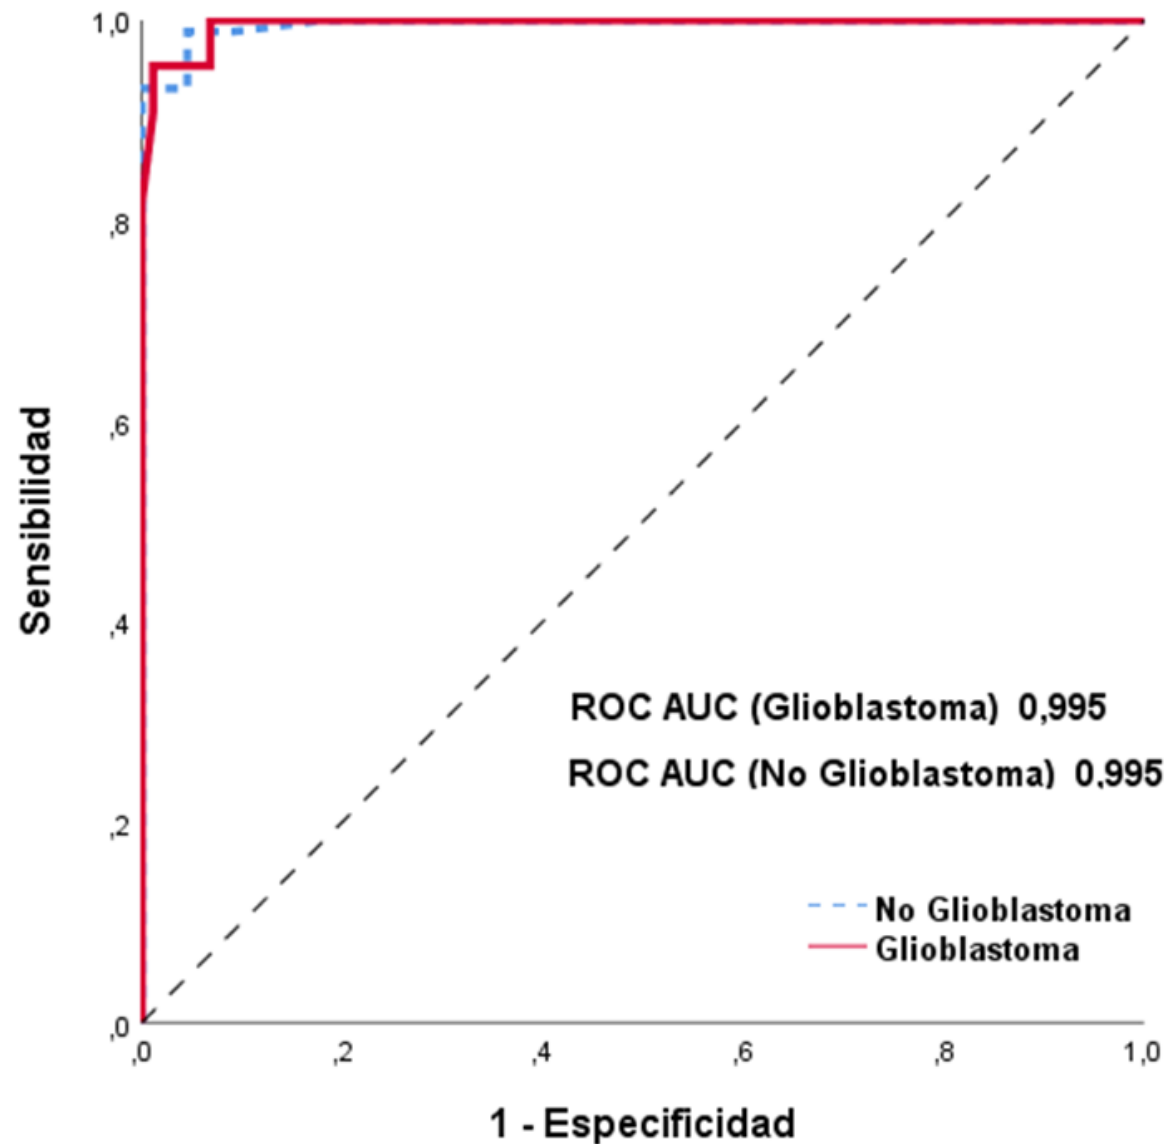
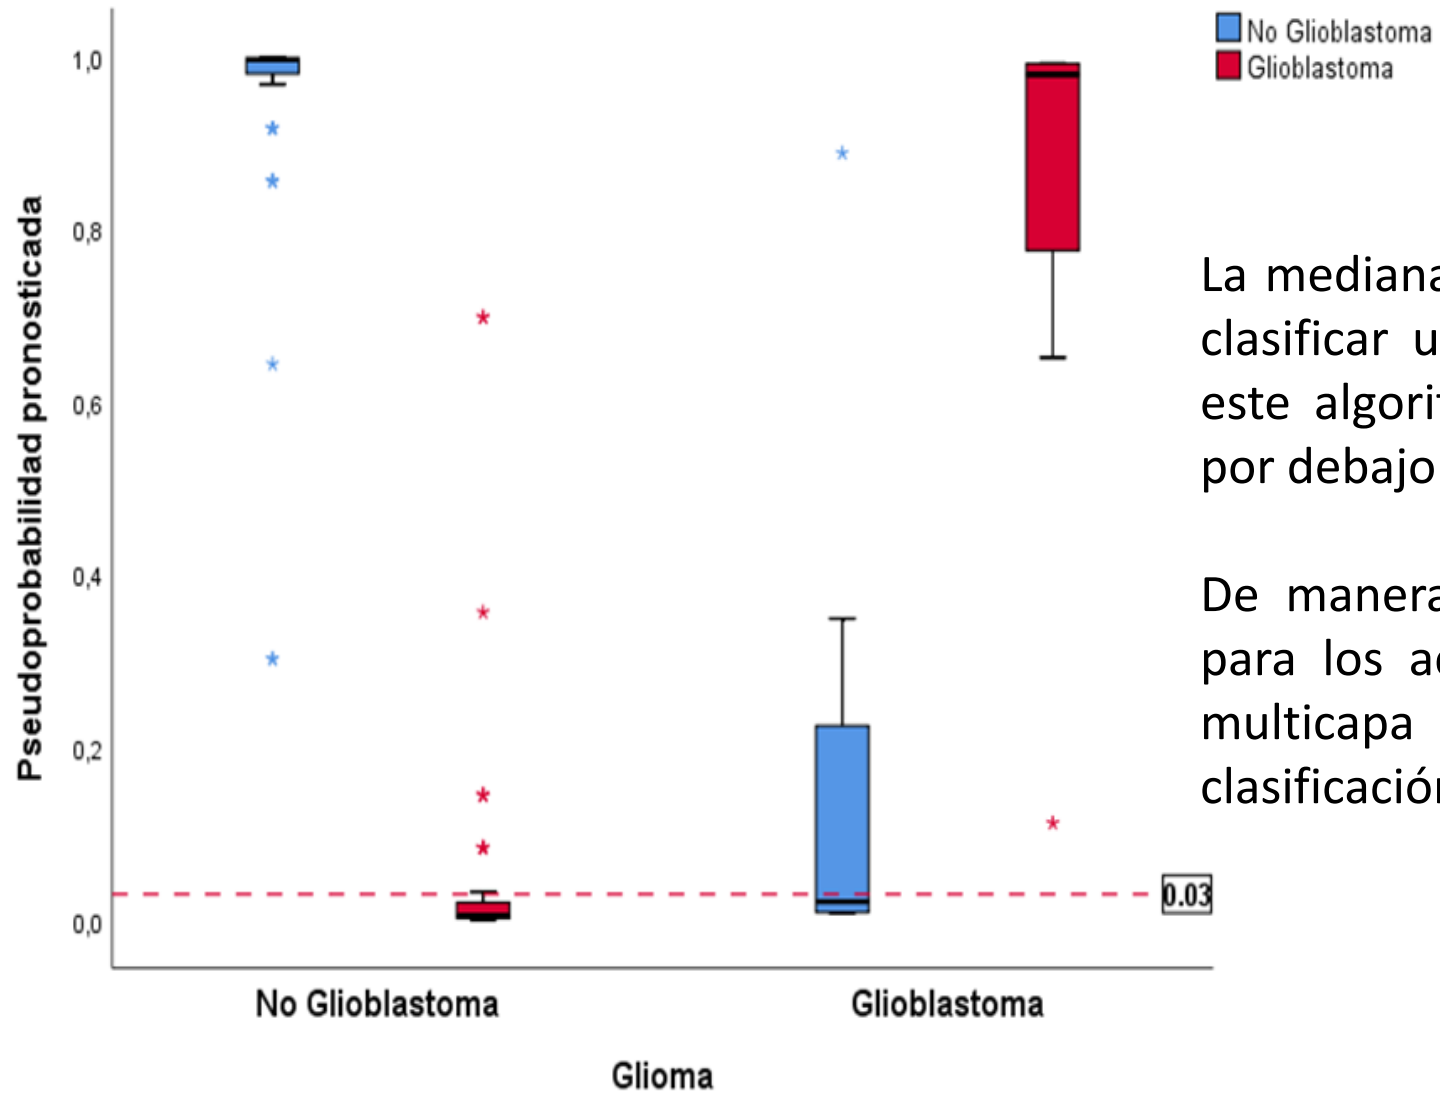


Gráfico 1. Curvas ROC para clasificar las clases glioblastoma y no glioblastoma utilizando el perceptrón multicapa.



La mediana de la pseudoprobabilidad 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 pseudoprobabilidad pronosticada para los aciertos en la clasificación por el perceptrón multicapa es alta y muy baja para los errores de clasificación.

Gráfico 2. Pseudoprobabilidad pronosticada para la clasificación con el perceptrón multicapa en función de la clasificación histológica.

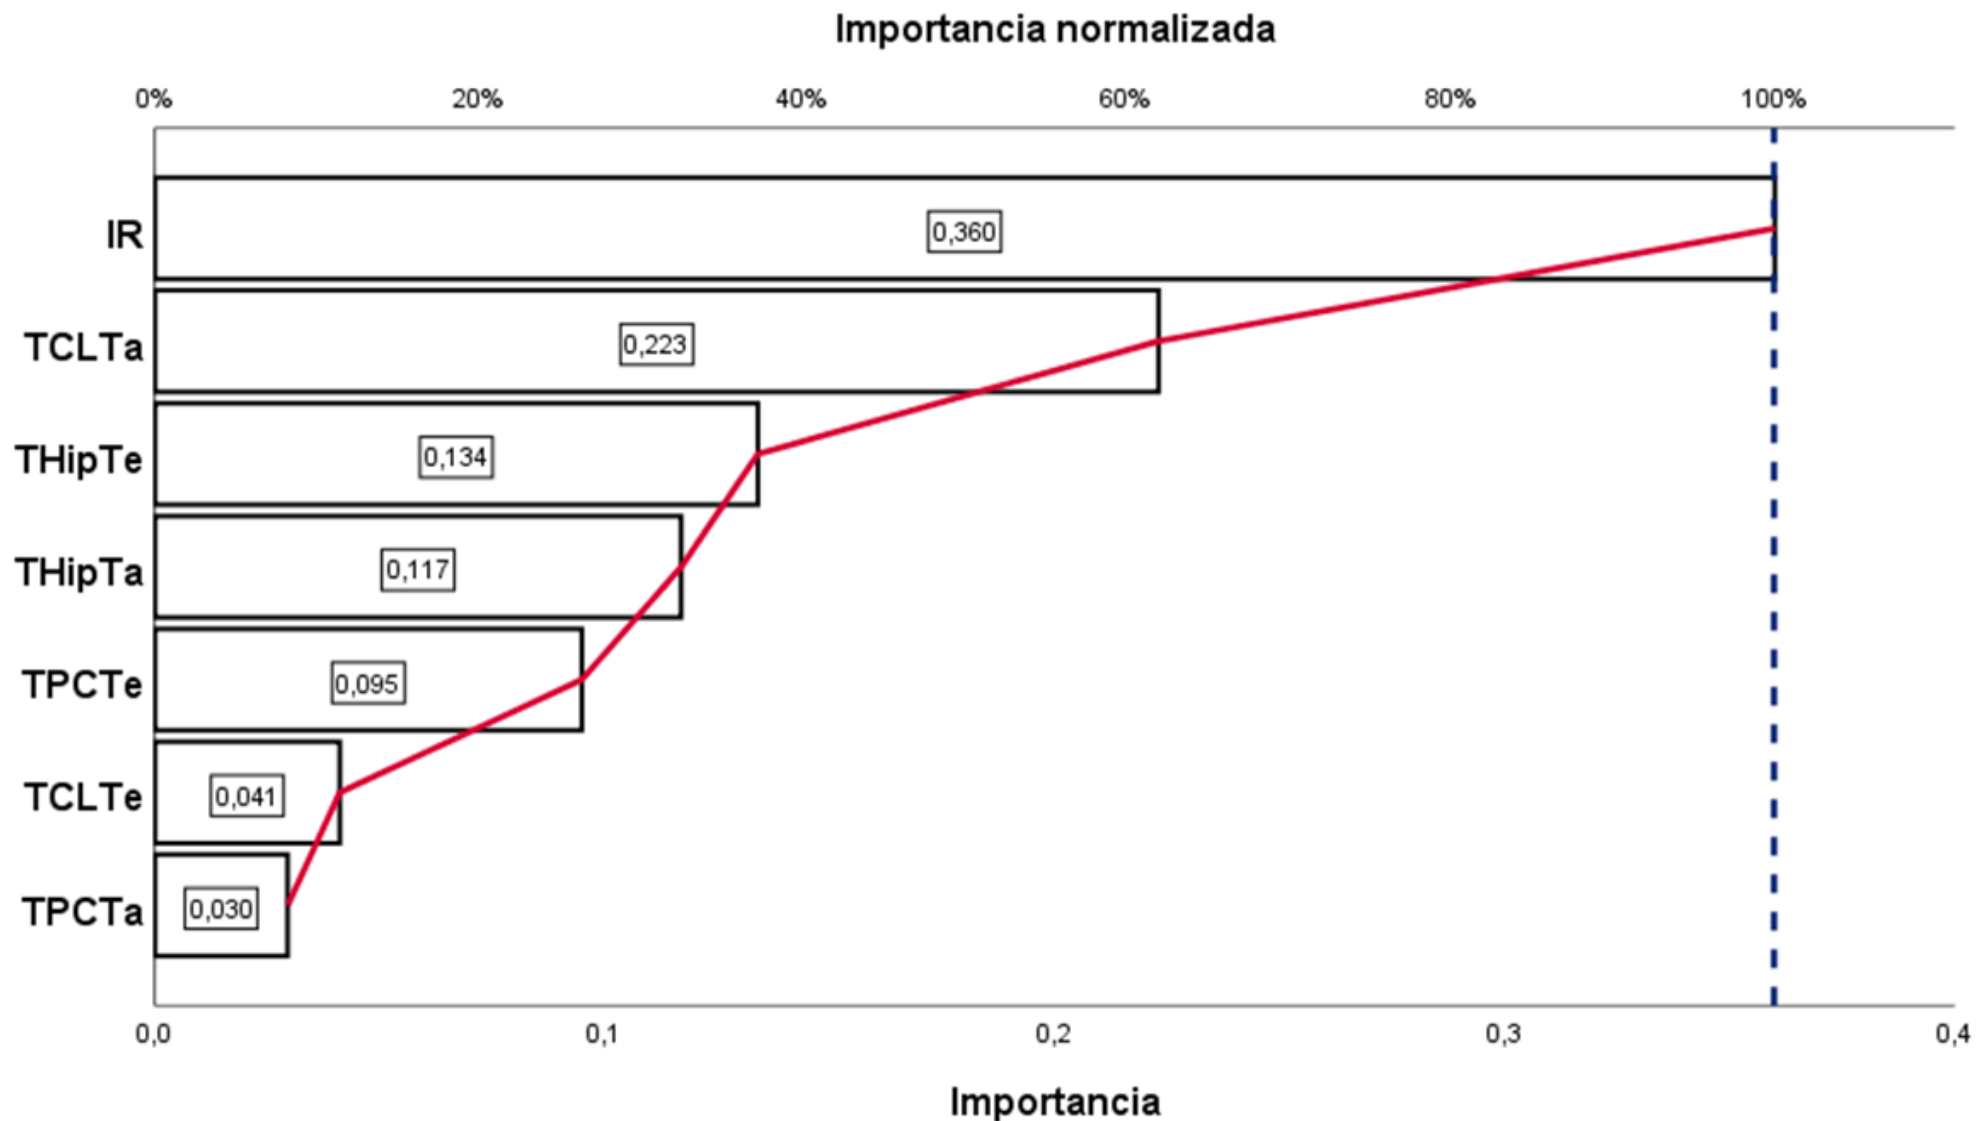


Gráfico 3. Importancia normalizada de cada una de las variables consideradas en la clasificación de glioblastomas con el perceptrón multicapa.

	5-Fold-cross-validation (tiempo = 0,08 segundos)		Reevaluación del modelo con la data inicial de prueba
Accuracy (%)	(k1)	93,333	
	(k2)	96,538	97,059
	(k3)	92,942	
	(k4)	90,025	
	(k5)	93,852	
		93,388	
Error (%)		6,612	2,941
Kappa		0,868	0,905
TP Rate		0,934	0,971
FP Rate		0,067	0,113
Precisión		0,936	0,972
Recall		0,934	0,971
F-Measure		0,934	0,970
MCC		0,870	0,909
ROC Area		0,984	1,000
PRC Area		0,985	1,000

Tabla 2. Resultados de las métricas en la validación.

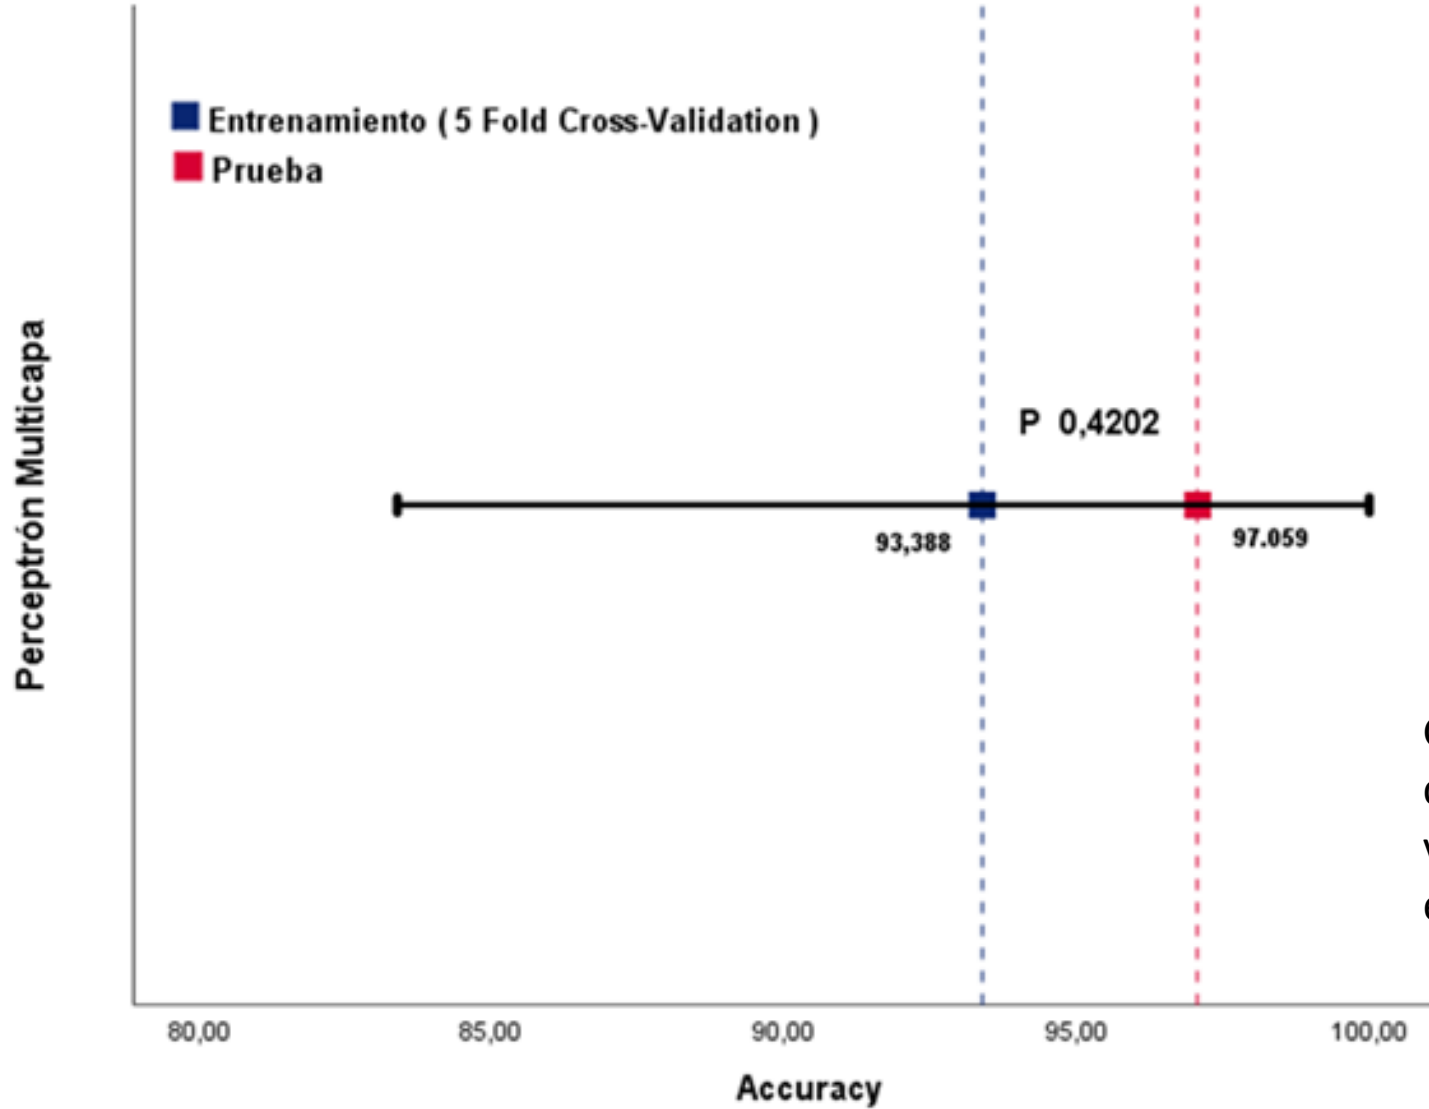


Gráfico 4. Diferencia entre instancias correctamente clasificadas en el entrenamiento de la data de validación con 5-fold-cross-validation y de prueba con el perceptrón multicapa. (Forest Plot)

CONCLUSIONES

La red neuronal artificial propuesta y entrenada con el propósito de reconocer/clasificar 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, muestra excelentes métricas de rendimiento.