

DIFERENCIACIÓN DE LESIONES PAROTÍDEAS BENIGNAS Y MALIGNAS MEDIANTE INTELIGENCIA ARTIFICIAL

Chiara Santini¹, Ana Belén Cendrero Camacho¹, Javier Pérez Lara², José Pablo Martínez Barbero³, Manuel Ramos⁴, Eva Briceño García¹, Manuel Cayetano Fortuny Pinto¹, Almudena Pérez Lara¹

¹Hospital Regional Universitario de Málaga, **Málaga**

² Departamento de Ingeniería, Universidad de Loyola, **Sevilla**

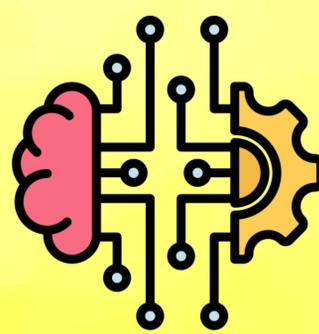
³ Hospital Universitario Virgen de las Nieves, **Granada**

⁴ Hospital Universitario Reina Sofía, **Córdoba**

Las lesiones tumorales parotídeas son relativamente frecuentes, existiendo un diverso rango de entidades benignas y malignas. Las lesiones más frecuentes son el Adenoma Pleomorfo, el Tumor de Warthin y el Carcinoma Mucoepidermoide.

OBJETIVOS

El objetivo de este trabajo es valorar la posibilidad de diferenciar estas tres entidades en imágenes de TC mediante análisis de textura empleando algoritmos de **Machine Learning (ML)**.



MATERIAL & MÉTODO

Se seleccionaron **47** pacientes con lesiones parotídeas

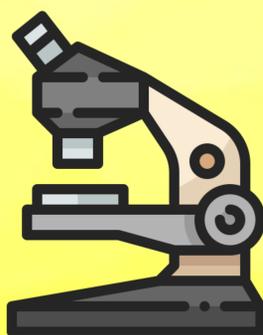
- 15** Adenomas Pleomorfos
- 15** Tumores de Warthin
- 17** Carcinomas Mucoepidermoides

CRITERIOS DE INCLUSIÓN

- **Diagnóstico histopatológico** de Adenoma Pleomorfo, Tumor de Warthin o Carcinoma Mucoepidermoide de parótida.
- **TC de cuello con contraste prequirúrgico**, realizado con técnica similar (reconstrucciones axiales de 0,625 mm, 80 ml de iohexol, delay 70 segundos).

CRITERIOS DE EXCLUSIÓN

- TC de cuello **sin** contraste o con espesor de corte de mayor grosor al seleccionado (2 mm, 3 mm, 5 mm)
- **Ausencia** de confirmación anatomopatológica
- Pacientes **no** candidatos a cirugía



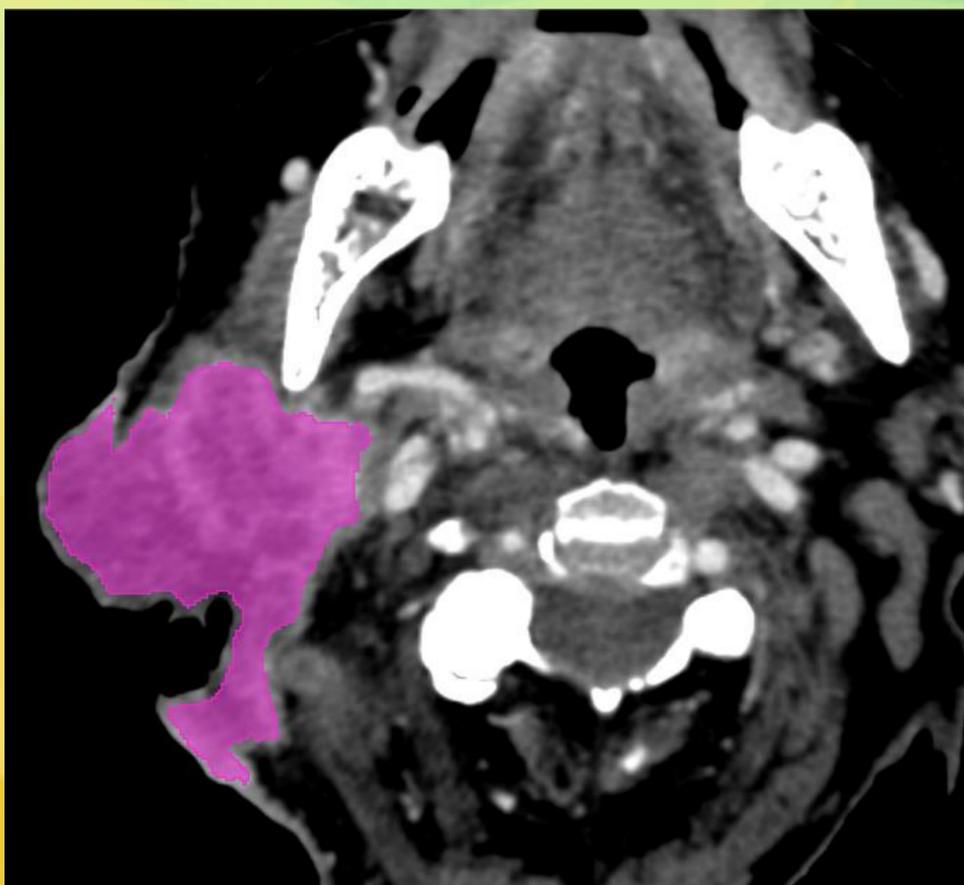
MATERIAL & MÉTODO

SEGMENTACIÓN

Empleando el software **3D Slicer v4.11.20210226**, libre y de código abierto para análisis de imágenes, se realizó una segmentación volumétrica de las lesiones.

No se incluyó en el área segmentada zonas con material quirúrgico, hueso, aire ni estructuras vasculares prominentes.

Todas las segmentaciones fueron realizadas por una residente de radiodiagnóstico y revisadas por una radióloga especializada en cabeza y cuello.



Ejemplo de segmentación manual de carcinoma **mucoepidermoide** de parótida derecha.

Imagen axial de TC donde se muestra una lesión ulcerada que afecta al lóbulo superficial y profundo de la parótida. Se incluyó la totalidad de la lesión evitando áreas de ulceración.

MATERIAL & MÉTODO

EXTRACCIÓN DE DATOS

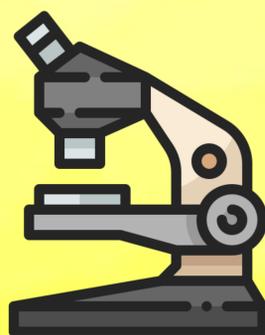
Se extrajeron estadísticos de **primer orden** del área segmentada, incluyendo la curtosis, percentil 10, percentil 90, entropía, rango intercuartílico, densidad máxima y mínima, media de densidad, mediana de densidad, desviación media absoluta, varianza, energía total, uniformidad y asimetría (skewness).

PROCESADO Y ANÁLISIS DE DATOS

Se realizó un procesado con **Python**, ejecutando un análisis de **regresión logística** y generando **diversos clasificadores de ML**.

Se calculó la precisión, la sensibilidad, la especificidad, el valor predictivo positivo y el valor predictivo negativo de cada modelo de Machine Learning.

El **75%** de la muestra se seleccionó de forma aleatoria para el set de **entrenamiento** y el **25%** para el **set de test**.



RESULTADOS

	Número	Edad media	Hombres	Mujeres
T. Warthin	15	62,7	12	3
Ad. Pleomórfico	15	57,97	9	6
Carcinoma mucoepidermoide	17	59,44	10	7

Se reclutaron un total de
15 tumores de Warthin,
15 pleomórficos
17 carcinomas mucoepidermoides.



La edad media de los pacientes fue similar entre los diferentes tipos de tumores, siendo las diferencias no estadísticamente significativas.

Existía una mayor proporción de **hombres** en los tumores de **Warthin** que en el resto de lesiones. Estas diferencias fueron estadísticamente significativas (Chi2, $p < 0,05$) y se reflejan en la literatura.

RESULTADOS

REGRESIÓN LOGÍSTICA

El análisis de regresión logística basado en las características de radiómica presentó una **baja** precisión para diferenciar entre los tres tipos de lesiones. La precisión alcanzada fue del **47%**, con una sensibilidad del 62% y una especificidad del 30%. Estos valores hacían que no fuese un clasificador válido para diferenciar los tres tipos de lesiones parotídeas.

	feature	correlation	abs_correlation	significance	significant
8	Maximum	-0.307565	0.307565	0.047544	True
10	90Percentile	-0.185376	0.185376	0.239860	False
3	Median	-0.173041	0.173041	0.273131	False
17	Mean	-0.167102	0.167102	0.290182	False
15	10Percentile	-0.161245	0.161245	0.307660	False
0	InterquartileRange	-0.135644	0.135644	0.391712	False
5	RobustMeanAbsoluteDeviation	-0.121749	0.121749	0.442440	False
11	Minimum	-0.114995	0.114995	0.468348	False
14	Variance	0.103797	0.103797	0.513016	False
12	Entropy	-0.088009	0.088009	0.579424	False
6	MeanAbsoluteDeviation	0.085112	0.085112	0.592016	False
2	Uniformity	0.084606	0.084606	0.594226	False
7	TotalEnergy	0.083333	0.083333	0.599810	False
4	Energy	0.081908	0.081908	0.606084	False
13	Range	0.077879	0.077879	0.623972	False
16	Kurtosis	0.049961	0.049961	0.753364	False
9	RootMeanSquared	0.044614	0.044614	0.779059	False
1	Skewness	-0.002365	0.002365	0.988142	False

VARIABLES EMPLEADAS EN EL ANÁLISIS DE REGRESIÓN LOGÍSTICA, CON LA SIGNIFICACIÓN DE CADA UNA DE ELLAS.

La única característica relevante para diferenciar entre los tres tipos de lesiones fue la **densidad máxima**.

RESULTADOS

MODELOS DE MACHINE LEARNING

MODELO	PRECISIÓN	SENSIBILIDAD	ESPECIFICIDAD
K Means	52%	60%	33%
Random Forest	47%	50%	45%
Support Vector Machine	34%	40%	33%
Ada Boost	57%	40%	60%
Voting diagnostic performance measurements	45%	62%	0%

Los diferentes **modelos** de ML aportaron una baja precisión, sensibilidad y especificidad para la diferenciación de lesiones parotídeas.

El mejor modelo fue **Ada Boost**, con una precisión del **57% (baja)** y sensibilidad y especificidad del 40% y 60% respectivamente.

RESULTADOS

DIFERENCIACIÓN DE LESIONES BENIGNAS VS CARCINOMA MUCOEPIDERMÓIDE

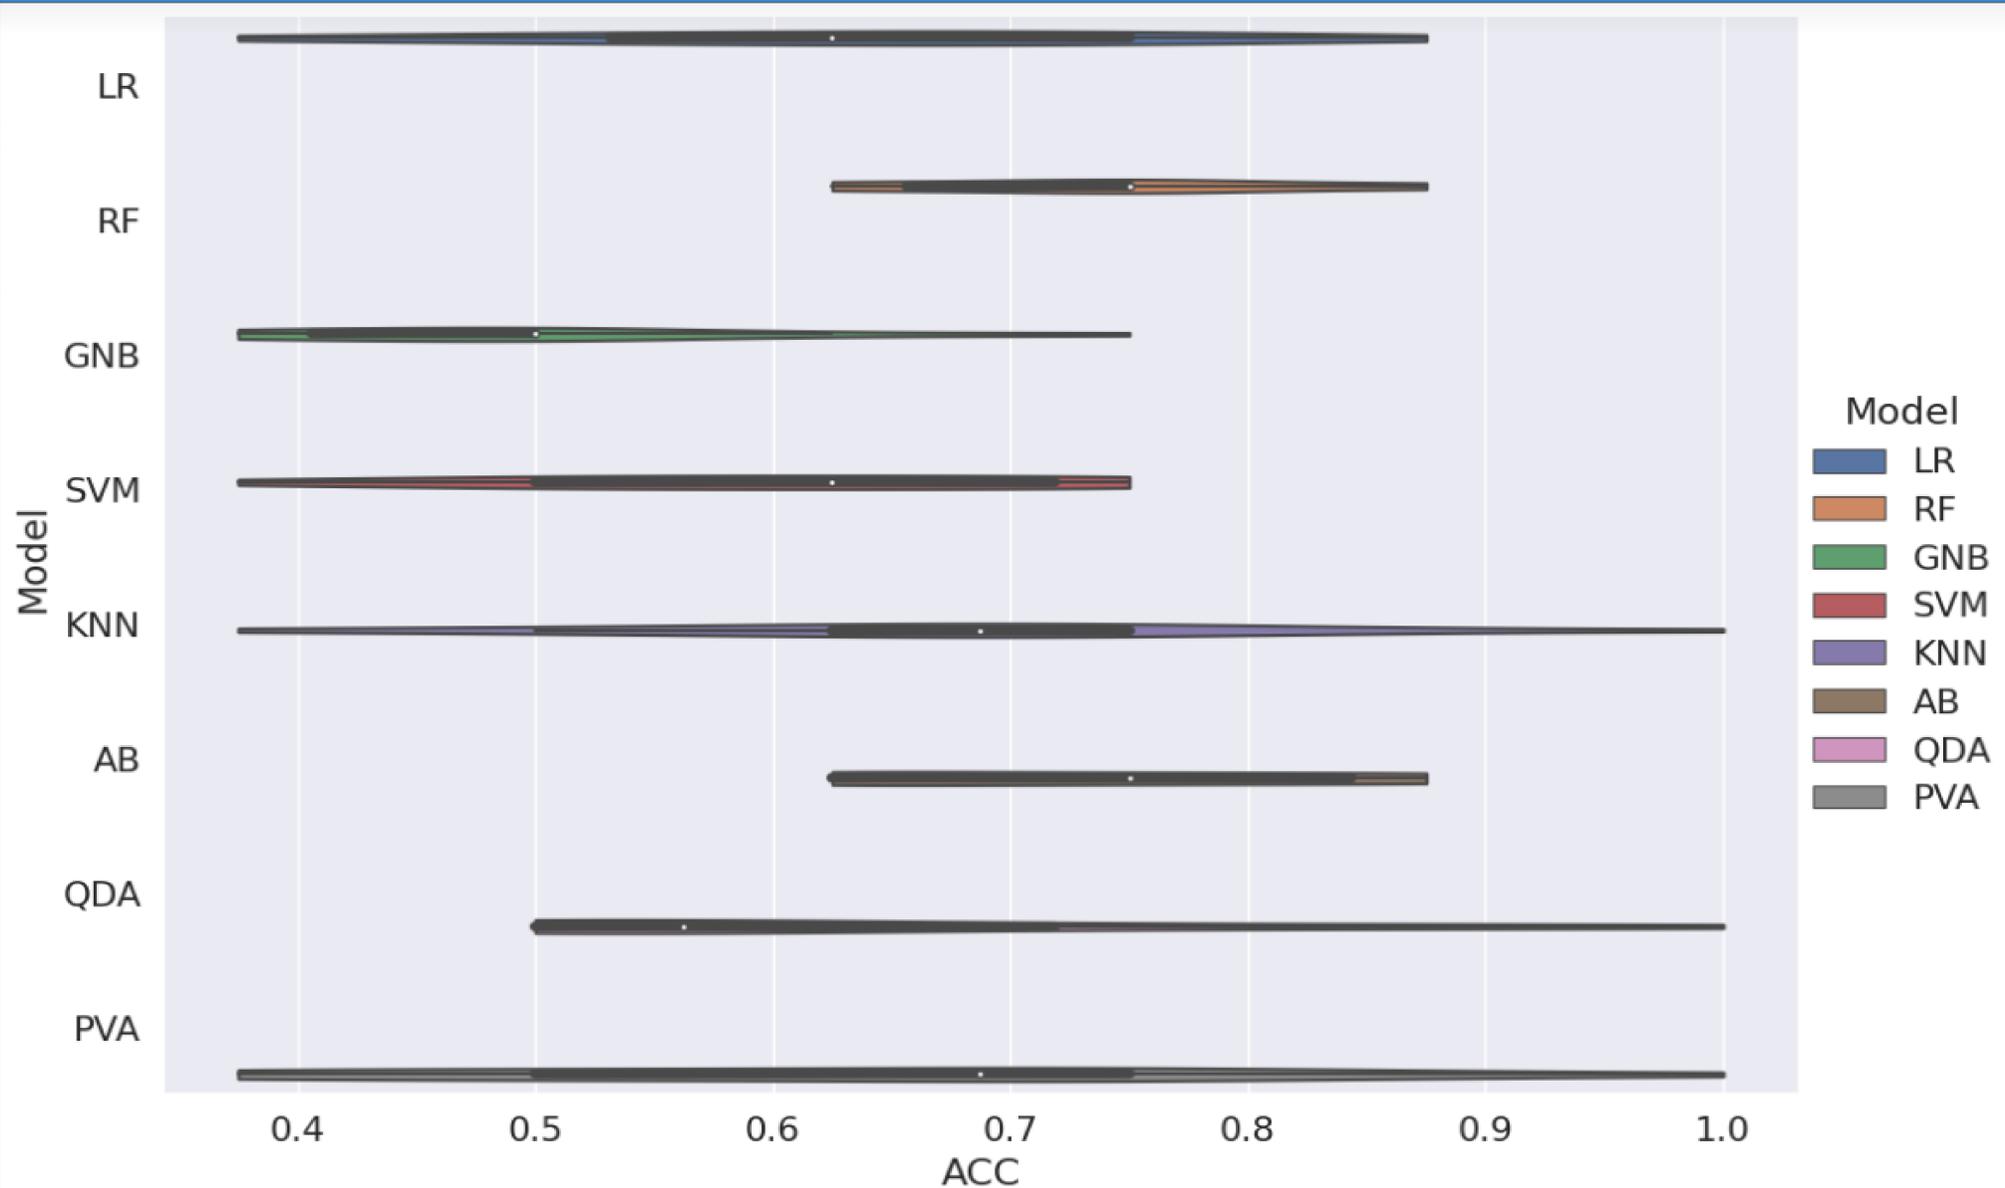
CLASIFICADOR	PRECISIÓN	SENSIBILIDAD	ESPECIFICIDAD
K-nearest neighbours	62%	40%	100%
Ada Boost	75%	100%	33%
Random Forest	50%	60%	33%

Se entrenaron múltiples **clasificadores**, incluyendo regresión logística, K-nearest neighbours, Ada Boost, Random Forest y Support Vector Machine entre otros. La diferenciación entre tumores benignos (Warthin + pleomórfico) y carcinoma mucoepidermoide alcanzó tasas de predicción del **75%** (buena) con el clasificador **Ada Boost**.

La sensibilidad era del 100% por lo que detectaba todas las lesiones malignas.

RESULTADOS

DIFERENCIACIÓN DE LESIONES BENIGNAS VS CARCINOMA MUCOEPIDERMÓIDE



Se realizó un procedimiento de **validación interna** con los datos disponibles.

Ada Boost consiguió una precisión más acotada y mejor posicionada al testear con **10 casos al azar**, en comparación con el resto de modelos. Otros métodos se dispersan en exceso, mostrando que el agrupamiento que se realiza entre grupo de training y test hace que los resultados no sean fiables.

DISCUSIÓN Y CONCLUSIONES

Este estudio presenta importantes **limitaciones**, incluyendo el pequeño tamaño muestral y la limitación de su aplicabilidad a estudios realizados con la misma técnica de imagen.

Los clasificadores de ML generados presentaban una **baja** precisión para diferenciar entre tumor de Warthin, adenoma pleomorfo y carcinoma mucoepidermoide de la parótida.

Sin embargo, la radiómica permite realizar una diferenciación **aceptable** entre los tumores benignos y malignos más frecuentes de la parótida con TC, pudiendo distinguir con cierta precisión entre tumores de Warthin y adenomas pleomórficos respecto a carcinomas mucoepidermoides.

La alta sensibilidad demostrada por Ada Boost en identificar los carcinomas mucoepidermoides puede ser un instrumento útil en una fase de cribaje de esta patología, sobre todo cuando se presenta en localizaciones profundas y de difícil abordaje para biopsia.

Es preciso ampliar el **tamaño muestral** para mejorar la precisión de los algoritmos y extender este estudio a imagen por **RM** para valorar si esta técnica presenta datos robustos que permitan aumentar los datos de precisión, sensibilidad y especificidad en la diferenciación de tumores parotídeos.

REFERENCIAS

- Wong, A. J., Kanwar, A., Mohamed, A. S., & Fuller, C. D. (2016). *Radiomics in head and neck cancer: from exploration to application*. *Translational cancer research*, 5(4), 371.
- Mukherjee, P., Cintra, M., Huang, C., Zhou, M., Zhu, S., Colevas, A. D., Gevaert, O. (2020). *CT-based radiomic signatures for predicting histopathologic features in head and neck squamous cell carcinoma*. *Radiology: Imaging Cancer*, 2(3), e190039.
- Zheng, Y. M., Xu, W. J., Hao, D. P., Liu, X. J., Gao, C. P., Tang, G. Z., Dong, C. (2021). *A CT-based radiomics nomogram for differentiation of lympho-associated benign and malignant lesions of the parotid gland*. *European Radiology*, 31, 2886-2895.
- Zheng, Y., Zhou, D., Liu, H., & Wen, M. (2022). *CT-based radiomics analysis of different machine learning models for differentiating benign and malignant parotid tumors*. *European radiology*, 32(10), 6953-6964.
- Liu, Y., Zheng, J., Lu, X., Wang, Y., Meng, F., Zhao, J., Zhang, T. (2021). *Radiomics-based comparison of MRI and CT for differentiating pleomorphic adenomas and Warthin tumors of the parotid gland: a retrospective study*. *Oral Surgery, Oral Medicine, Oral Pathology and Oral Radiology*, 131(5), 591-599.
- Al Ajmi, E., Forghani, B., Reinhold, C., Bayat, M., & Forghani, R. (2018). *Spectral multi-energy CT texture analysis with machine learning for tissue classification: an investigation using classification of benign parotid tumours as a testing paradigm*. *European radiology*, 28, 2604-2611.