

# ANÁLISIS DE TEXTURA PARA DIFERENCIAR CARCINOMA ESCAMOCELULAR Y BASOCELULAR DE LA PIEL.-

Carmen Morales Puerta<sup>1</sup>, Pablo Sebastián Castilla Fernández<sup>1</sup>, Ana Belén Cendrero Camacho, Javier Pérez Lara<sup>2</sup>, Eva Briceño García, Almudena Pérez Lara

<sup>1</sup>Hospital Regional Universitario de Málaga.

<sup>2</sup>Departamento de Ingeniería, Universidad de Loyola

**37** Congreso  
Nacional  
CENTRO DE  
CONVENCIONES  
INTERNACIONALES

Barcelona  
22/25  
MAYO 2024

**seram**  
Sociedad Española de Radiología Médica

**ferm**  
FEDERACIÓN ESPAÑOLA DE  
FISICOS DE MEDICINA NUCLEAR

**RC** | RADIOLOGOS  
DE CATALUNYA

**No hay conflicto de interés.**

# ÍNDICE.-

1.- Objetivos.-

2.- Materiales y métodos.-

3.- Resultados.-

4.- Conclusiones.-

## OBJETIVOS.-

- El carcinoma escamocelular y el carcinoma basocelular son los tumores no melanocíticos más frecuentes en piel.
- Su apariencia en imagen por TC es similar y no muestran signos distintivos más allá de los focos hiperecogénicos característicos del carcinoma escamocelular en ecografía.
- Recientemente se han desarrollado múltiples algoritmos de Machine Learning (ML) basados en radiómica para identificación de lesiones tumorales en el área de cabeza y cuello, pero no existen publicaciones sobre su utilidad en la diferenciación del carcinoma escamocelular y basocelular de la piel.
- El objetivo de este trabajo es determinar si la radiómica en imágenes de TC es útil en la diferenciación de estos dos tipos de tumores cutáneos.

# MATERIALES Y MÉTODOS.-

## ● CRITERIOS DE INCLUSIÓN:

- Pacientes con carcinoma escamocelular y basocelular de la piel, todos ellos con resultado de anatomía patológica disponible y que tuviesen un TC de cuello con contraste prequirúrgico con técnica similar (rec 0,625 mm) entre 2012 y 2023.

## ● CRITERIOS DE EXCLUSIÓN:

- Pacientes con otro tipo de carcinoma de piel que no sea escamocelular o basocelular.
- Pacientes que no dispongan de resultados de anatomía patológica.
- Pacientes que no dispongan de TC de cuello prequirúrgico.
- Excesivo artefacto en imagen de TC.

# MATERIALES Y MÉTODOS.-

Se revisó la historia clínica de los pacientes recogiendo datos demográficos.

Se descargaron las imágenes de cada paciente en formato DICOM para su posterior segmentación.

Para la segmentación se empleó el software 3D Slicer. Se realizó una segmentación manual de toda la lesión por una residente de radiodiagnóstico, con supervisión por una radióloga especialista en cabeza y cuello.

Se excluyeron áreas de ulceración, artefacto metálico / movimiento y estructuras vasculares prominentes.



# MATERIALES Y MÉTODOS.-

Se extrajeron datos de radiómica (estadísticos de primer orden) de cada tumor segmentado con 3D Slicer.

Se generaron diversos clasificadores de Machine Learning (ML) con Python empleando los datos extraídos. El objetivo era valorar la posibilidad de diferenciación entre ambos tumores con datos de radiómica.


El 75% de los datos se empleó en el set de entrenamiento y el 25% en el set de test. Se realizó una validación interna con método out-of-bags.

Previamente se realizó un análisis de las variables con regresión logística.

# RESULTADOS.-


% casos por sexo

● Hombre ● Mujer




% invasión estructuras profundas

● NO ● SI



% MTX linfáticas

● NO ● SI


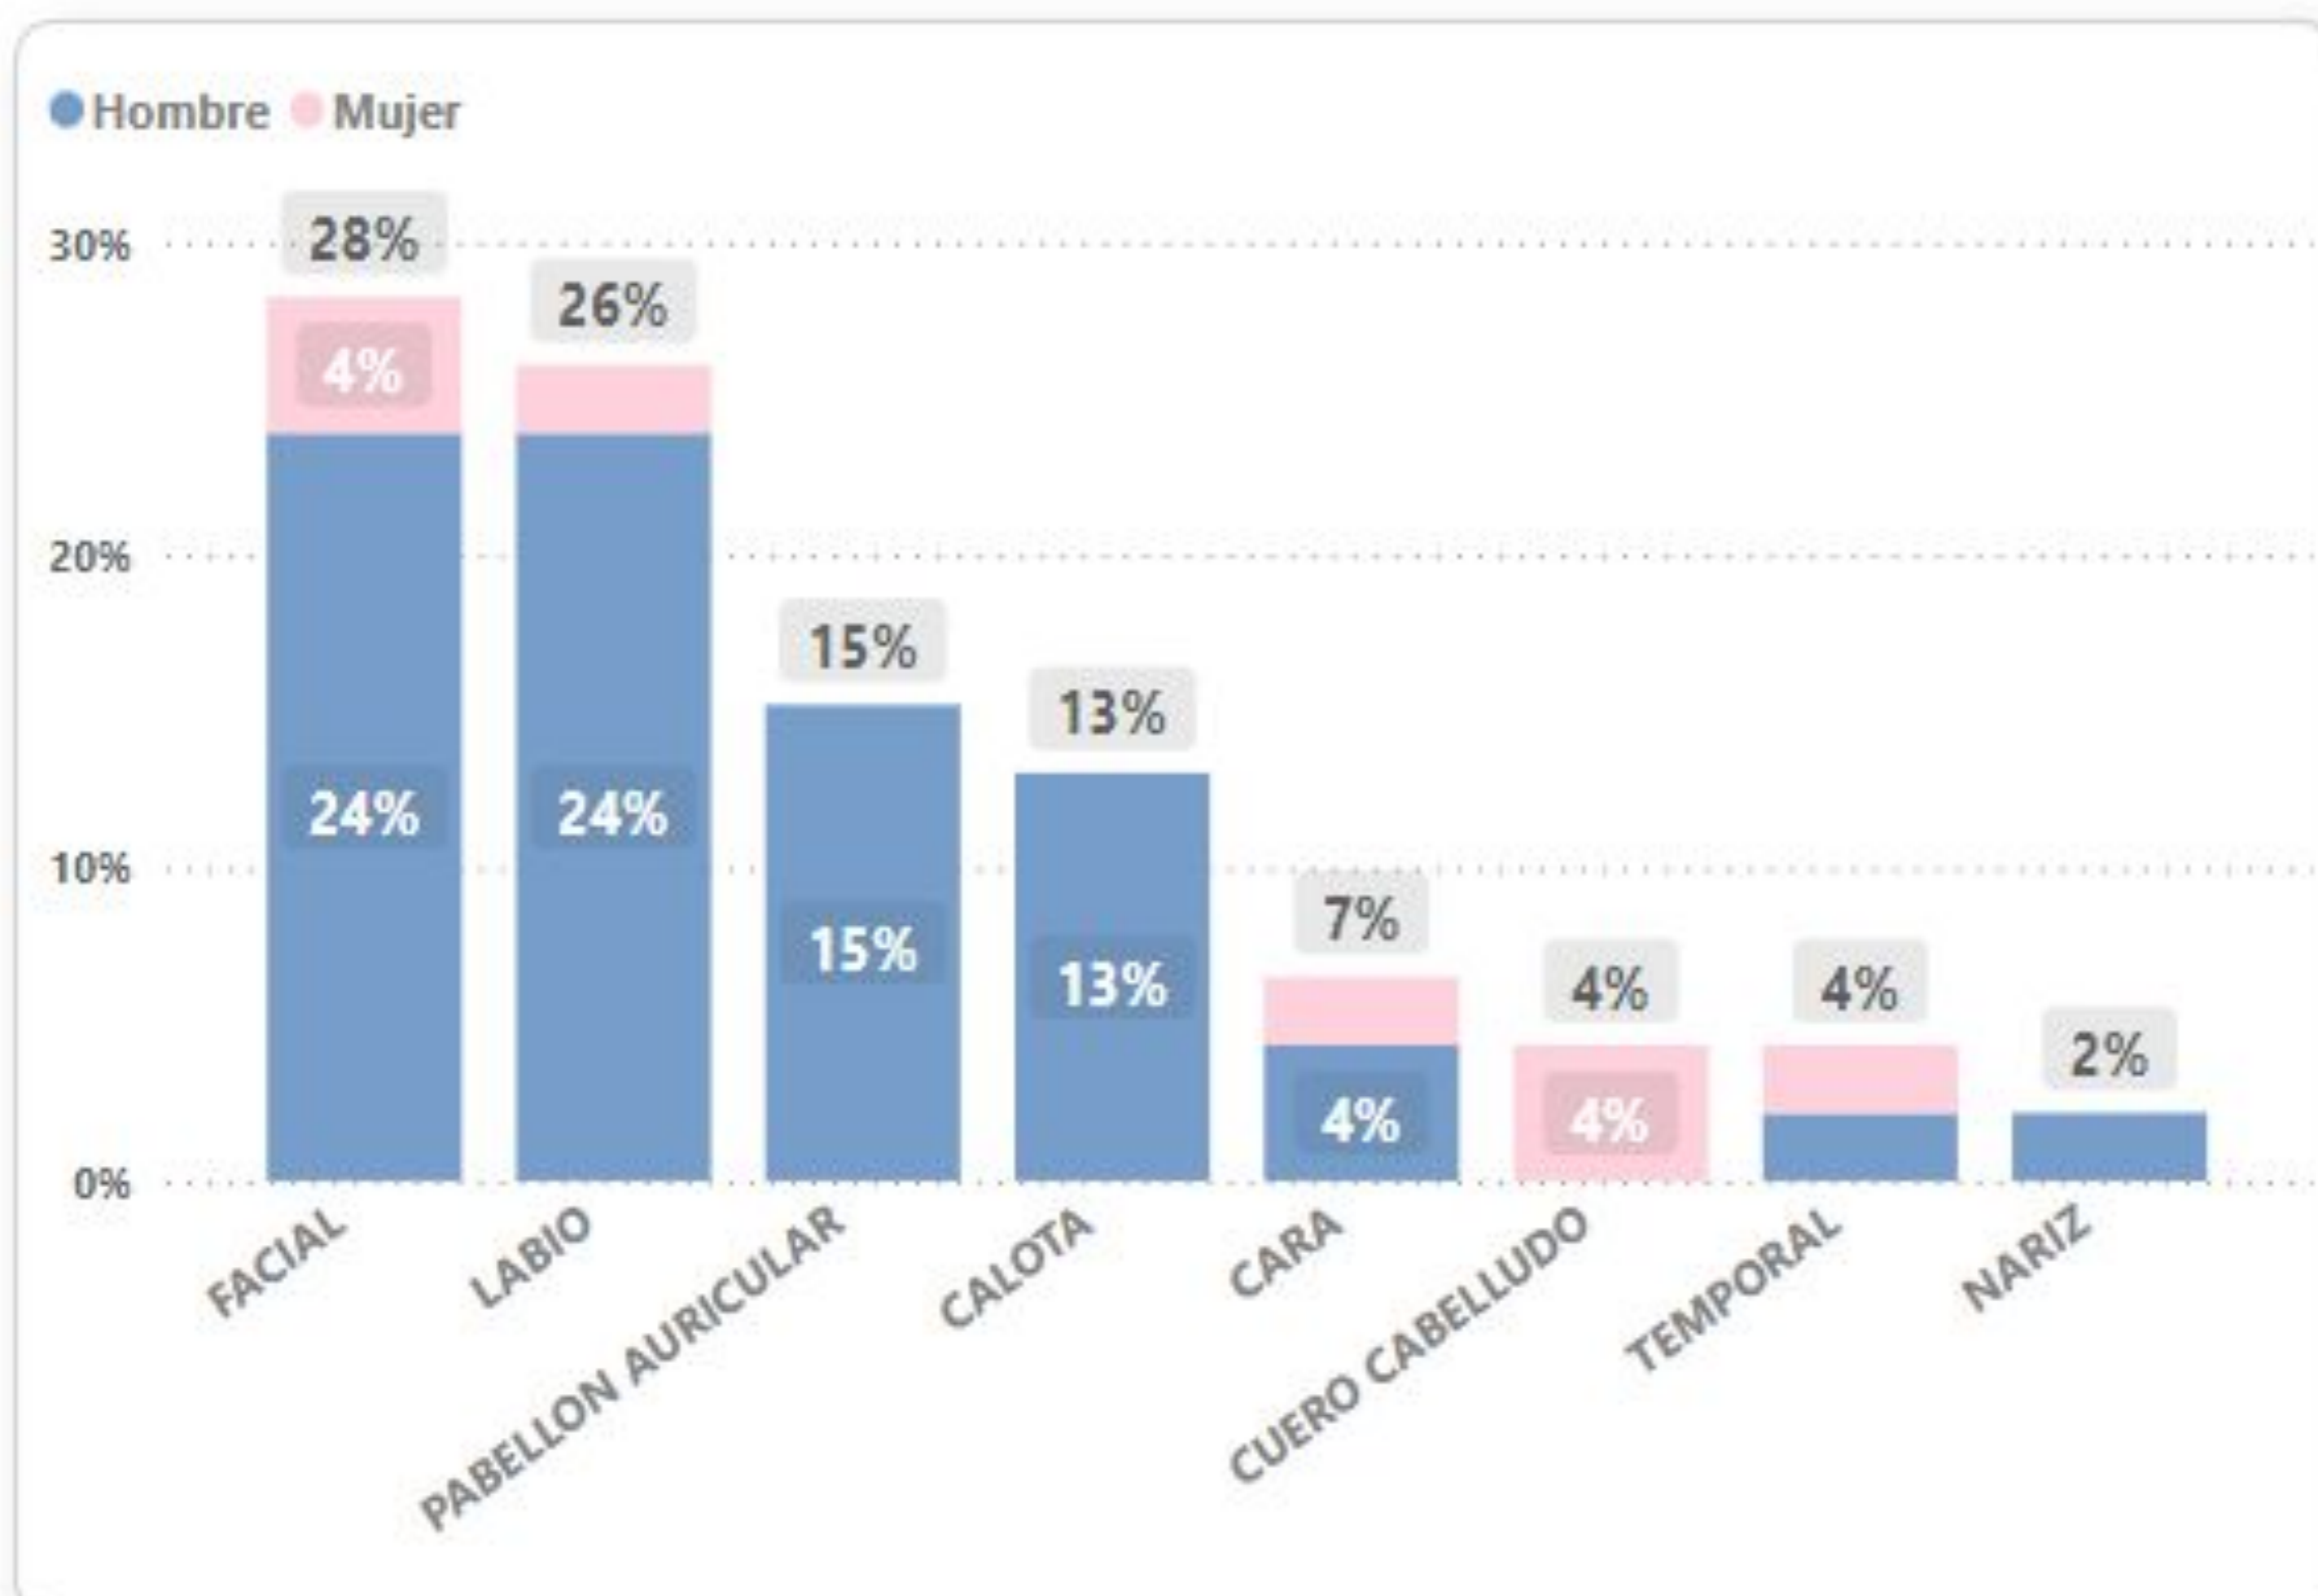


Se seleccionaron 17 pacientes con carcinoma escamocelular y 13 pacientes con carcinoma basocelular.

La mayoría de pacientes eran varones en ambos grupos.



# RESULTADOS.-



# RESULTADOS.-

## REGRESIÓN LOGÍSTICA

Se realizó una valoración inicial mediante análisis de regresión logística para establecer si existían variables que permitiesen diferenciar entre los dos tipos de tumores.

El análisis de regresión logística presentó una precisión baja (57%; sensibilidad 60%, especificidad 50%) siendo estadísticamente significativas únicamente la curtosis y la asimetría para diferenciar entre las dos lesiones.

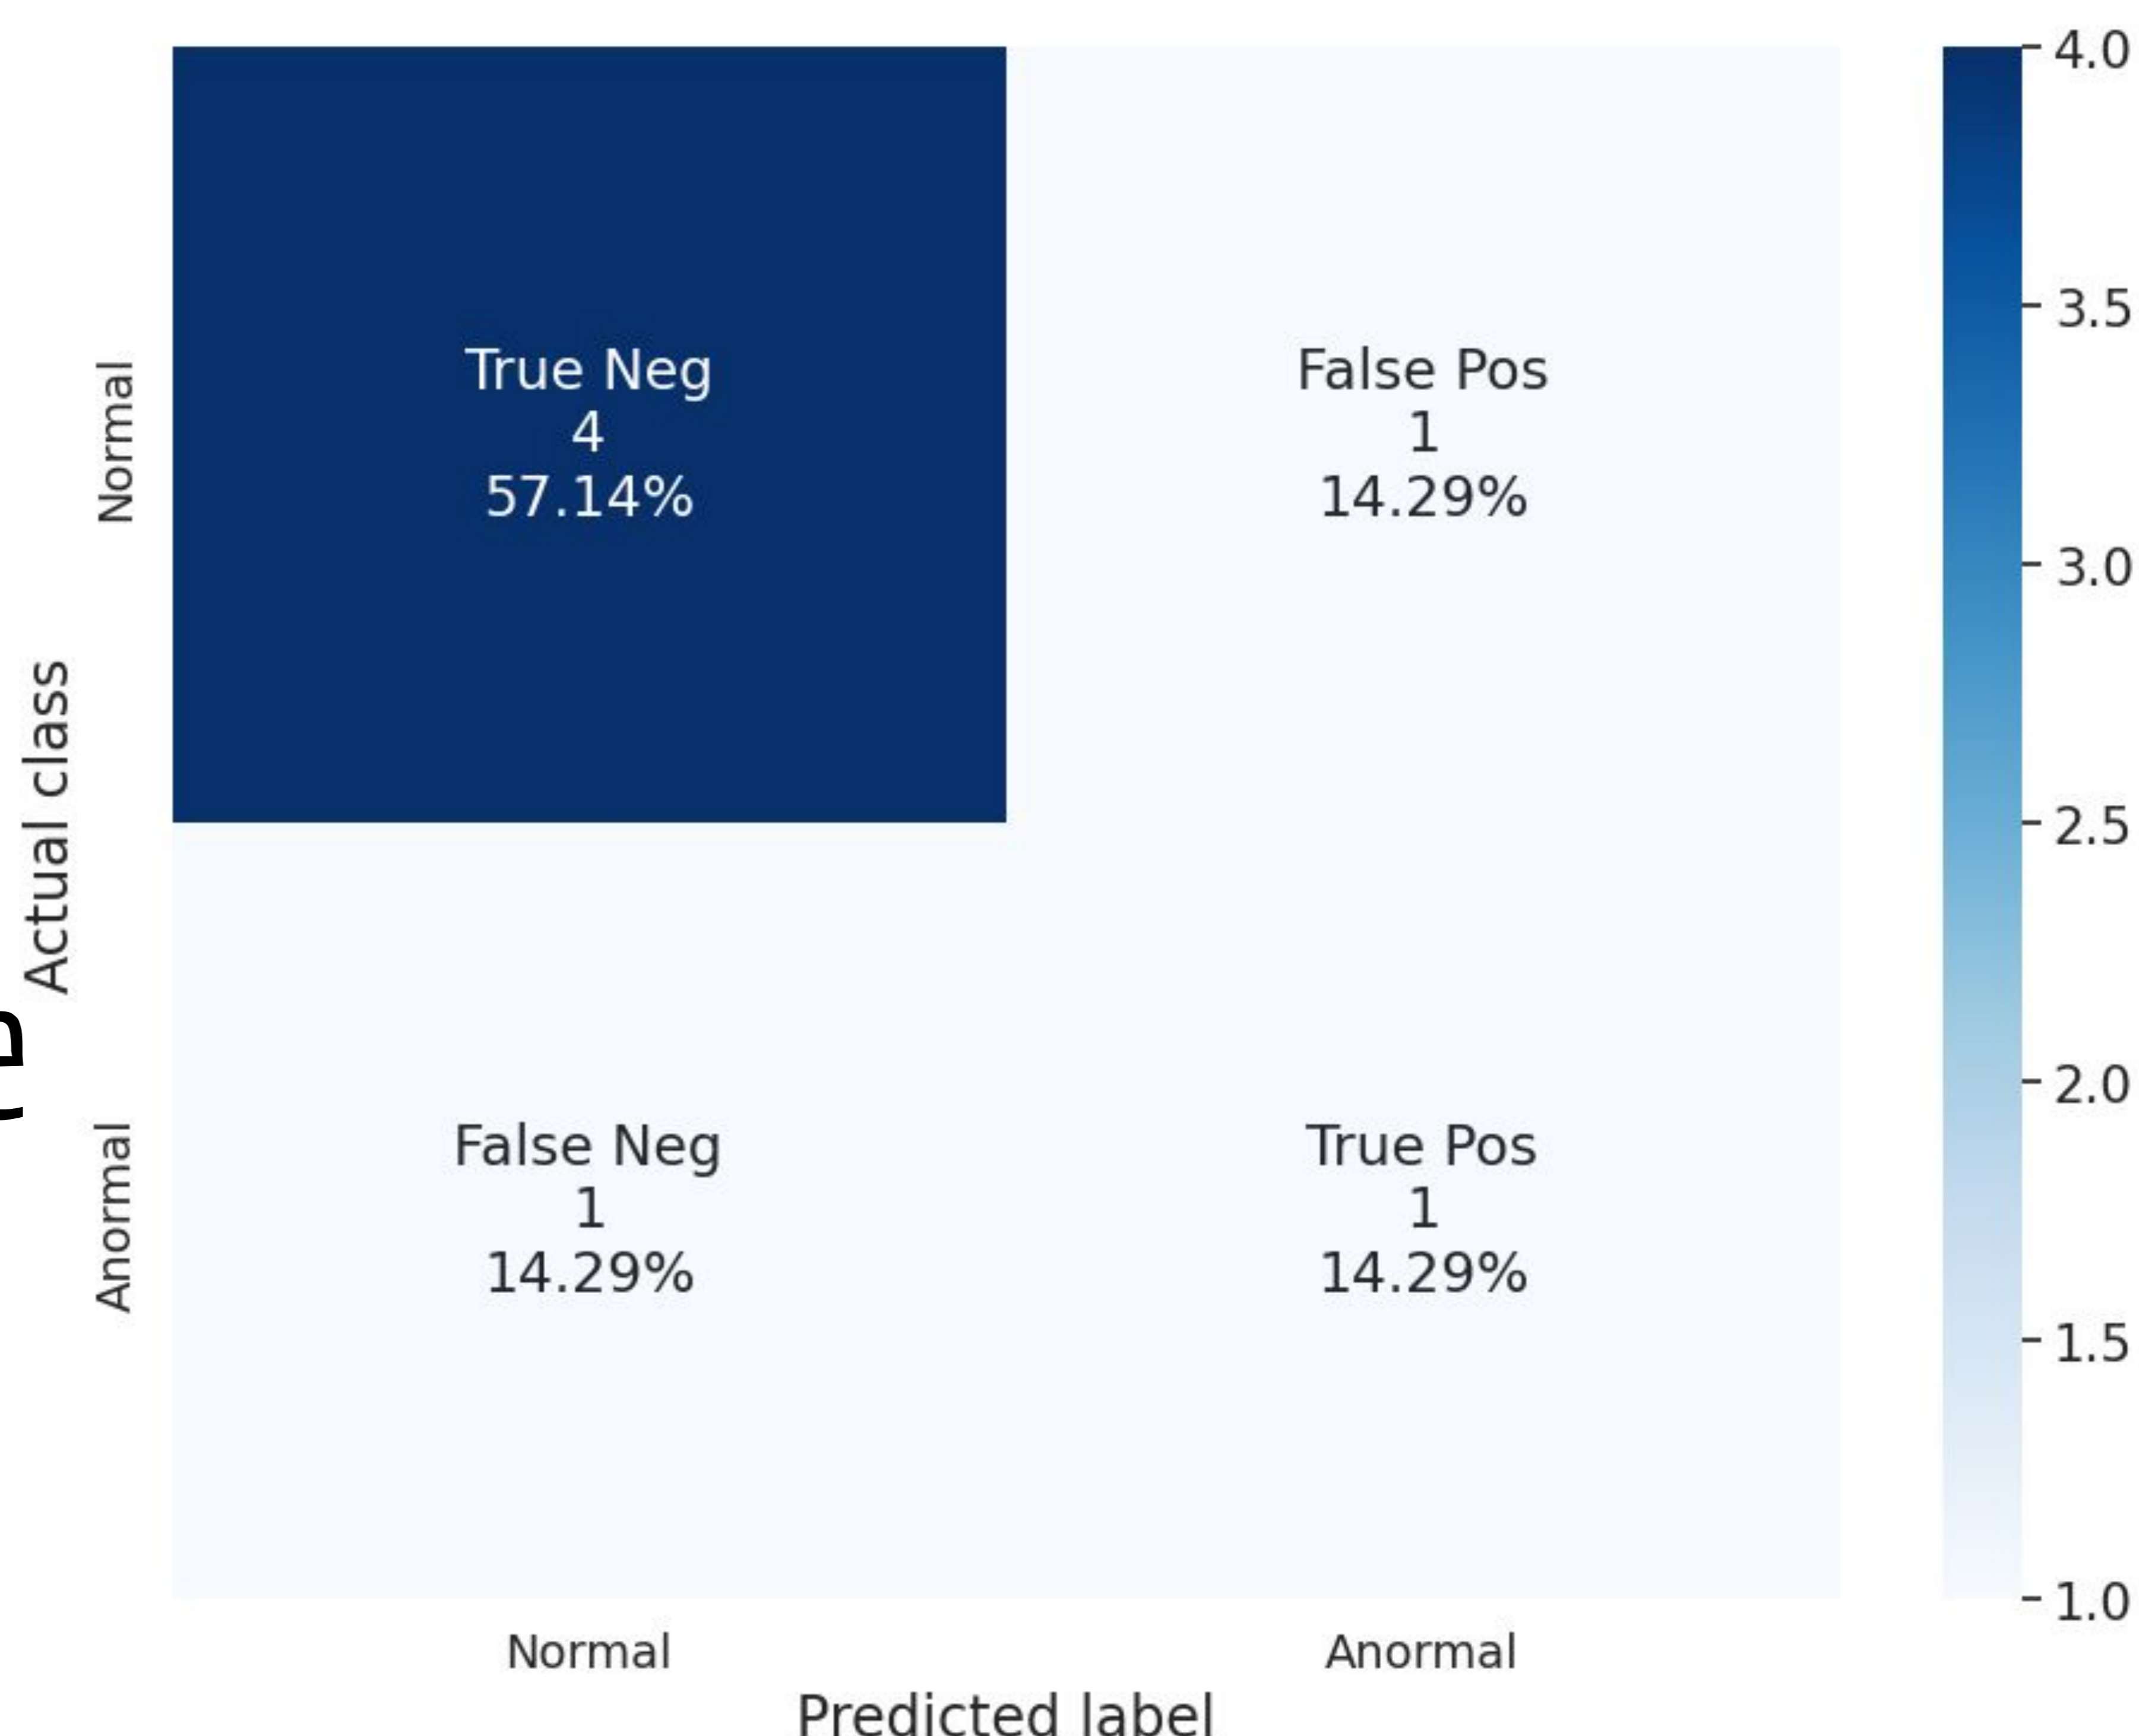
	feature	correlation	abs_correlation	significance	significant
16	Kurtosis	0.471953	0.471953	0.014923	True
1	Skewness	-0.428888	0.428888	0.028797	True
13	Range	0.385990	0.385990	0.051462	False
11	Minimum	-0.335782	0.335782	0.093533	False
14	Variance	0.236424	0.236424	0.244903	False
12	Entropy	0.232364	0.232364	0.253339	False
6	MeanAbsoluteDeviation	0.227288	0.227288	0.264148	False
2	Uniformity	-0.205494	0.205494	0.313893	False
5	RobustMeanAbsoluteDeviation	0.203502	0.203502	0.318709	False
8	Maximum	0.199097	0.199097	0.329521	False
0	InterquartileRange	0.190053	0.190053	0.352402	False
7	TotalEnergy	0.171398	0.171398	0.402480	False
3	Median	0.115477	0.115477	0.574288	False
4	Energy	-0.111890	0.111890	0.586316	False
10	90Percentile	0.096816	0.096816	0.637999	False
9	RootMeanSquared	0.090001	0.090001	0.661939	False
17	Mean	0.085243	0.085243	0.678850	False
15	10Percentile	0.005903	0.005903	0.977170	False

# RESULTADOS.-

## GNB (GAUSSIAN NAIVE BAYES)

Este clasificador de ML presentó una precisión del 71% (buena), con una sensibilidad del 50% y una especificidad del 80% para la detección de carcinoma escamocelular.

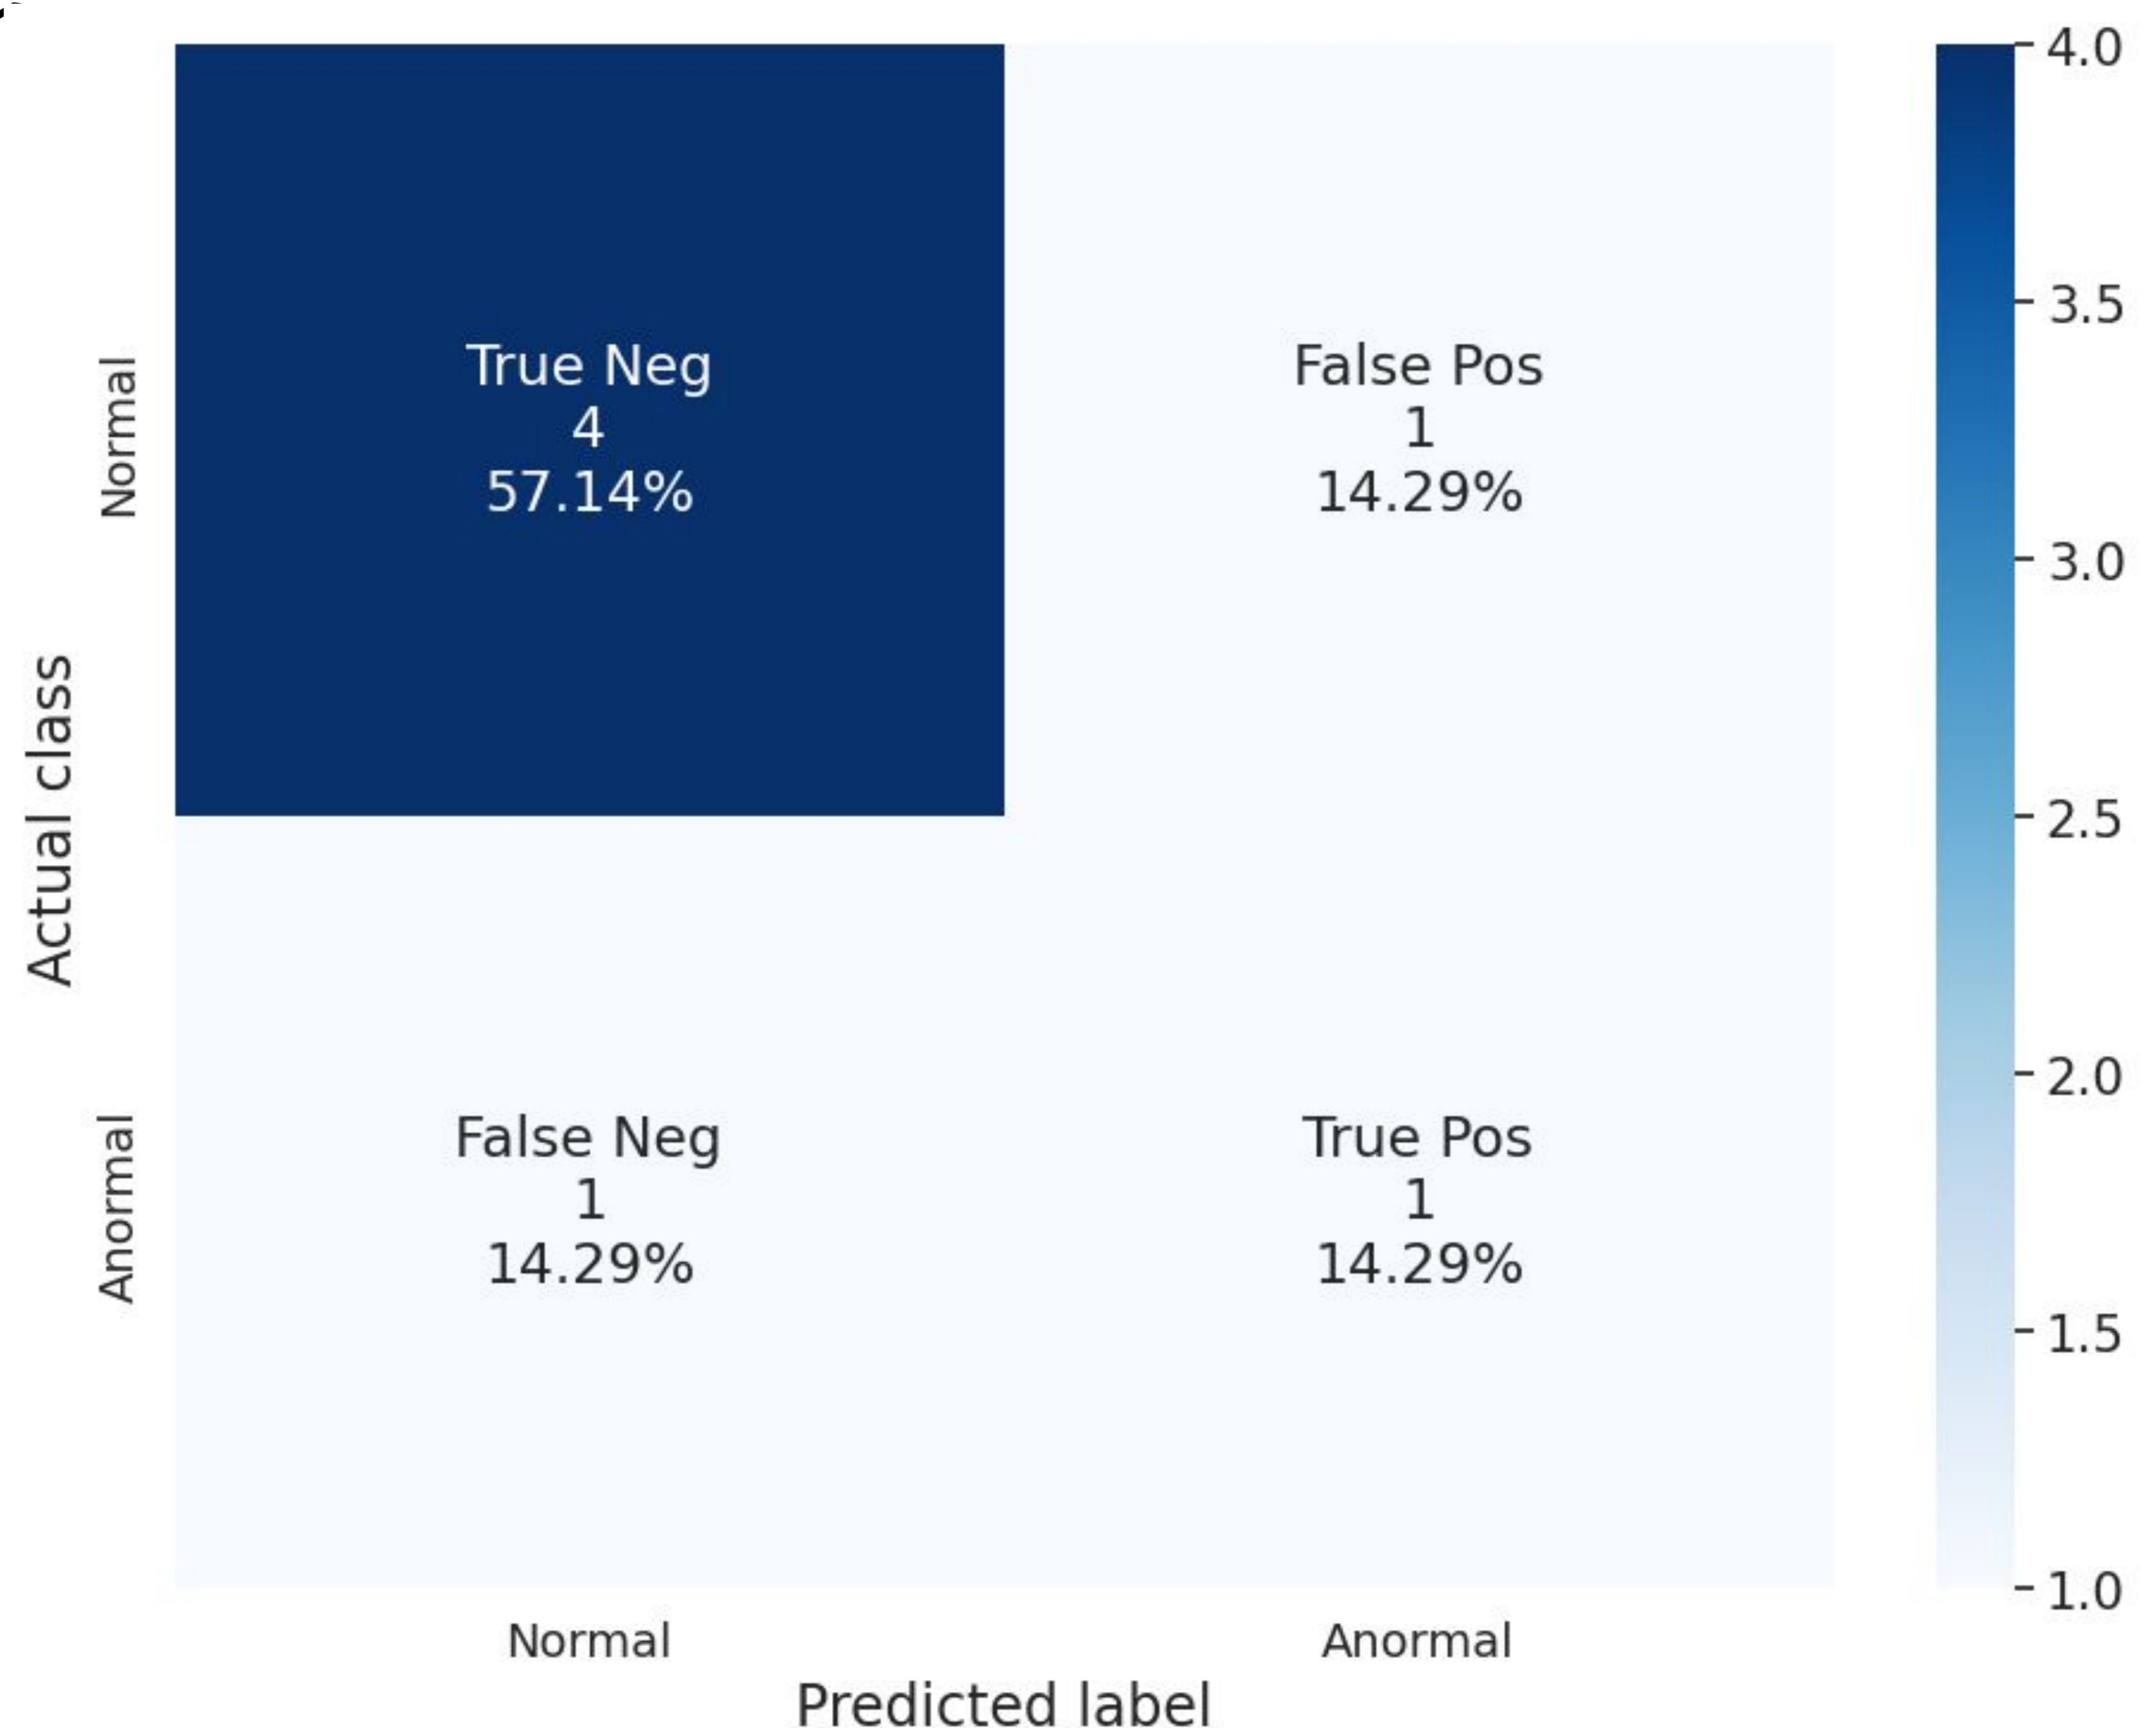
Si bien la sensibilidad era relativamente baja, la especificidad permitía descartar con elevada fiabilidad que una lesión se tratase de carcinoma escamocelular.



# RESULTADOS.-

## QDA (QUADRATIC DISCRIMINANT ANALYSIS)

Este clasificador de ML también presentó una precisión del 71% (buena), con una sensibilidad del 50% y una especificidad del 80% para la detección de carcinoma escamocelular

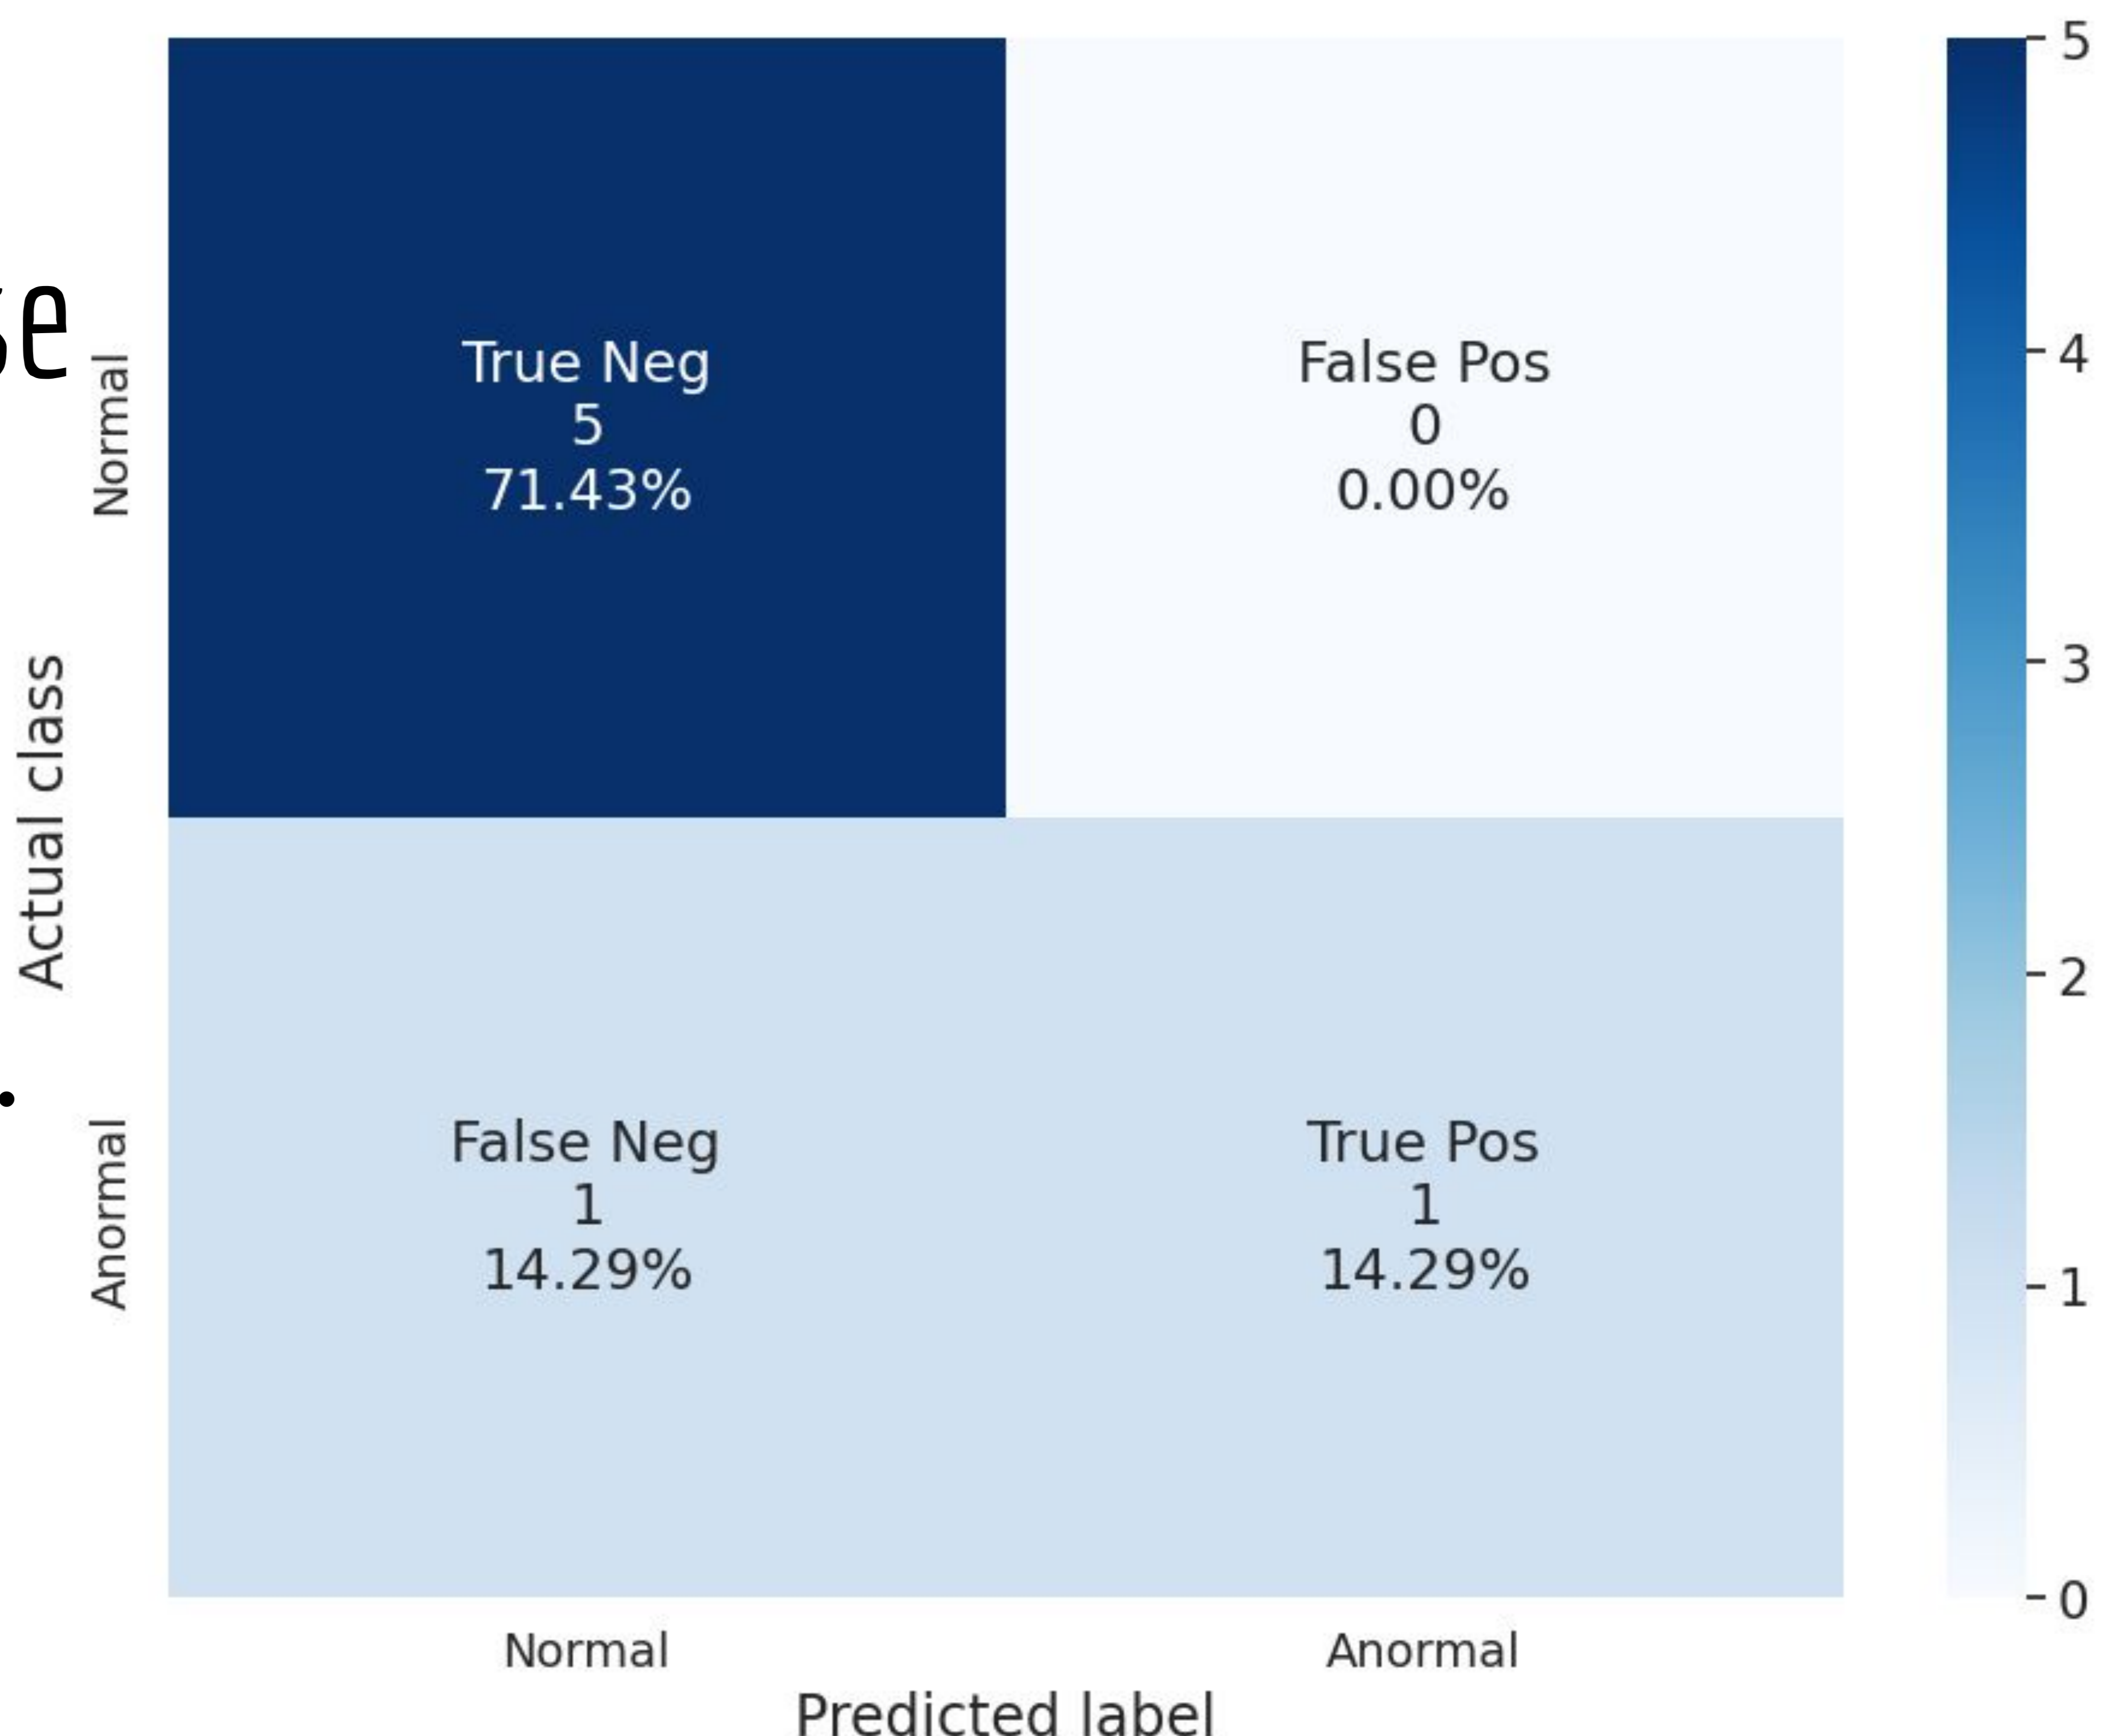


## RESULTADOS.-

Si bien la sensibilidad no se modificó, la especificidad alcanzó el 100% con este modelo.

Este clasificador de ML presentó la precisión más alta del estudio (85%, excelente), con una sensibilidad del 50% y una especificidad del 100% para la detección de carcinoma escamocelular.

Si bien la sensibilidad no se modificó, la especificidad alcanzó el 100% con este modelo.




# RESULTADOS.-

## Sistema de votación ponderada

Se ejecutó un sistema de votación ponderada entre los diferentes clasificadores de ML generados.

Se observó una precisión del 71% (buena), con una sensibilidad del 50% y una especificidad del 80% para la detección de carcinoma escamocelular.



# CONCLUSIONES.-

Se alcanzó una precisión del 71 % (S 50%, E 80%) (buena) para diferenciar entre carcinoma escamocelular de basocelular mediante clasificadores de Machine Learning basados en datos de radiómica obtenidos con imágenes de TC.

Este resultado abre vías para valorar la diferenciación por imagen de TC de tumores cutáneos, que quizás requiera de otros tipos de análisis incluyendo identificación por Deep Learning.

Es preciso trabajar con bases de datos más amplias para mejorar los resultados del análisis y establecer posibles diferencias reales entre los dos tumores.

# BIBLIOGRAFÍA.-

1. Shi YJ, Zhu HT, Yan S, Li XT, Zhang XY, Sun YS. A CT-Based Radiomics Nomogram Model for Differentiating Primary Malignant Melanoma of the Esophagus from Esophageal Squamous Cell Carcinoma. *Biomed Res Int.* 2023 Feb 20;2023:6057196. doi: 10.1155/2023/6057196. PMID: 36860814; PMCID: PMC9970707.
2. Widaatalla Y, Wolswijk T, Adan F, Hillen LM, Woodruff HC, Halilaj I, Ibrahim A, Lambin P, Mosterd K. The application of artificial intelligence in the detection of basal cell carcinoma: A systematic review. *J Eur Acad Dermatol Venereol.* 2023 Jun;37(6):1160-1167. doi: 10.1111/jdv.18963. Epub 2023 Feb 28. PMID: 36785993.
3. Peng Z, Wang Y, Wang Y, Jiang S, Fan R, Zhang H, Jiang W. Application of radiomics and machine learning in head and neck cancers. *Int J Biol Sci.* 2021 Jan 1;17(2):475-486. doi: 10.7150/ijbs.55716. PMID: 33613106; PMCID: PMC7893590.
4. Scheckenbach K, Colter L, Wagenmann M. Radiomics in Head and Neck Cancer: Extracting Valuable Information from Data beyond Recognition. *ORL J Otorhinolaryngol Relat Spec.* 2017;79(1-2):65-71. doi: 10.1159/000455704. Epub 2017 Feb 24. PMID: 28231582.
5. Marcu DC, Grava C, Marcu LG. Current Role of Delta Radiomics in Head and Neck Oncology. *Int J Mol Sci.* 2023 Jan 22;24(3):2214. doi: 10.3390/ijms24032214. PMID: 36768535; PMCID: PMC9916410.
6. Abdel Razek AAK, Khaled R, Helmy E, Naglah A, AbdelKhalek A, El-Baz A. Artificial Intelligence and Deep Learning of Head and Neck Cancer. *Magn Reson Imaging Clin N Am.* 2022 Feb;30(1):81-94. doi: 10.1016/j.mric.2021.06.016. PMID: 34802583.
7. Wong AJ, Kanwar A, Mohamed AS, Fuller CD. Radiomics in head and neck cancer: from exploration to application. *Transl Cancer Res.* 2016 Aug;5(4):371-382. doi: 10.21037/tcr.2016.07.18. PMID: 30627523; PMCID: PMC6322843.
8. van Griethuysen JJM, Fedorov A, Parmar C, Hosny A, Aucoin N, Narayan V, Beets-Tan RGH, Fillion-Robin JC, Pieper S, Aerts HJWL. Computational Radiomics System to Decode the Radiographic Phenotype. *Cancer Res.* 2017 Nov 1;77(21):e104-e107. doi: 10.1158/0008-5472.CAN-17-0339. PMID: 29092951; PMCID: PMC5672828.
9. Fedorov A., Beichel R., Kalpathy-Cramer J., Finet J., Fillion-Robin J-C., Pujol S., Bauer C., Jennings D., Fennessy F., Sonka M., Buatti J., Aylward S.R., Miller J.V., Pieper S., Kikinis R. 3D Slicer as an Image Computing Platform for the Quantitative Imaging Network. *Magnetic Resonance Imaging.* 2012 Nov;30(9):1323-41. PMID: 22770690.