

# DIFERENCIACION DE LESIONES MANDIBULARES MEDIANTE TÉCNICAS DE IA

**Laura Acosta Barrios<sup>1</sup>, María Isabel Gómez Alonso<sup>1</sup>, Almudena Pérez Lara<sup>1</sup>, Daniel Calvo<sup>2</sup>, David Román<sup>1</sup>, Beatriz Asenjo García<sup>1</sup>, Javier Pérez Lara<sup>3</sup>, Javier Carrillo<sup>1</sup>, Jose Mellado<sup>1</sup>**

Hospital Regional Universitario Carlos Haya<sup>1</sup>, Málaga  
Hospital Universitario Nuestra Señora de Valme<sup>2</sup>, Sevilla.  
Departamento de Ingeniería, Universidad de Loyola<sup>3</sup>

# ÍNDICE

1

**OBJETIVOS**

2

**MATERIAL Y METODO**

3

**RESULTADOS**

4

**CONCLUSIONES**

5

**BIBLIOGRAFIA**

Las lesiones quísticas mandibulares son hallazgos frecuentes en los estudios de cabeza y cuello, y constituyen un **reto diagnóstico** para el radiólogo ya que pueden tener similares características radiológicas.

Es fundamental la diferenciación entre quistes y lesiones de otra índole para definir el tratamiento adecuado, ya que hay algunas que pueden recurrir tras la enucleación y pueden requerir hemimandibulectomía.

## OBJETIVOS

Valorar la **utilidad del análisis de textura** como herramienta para diferenciar las lesiones mandibulares más frecuentes (ameloblastoma, quiste folicular, quiste radicular, odontoma y queratoquiste).

# MATERIAL Y MÉTODO

## Selección de pacientes

### CRITERIOS DE INCLUSION


Se seleccionaron pacientes con TC de mandíbula y senos paranasales sin contraste intravenoso, con grosor de corte 0,67 mm.

- 15 pacientes con diagnóstico anatomopatológico de **ameloblastoma, queratoquistes y odontomas** respectivamente.
- 15 pacientes con diagnóstico radiológico de **quistes radicales y foliculares**.

### CRITERIOS DE EXCLUSION

- Artefacto metálico o de movimiento que afectase al área de la lesión.
- Estudios con contraste intravenoso.

# MATERIAL Y MÉTODO



**Figura 1. Ejemplos de lesiones segmentadas.** Quiste radicular (A, paciente con pieza cariada y lucencia en torno a raíz dentaria), quiste folicular (B, quiste en torno a pieza no erupcionada), odontoma compuesto (C, se identifican los componentes dentarios dentro de la lesión), queratoquiste (D, lesión insuflante en cortical mandibular izquierda con adelgazamiento de la mandíbula) y ameloblastoma (E, lesión que expande la mandíbula, bien definida adelgazando la cortical con aspecto en pompas de jabón).

# MATERIAL Y MÉTODO

## Análisis de textura

- Se empleó el **software 3D Slicer**, un software libre de código abierto que permite realizar procesamiento de imagen.
- Se realizó una **segmentación manual** de toda la lesión en cada sección visible, evitando áreas con artefacto, la raíz dentaria y el hueso de la periferia (cortical maxilar/mandibular o raíz dentaria).
- Se extrajeron estadísticos de primer orden de cada segmentación: **rango intercuartílico, asimetría (skewness), percentil 10, percentil 90, media, mediana, desviación estándar, curtosis, densidad máxima y mínima, entropía, rango, varianza, media cuadrática y energía total.**




Figura 2. Ejemplo de segmentación realizada sobre un ameloblastoma de la hemimandíbula izquierda.

# MATERIAL Y MÉTODO

## Análisis de datos

Se empleó **Phyton** (lenguaje de programación utilizado en el desarrollo de algoritmos y aplicaciones) para crear modelos de Machine Learning (ML) que permitiesen identificar las diferentes lesiones mandibulares en base a los datos de análisis de textura.

Los clasificadores empleados fueron **regresión logística**, **K Means**, **Random Forest (RF)** y **Support Vector Machine (SMV)**. Se realizó un análisis preliminar de la muestra y posteriormente se analizó la capacidad de diferenciación de una lesión específicamente respecto a la muestra total.

Se calcularon 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.
- El 25% de la muestra se empleó para el set de test.

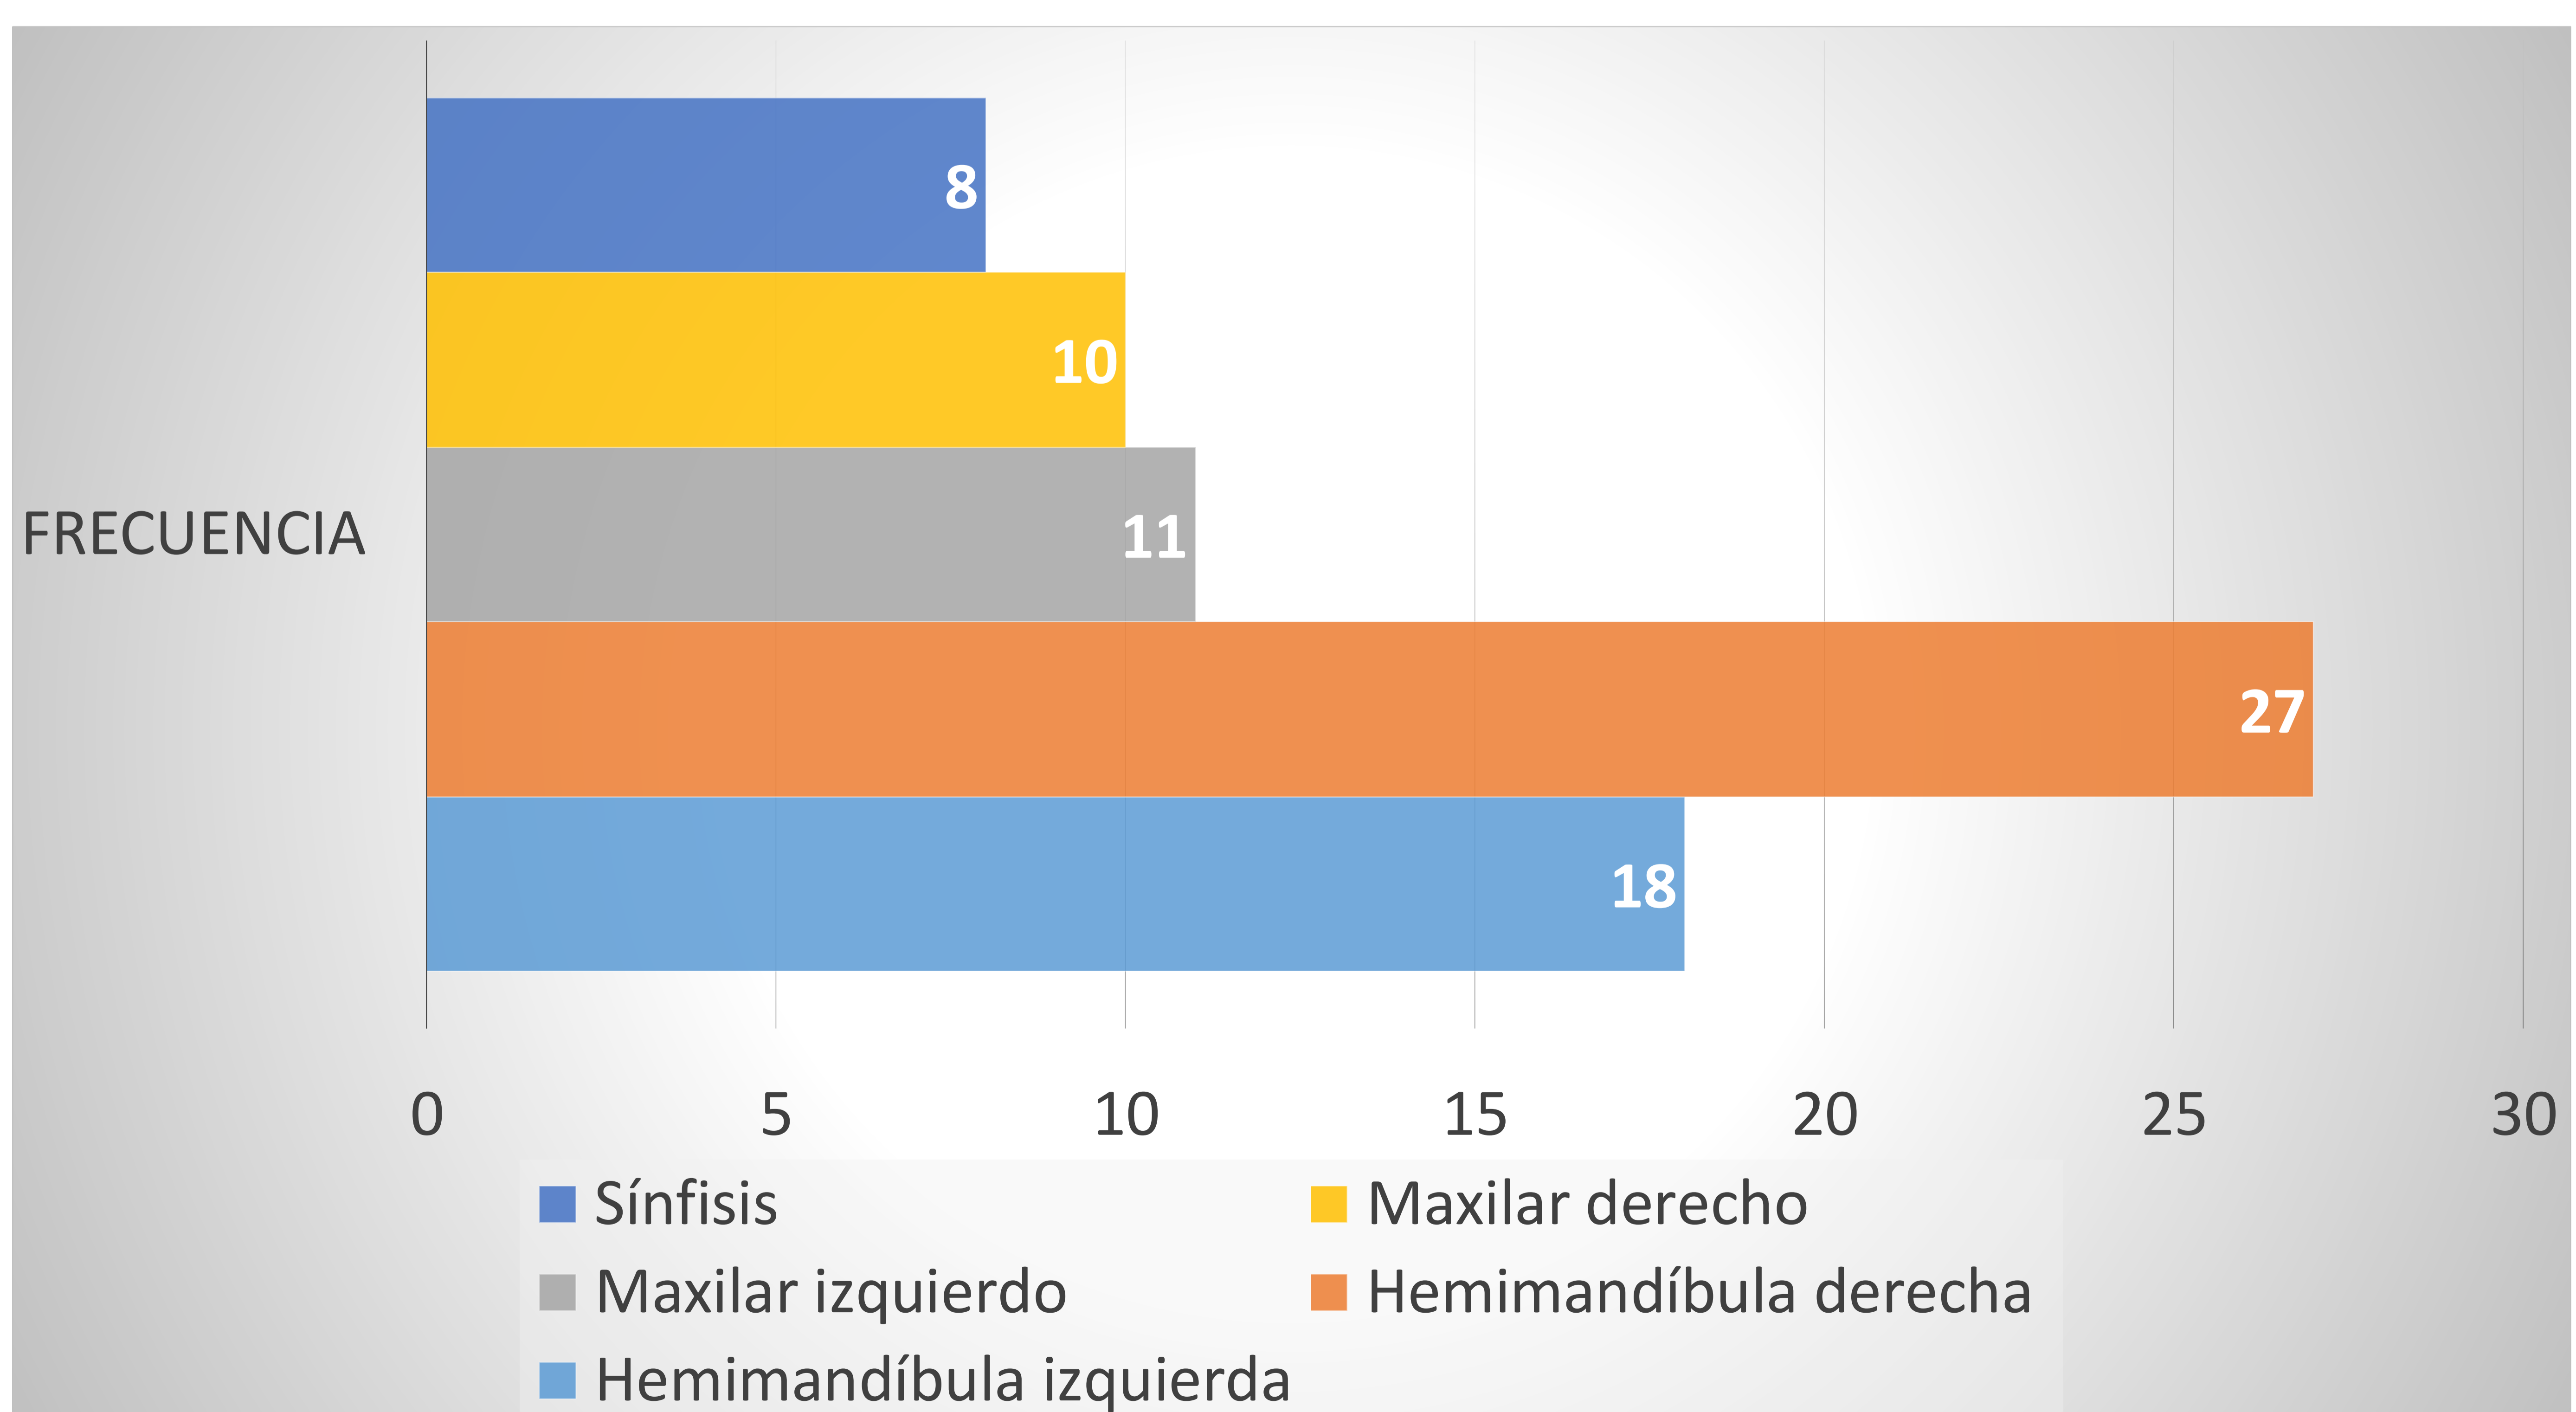
# RESULTADOS

## Datos demográficos y clínicos

La edad media de los pacientes seleccionados fue de 24,8 años (rango 11-72 años).

37 pacientes eran mujeres, 38 hombres.

La mayoría de lesiones se encontraban en el cuarto cuadrante.



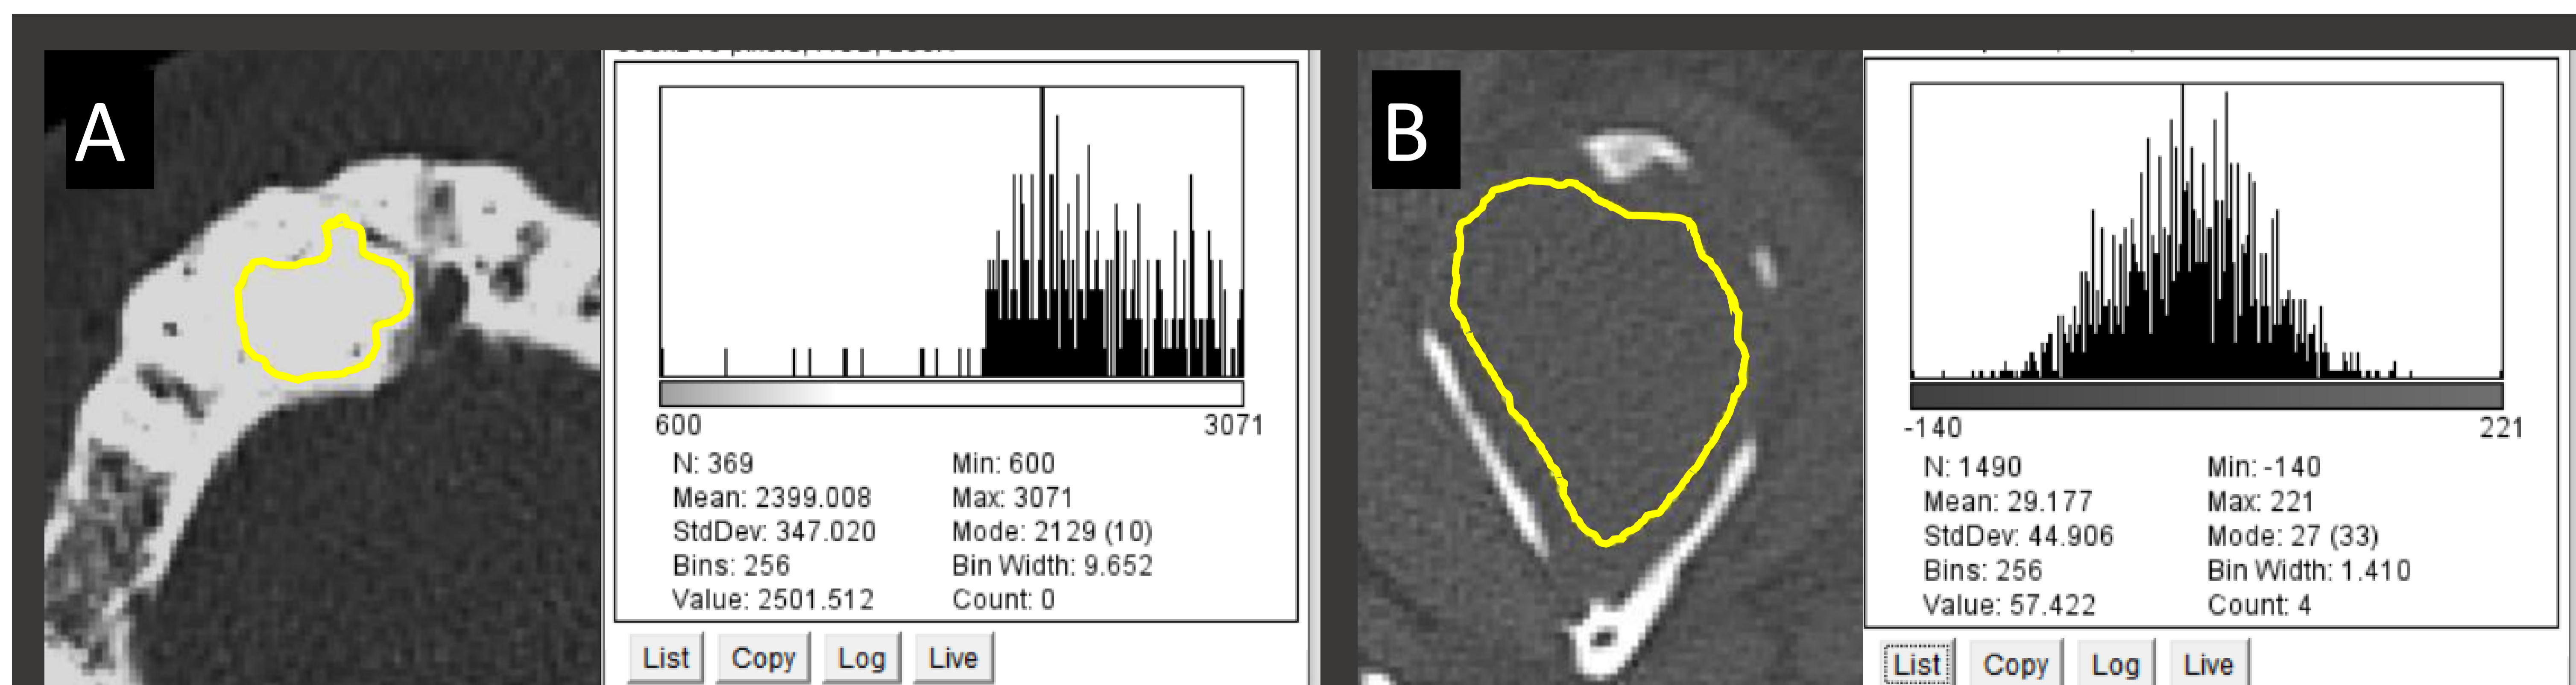


# RESULTADOS

## Análisis de textura

|                             | AMELOBLASTOMA    | QUERATOQUISTE  | QUISTE FOLICULAR | QUISTE RADICULAR | ODONTOMA          |
|-----------------------------|------------------|----------------|------------------|------------------|-------------------|
| 10Percentile                | -49              | -28,9          | -159,09          | -35,27           | 589,77            |
| 90Percentile                | 162,53           | 116,27         | 103,41           | 149,41           | 2.213,88          |
| Energy                      | 2.764.901.000,00 | 206.441.700,00 | 835.387.100,00   | 11.064.810,00    | 31.762.300.000,00 |
| Entropy                     | 3,31             | 3,24           | 3,36             | 3,5              | 6,28              |
| InterquartileRange          | 100,67           | 73,27          | 135,68           | 93,7             | 935,78            |
| Kurtosis                    | 38,12            | 17,97          | 5,24             | 3,66             | 3,31              |
| Maximum                     | 1.165,73         | 827,2          | 457,4            | 340,8            | 2.815,93          |
| MeanAbsoluteDeviation       | 71,64            | 47,89          | 86,29            | 58,22            | 514,07            |
| Mean                        | 53,94            | 43,72          | -4,12            | 56,53            | 1.404,97          |
| Median                      | 41,7             | 39,43          | 21,87            | 55,9             | 1.402,27          |
| Minimum                     | -319,67          | -217,47        | -337,13          | -184,67          | -104,4            |
| Range                       | 1.485,40         | 1.044,67       | 794,53           | 525,47           | 2.920,33          |
| RobustMeanAbsoluteDeviation | 43,76            | 30,86          | 63,51            | 39,38            | 385,99            |
| RootMeanSquared             | 123,54           | 82,02          | 135,11           | 97,08            | 1.560,03          |
| Skewness                    | 2,85             | 1,37           | 0,16             | 0,18             | -0,19             |
| TotalEnergy                 | 267.132.700,00   | 33.170.980,00  | 66.177.570,00    | 5.883.300,00     | 3.633.393.000,00  |
| Uniformity                  | 0,18             | 0,14           | 0,13             | 0,11             | 0,02              |
| Variance                    | 18.021,42        | 5.390,32       | 24.755,10        | 6.270,73         | 425.797,30        |

**Tabla 1.** Valores medios del análisis de textura realizado en cada tipo de lesión.



**Figura 3.** Ejemplo de histograma de un odontoma (A) y de un queratoquiste (B). Nótese las diferencias en la morfología de la curva.

# RESULTADOS

## Análisis de datos

Se emplea un clasificador K Means y Random Forest (RF) para diferenciar entre los cinco tipos de lesiones estudiadas en base a los datos de textura.

Las técnicas de clasificación multiclase probadas ofrecieron una **precisión diagnóstica del 65%** (baja precisión). La dispersión de pares de magnitudes no fue suficiente para realizar una adecuada discriminación.

Al obtener este resultado se decide realizar **5 análisis biclase** independientes (empleando regresión logística, K means, RF y SMV). En cada uno se establece la **clase 0 para la lesión a detectar** y la **clase 1** para todos los demás.

Se compara así de forma individual cada tipo de lesión con el conjunto de datos global.

# RESULTADOS

## Análisis de datos

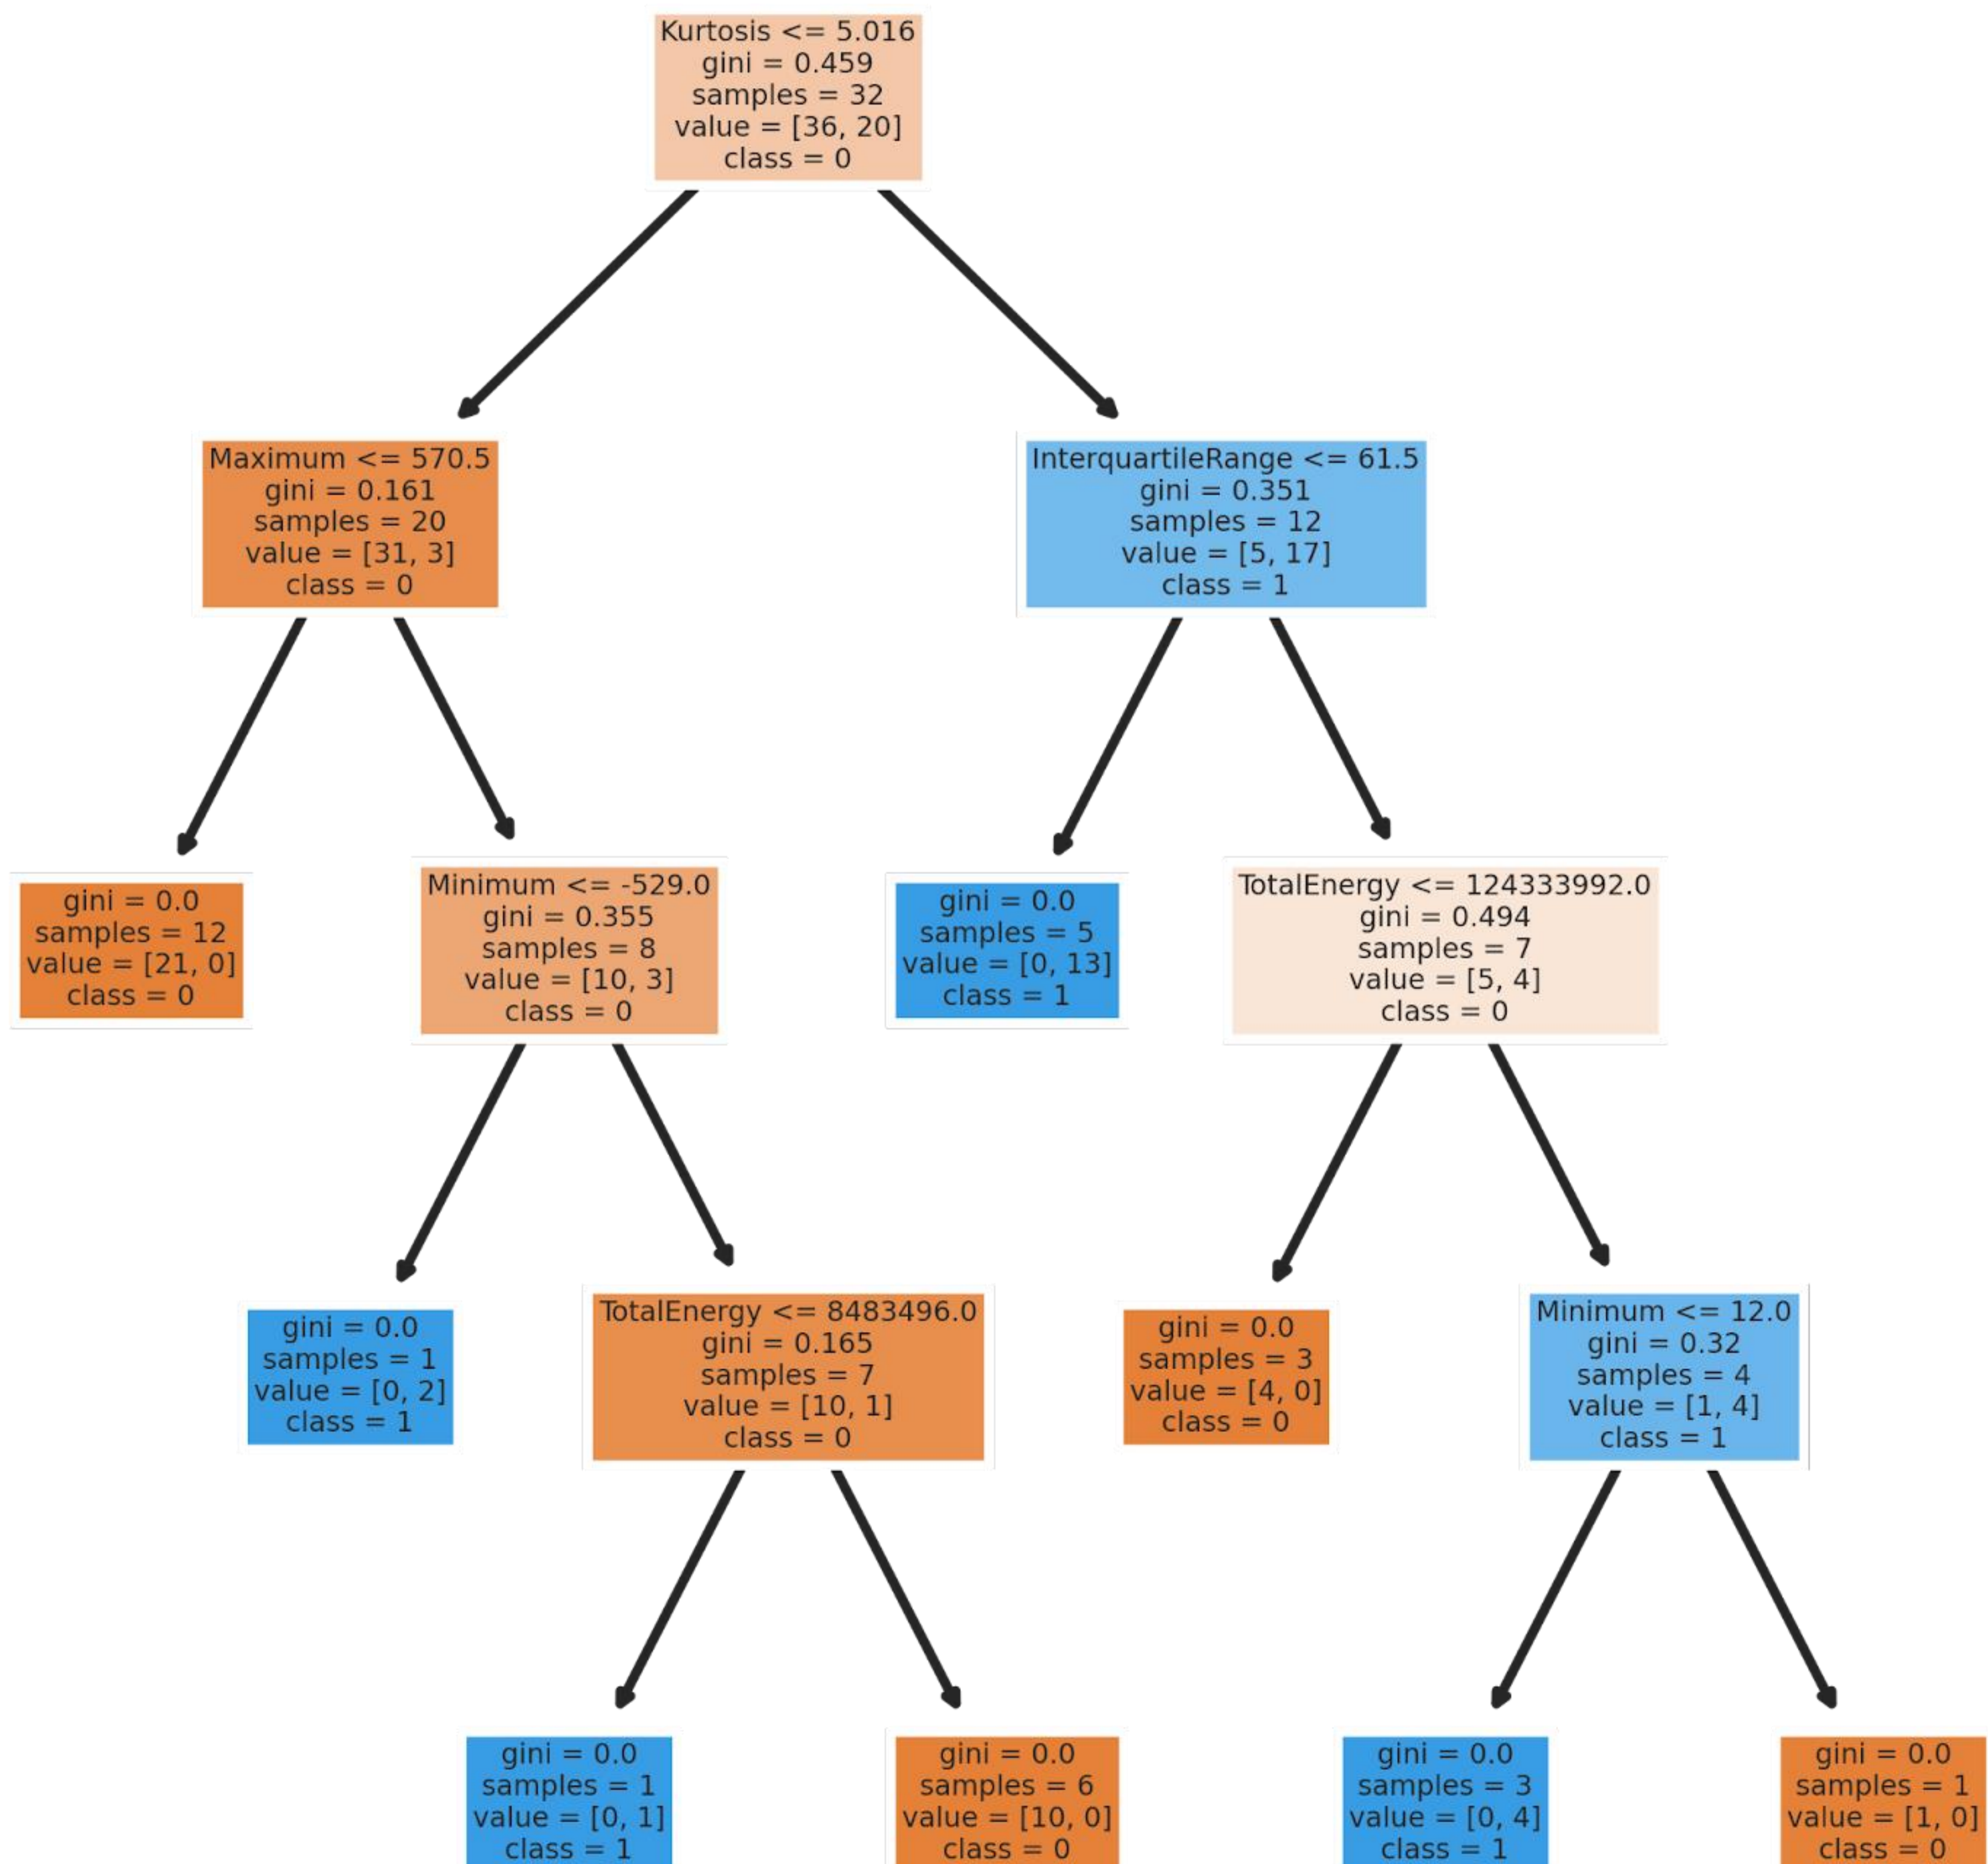


Diagrama de árbol de decisiones creado con el clasificador RF

# RESULTADOS

## Análisis de datos

### ODONTOMA VS CONJUNTO DE LESIONES

|               | REG LOG | K MEANS | RF   | SVM  |
|---------------|---------|---------|------|------|
| PRECISION     | 100%    | 100%    | 100% | 100% |
| SENSIBILIDAD  | 100%    | 100%    | 100% | 100% |
| ESPECIFICIDAD | 100%    | 100%    | 100% | 100% |
| VPP           | 100%    | 100%    | 100% | 100% |
| VPN           | 100%    | 100%    | 100% | 100% |

**El algoritmo fue capaz de clasificar correctamente todos los odontomas**, sin clasificar otras lesiones de forma incorrecta dentro de este grupo.

**Es posible mediante técnicas de regresión logística y ML realizar una correcta caracterización de los odontomas alcanzando un VPP y VPN del 100%.**

# RESULTADOS

## Análisis de datos

### AMELOBLASTOMA VS CONJUNTO DE LESIONES

|               | REG LOG | K MEANS | RF  | SVM  |
|---------------|---------|---------|-----|------|
| PRECISION     | 89%     | 60%     | 89% | 82%  |
| SENSIBILIDAD  | 100%    | 0%      | 0%  | 0%   |
| ESPECIFICIDAD | 88%     | 75%     | 94% | 100% |
| VPP           | 33%     | 0%      | 0%  | 0%   |
| VPN           | 100%    | 75%     | 94% | 100% |

**El modelo mostró una precisión del 89% (excelente) para clasificar adecuadamente ameloblastomas mediante regresión logística (S 100%, E 88%).**

Los modelos de ML aportaron una sensibilidad del 0%, lo que implica que no eran capaces de identificar adecuadamente ningún ameloblastoma. Estos clasificadores sí mostraron valores altos de VPN, por lo que los errores de etiquetado (confundir otras lesiones con ameloblastoma) fueron bajos.

**En este caso, la regresión logística mostró valores de sensibilidad muy altos y es el clasificador adecuado para diferenciar ameloblastomas.**

# RESULTADOS

## Análisis de datos

### QUERATOQUISTE VS CONJUNTO DE LESIONES

|               | REG LOG | K MEANS | RF  | SVM |
|---------------|---------|---------|-----|-----|
| PRECISION     | 68%     | 60%     | 52% | 74% |
| SENSIBILIDAD  | 50%     | 0%      | 14% | 50% |
| ESPECIFICIDAD | 73%     | 75%     | 75% | 80% |
| VPP           | 33%     | 0%      | 25% | 40% |
| VPN           | 84%     | 75%     | 60% | 85% |

El algoritmo mostró escasa precisión para clasificar queratoquistes con el clasificador K Means y RF (K means no fue capaz de clasificar adecuadamente ningún queratoquiste). Sin embargo, **el modelo SVM presentó una precisión del 74% (buena) con un VPN del 85%**, lo cual implica que el modelo es capaz de **descartar** esta lesión con una fiabilidad alta.

La sensibilidad y el VPP mostraron valores bajos (50% y 40% respectivamente) con este modelo, teniendo un **rendimiento bajo para detectar queratoquistes**.

# RESULTADOS

## Análisis de datos

### QUISTE FOLICULAR VS CONJUNTO DE LESIONES

|               | REG LOG | K MEANS | RF   | SVM  |
|---------------|---------|---------|------|------|
| PRECISION     | 79%     | 60%     | 73%  | 84%  |
| SENSIBILIDAD  | 20%     | 0%      | 0%   | 0%   |
| ESPECIFICIDAD | 100%    | 75%     | 73%  | 100% |
| VPP           | 77%     | 0%      | 0%   | 0%   |
| VPN           | 100%    | 75%     | 100% | 100% |

**El algoritmo mostró una precisión del 84% (excelente) con SVM para clasificar quistes foliculares vs otras lesiones.**

La sensibilidad fue del 0% con los modelos de ML, lo que significa que no eran capaces de clasificar adecuadamente ningún quiste folicular; **el VPN fue del 100%** lo que implica que el algoritmo no etiqueta erróneamente ninguna lesión de otras características como quiste folicular y es útil para **descartar** esta lesión.

El modelo de regresión lineal mostró una sensibilidad del 20% para detectar quistes foliculares (baja).

# RESULTADOS

## Análisis de datos

### QUISTE RADICULAR VS CONJUNTO DE LESIONES

|               | REG LOG | K MEANS | RF   | SVM  |
|---------------|---------|---------|------|------|
| PRECISION     | 89%     | 40%     | 89%  | 84%  |
| SENSIBILIDAD  | 60%     | 25%     | 100% | 100% |
| ESPECIFICIDAD | 100%    | 100%    | 87%  | 81%  |
| VPP           | 60%     | 25%     | 100% | 100% |
| VPN           | 100%    | 100%    | 60%  | 50%  |

**La precisión para clasificar adecuadamente los quistes radiculares fue del 89% con RF y regresión logística (excelente).**

**La sensibilidad y el VPN fue del 100% con RF y SVM, lo cual implica que se detectan la totalidad de los quistes radiculares.** La especificidad fue del 87%, por lo que sería necesario ampliar la muestra para intentar mejorar el algoritmo y evitar etiquetados erróneos de otras lesiones.



# CONCLUSIONES

**La diferenciación de lesiones mandibulares con técnicas de regresión logística e inteligencia artificial es compleja.**

**Es posible clasificar correctamente todos los odontomas con los diferentes métodos empleados (tanto regresión logística como métodos de ML). Además la clasificación de ameloblastomas con regresión logística y de quistes radicales con Random Forest es excelente.**

**El rendimiento más bajo se obtuvo con los queratoquistes y con los quistes foliculares. Los clasificadores fueron capaces de descartar estas lesiones con una fiabilidad alta, pero no de detectarlos con una tasa aceptable para el diagnóstico.**

**Es preciso realizar estudios con mayor número de pacientes que permitan mejorar la precisión y sensibilidad del algoritmo y que posibiliten desarrollar clasificadores adecuados para la diferenciación de lesiones mandibulares.**

# BIBLIOGRAFÍA

1. Kumar J, Vanagundi R, Manchanda A, Mohanty S, Meher R. Radiolucent Jaw Lesions: Imaging Approach. Indian J Radiol Imaging 2021;(31)224–236.
2. Subramaniam R, Reddy S, Imsande H, Gohel A, Sakai O, Devenney-Cakir B. Cystic and Cystic-Appearing Lesions of the Mandible: Review. AJR; 2011(196): 66-77.
3. Odaa M, Staziakia P, Qureshia M, Andreu-Arasaa C, Li B et al. CT texture analysis to differentiate cystic and cystic-appearing odontogenic lesions. European Journal of Radiology;2019 (120).
4. Avril L, Lombardi T, Ailianou A, Burkhardt K, Varoquaux A, Scolozzi P, et al. Radiolucent lesions of the mandible: a pattern-based approach to diagnosis. Insights Imaging. 2014;(5)85–101.