


Vicente Javier Ruiz García¹, Virginia Márquez Pérez¹, Sara Sánchez Paniagua Martín¹, María Vidal Denis¹, Javier Pérez Lara², Beatriz Asenjo García¹, Almudena Pérez Lara¹

¹Hospital Regional Universitario de Málaga, Málaga

² Departamento de Ingeniería, Universidad de Loyola

ANÁLISIS DE TEXTURA EN LA DETECCIÓN DE OTOSCLEROSIS



ÍNDICE

- 1 OBJETIVOS
- 2 MATERIAL Y MÉTODO
- 3 RESULTADOS
- 4 CONCLUSIONES
- 5 BIBLIOGRAFÍA

La otoesclerosis es una causa frecuente de hipoacusia, con una prevalencia del 0,3% al 1% en la población general. Aparece con mayor frecuencia en el adulto joven (20-40 años).

Por lo general el diagnóstico de esta patología se realiza mediante la exploración clínica y la audiometría. El TC está indicado para confirmar el diagnóstico y para planificar el tratamiento.

Aunque los cambios por imagen en la otosclerosis son normalmente fáciles de reconocer por el radiólogo, la utilización de un **algoritmo de inteligencia artificial** que permita identificar con precisión esta patología **evitaría falsos negativos y retrasos en el diagnóstico.**

OBJETIVOS

- Determinar si el **análisis de textura** permite identificar con precisión la otosclerosis en imágenes de TC de peñasco, empleando para ello técnicas de **Machine Learning (ML)**.
- **Comparar la precisión del algoritmo** de inteligencia artificial (IA) con la precisión diagnóstica de un radiólogo especializado en cabeza y cuello y de radiólogos generales.

MATERIAL Y MÉTODO

CRITERIOS DE INCLUSIÓN

Se seleccionaron pacientes con TC de peñasco realizado en nuestro centro entre 2013 y 2019, sin contraste y con reconstrucciones de 1 mm de grosor.

- **CASOS:** 50 pacientes con sospecha clínica de otosclerosis y audiometría compatible, con hallazgos en TC de otosclerosis fenestral.
- **CONTROLES:** 50 pacientes sin hipoacusia que se realizaron el TC por diferentes sospechas clínicas (e.g. osteoma del CAE) y sin hallazgos en imagen sugestivos de otosclerosis.

CRITERIOS DE EXCLUSIÓN

- Presencia de artefactos metálicos o de artefactos por movimiento.
- Pacientes con cirugía de estapedectomía previa.

ANÁLISIS DE TEXTURA

Se empleó el software 3D Slicer (software gratuito y de código abierto para análisis de imágenes).

1. Se realizó una segmentación manual de la **fissula ante fenestram** estableciendo los siguientes límites:

- **Anterior: canal del nervio facial.**
- **Posterior: vestíbulo.**
- **Medial: cóclea.**
- **Lateral: canal del nervio facial-caja timpánica.**

La segmentación se trazó con un margen de 1 mm de las estructuras descritas para evitar volumen parcial.

2. Se extrajeron estadísticos de primer orden: **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 **skewness (asimetría)**.



Fig 1. Ejemplo de segmentación de fissula ante fenestram en paciente con audiometría sugestiva de otoesclerosis.

ANÁLISIS DE DATOS

Los datos extraídos se analizaron con Python, lenguaje de programación multiparadigma.

Primero se realizó un **análisis de regresión logística** para determinar la existencia de **variables con capacidad discriminatoria**.

Posteriormente se generó un **clasificador con K-Means** para trazar clusters de pacientes en base a similitudes en las variables medidas.

Por último, se generó un **clasificador con Random Forest** para encontrar una **combinación de variables que permitiese predecir la presencia de otosclerosis** con los valores de análisis de textura.

Se calcularon la **precisión**, la **sensibilidad**, la **especificidad**, el **valor predictivo positivo** y el **valor predictivo negativo** del 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.

COMPARATIVA DE PRECISIÓN DIAGNÓSTICA Machine vs Human

Se realizó una **lectura ciega** del TC de peñasco por un **radiólogo especialista en cabeza y cuello**.

Además se revisó el **informe de TC de peñasco** realizado (informado por radiólogos generales), identificando aquellos casos informados de forma positiva y negativa para otosclerosis.



Se calculó la **precisión diagnóstica** del radiólogo de cabeza y cuello y del informe realizado para el TC de peñasco, y se **comparó con la precisión diagnóstica del modelo de inteligencia artificial** mediante un test de la Chi Cuadrado.

RESULTADOS

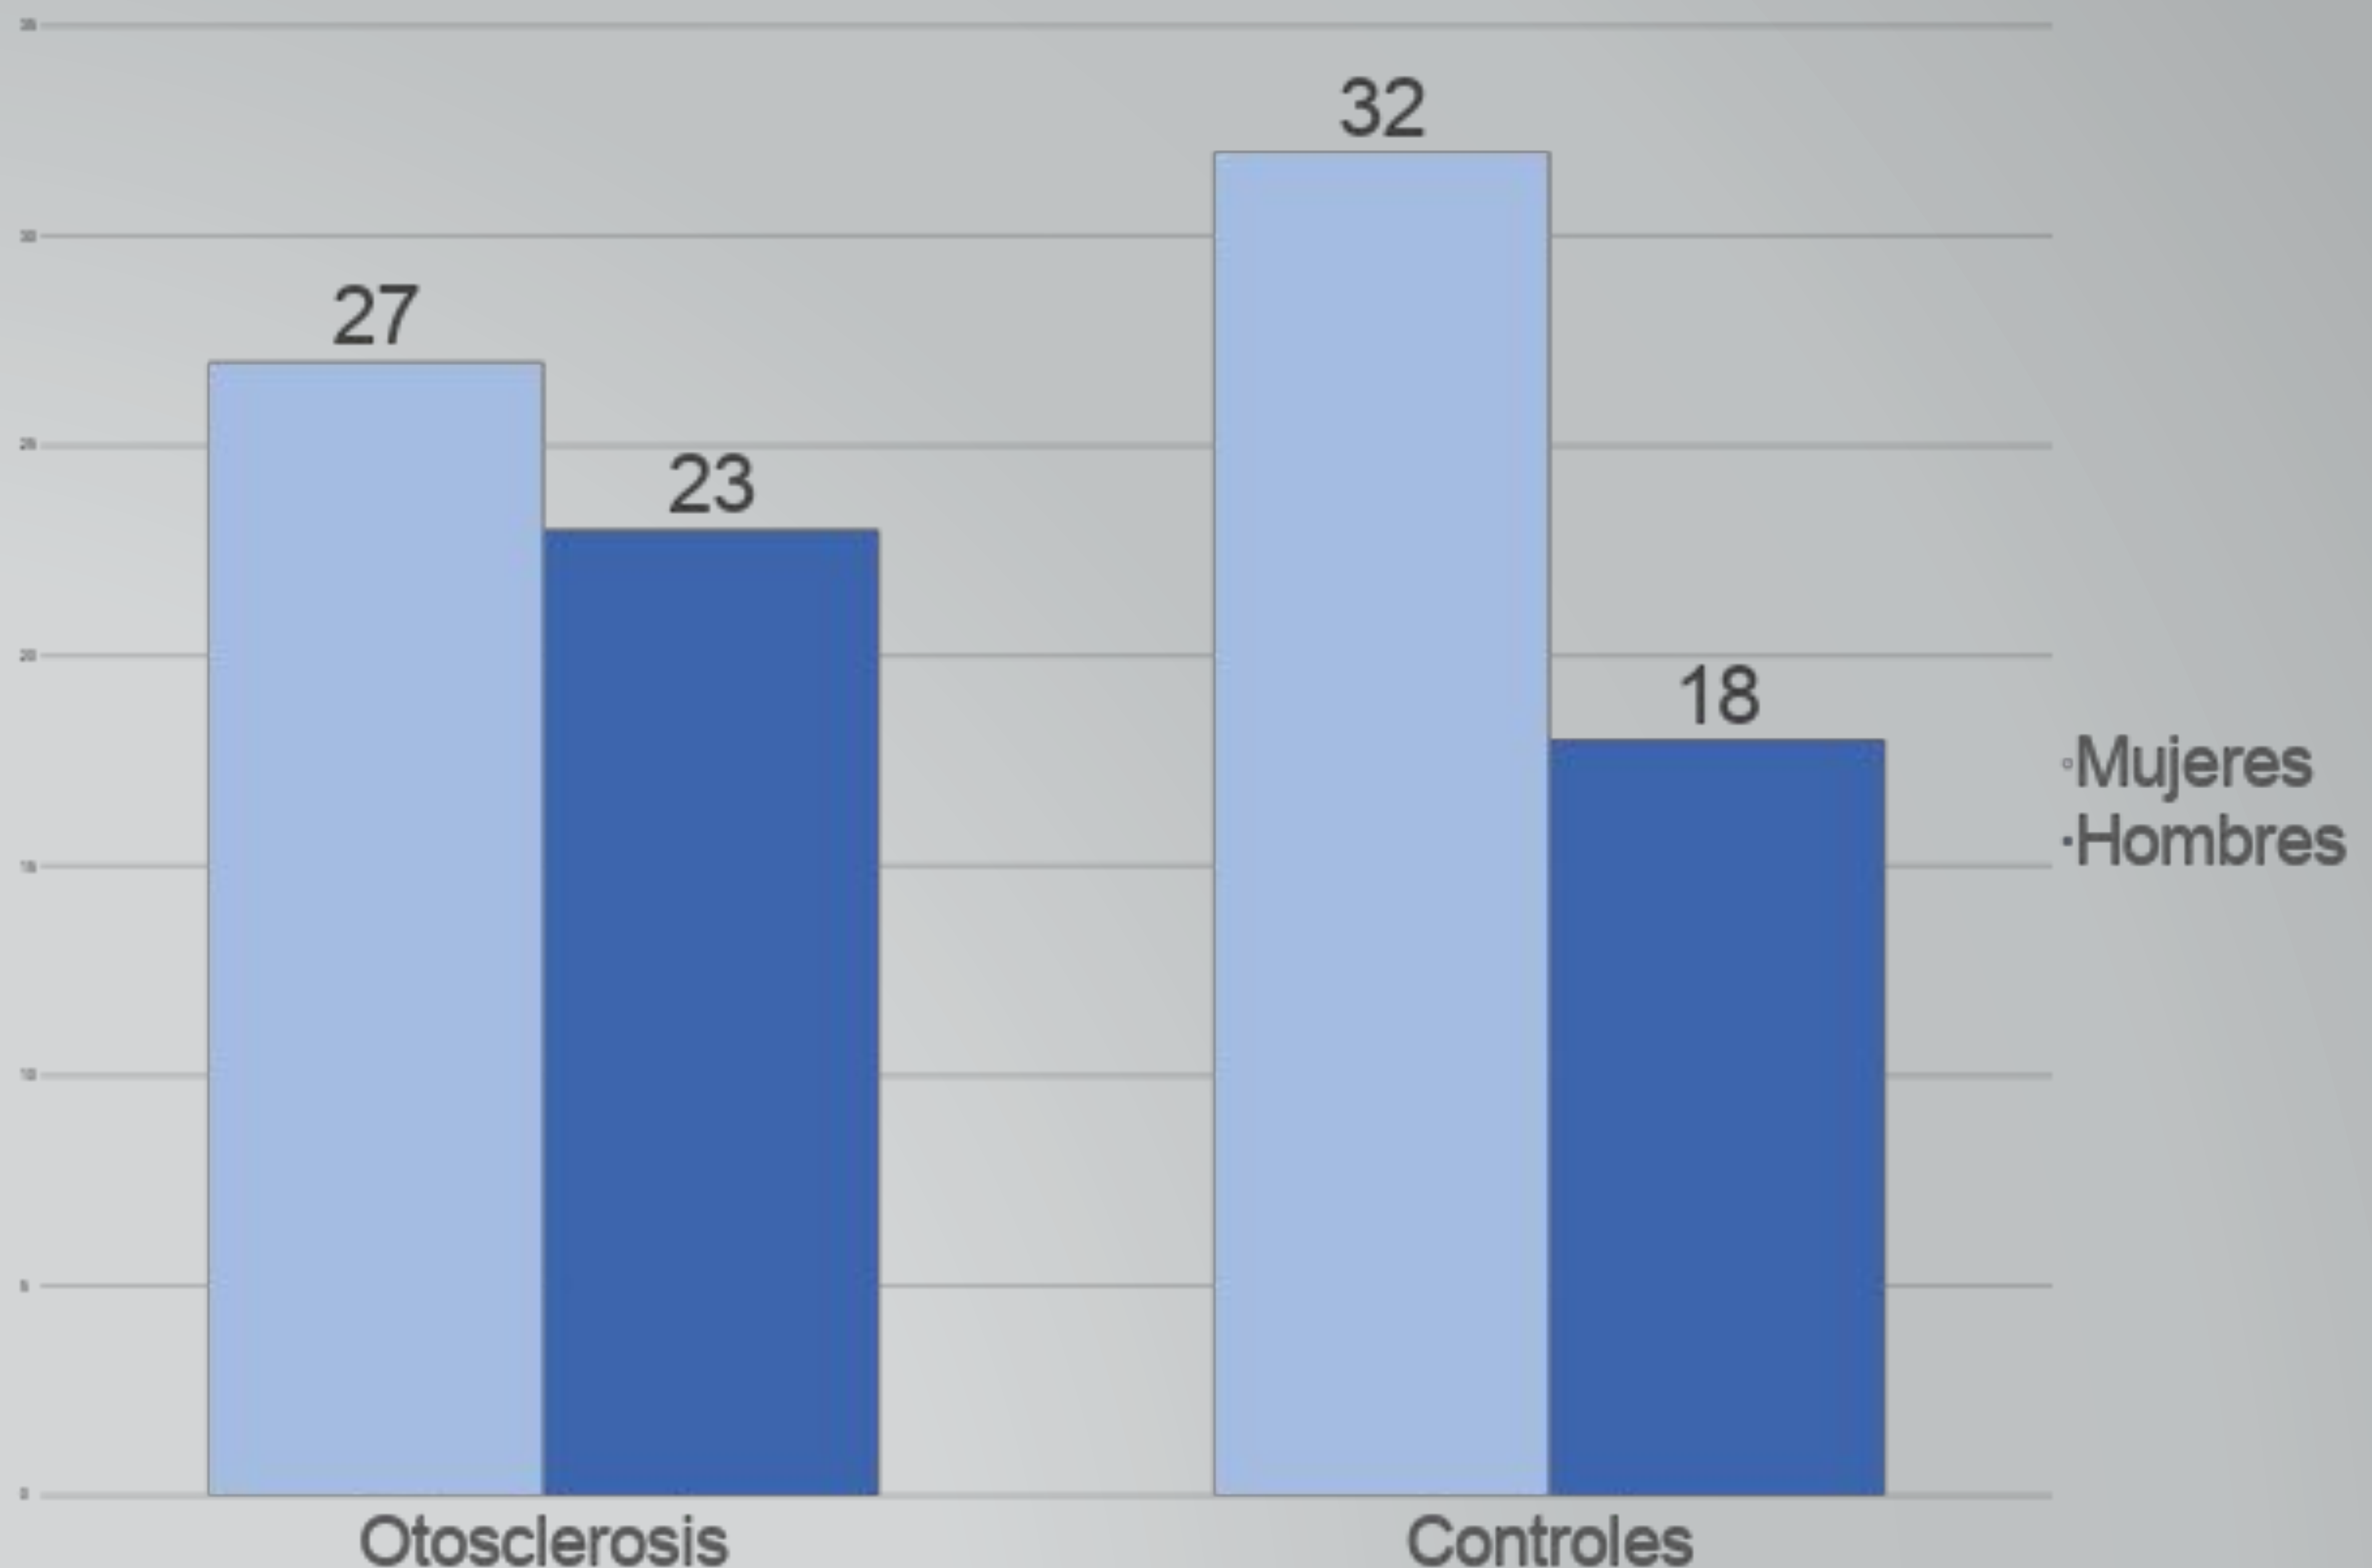
DATOS DEMOGRÁFICOS

La media de edad en pacientes con **otosclerosis** fue de **44** años.

27 pacientes eran mujeres (54%), 23 hombres (46%).

La media de edad en pacientes del **grupo control** fue de **38** años.

32 pacientes eran mujeres (64%), 18 hombres (36%).



DATOS DE ANÁLISIS DE TEXTURA

La media de los valores del análisis de textura en el grupo de pacientes con otosclerosis y en el grupo control fueron:

InterquartileRange	229.0
Skewness	-0.2728
Uniformity	0.0444
Median	1955
Energy	865176316
RobustMeanAbsoluteDeviation	97,34
MeanAbsoluteDeviation	138,89
TotalEnergy	23762777,23
Maximum	2399
RootMeanSquared	1952,27
90Percentile	2143.6
Minimum	1081,00
Entropy	4,73
Range	1018,00
Variance	30226,33
10Percentile	1214,00
Kurtosis	3,07
Mean	1844,51

OTOSCLEROSIS

InterquartileRange	166.5
Skewness	-0.2025
Uniformity	0.0771
Median	2036
Energy	147687774
RobustMeanAbsoluteDeviation	67,59
MeanAbsoluteDeviation	98,78
TotalEnergy	8077175,44
Maximum	2272
RootMeanSquared	2025,45
90Percentile	2149.0
Minimum	1768.0
Entropy	3,87
Range	504.0
Variance	141788302469,00
10Percentile	1891.0
Kurtosis	2,68
Mean	2021,94

CONTROL




Fig 2. Histograma obtenido en el análisis de textura en un oído con otosclerosis (A) y en un paciente control (C). El rango de densidades en el oído con otosclerosis fue más amplio, mostrando valores por debajo de 1000 UH en algunos casos (B). En el oído sano la densidad mínima mostraba valores mayores a 1300 UH en todos los casos.

REGRESIÓN LOGÍSTICA

Se realizó un análisis de regresión logística binaria con los datos de textura, mostrando **una precisión del 96%** para diferenciar entre pacientes con otosclerosis y grupo control.

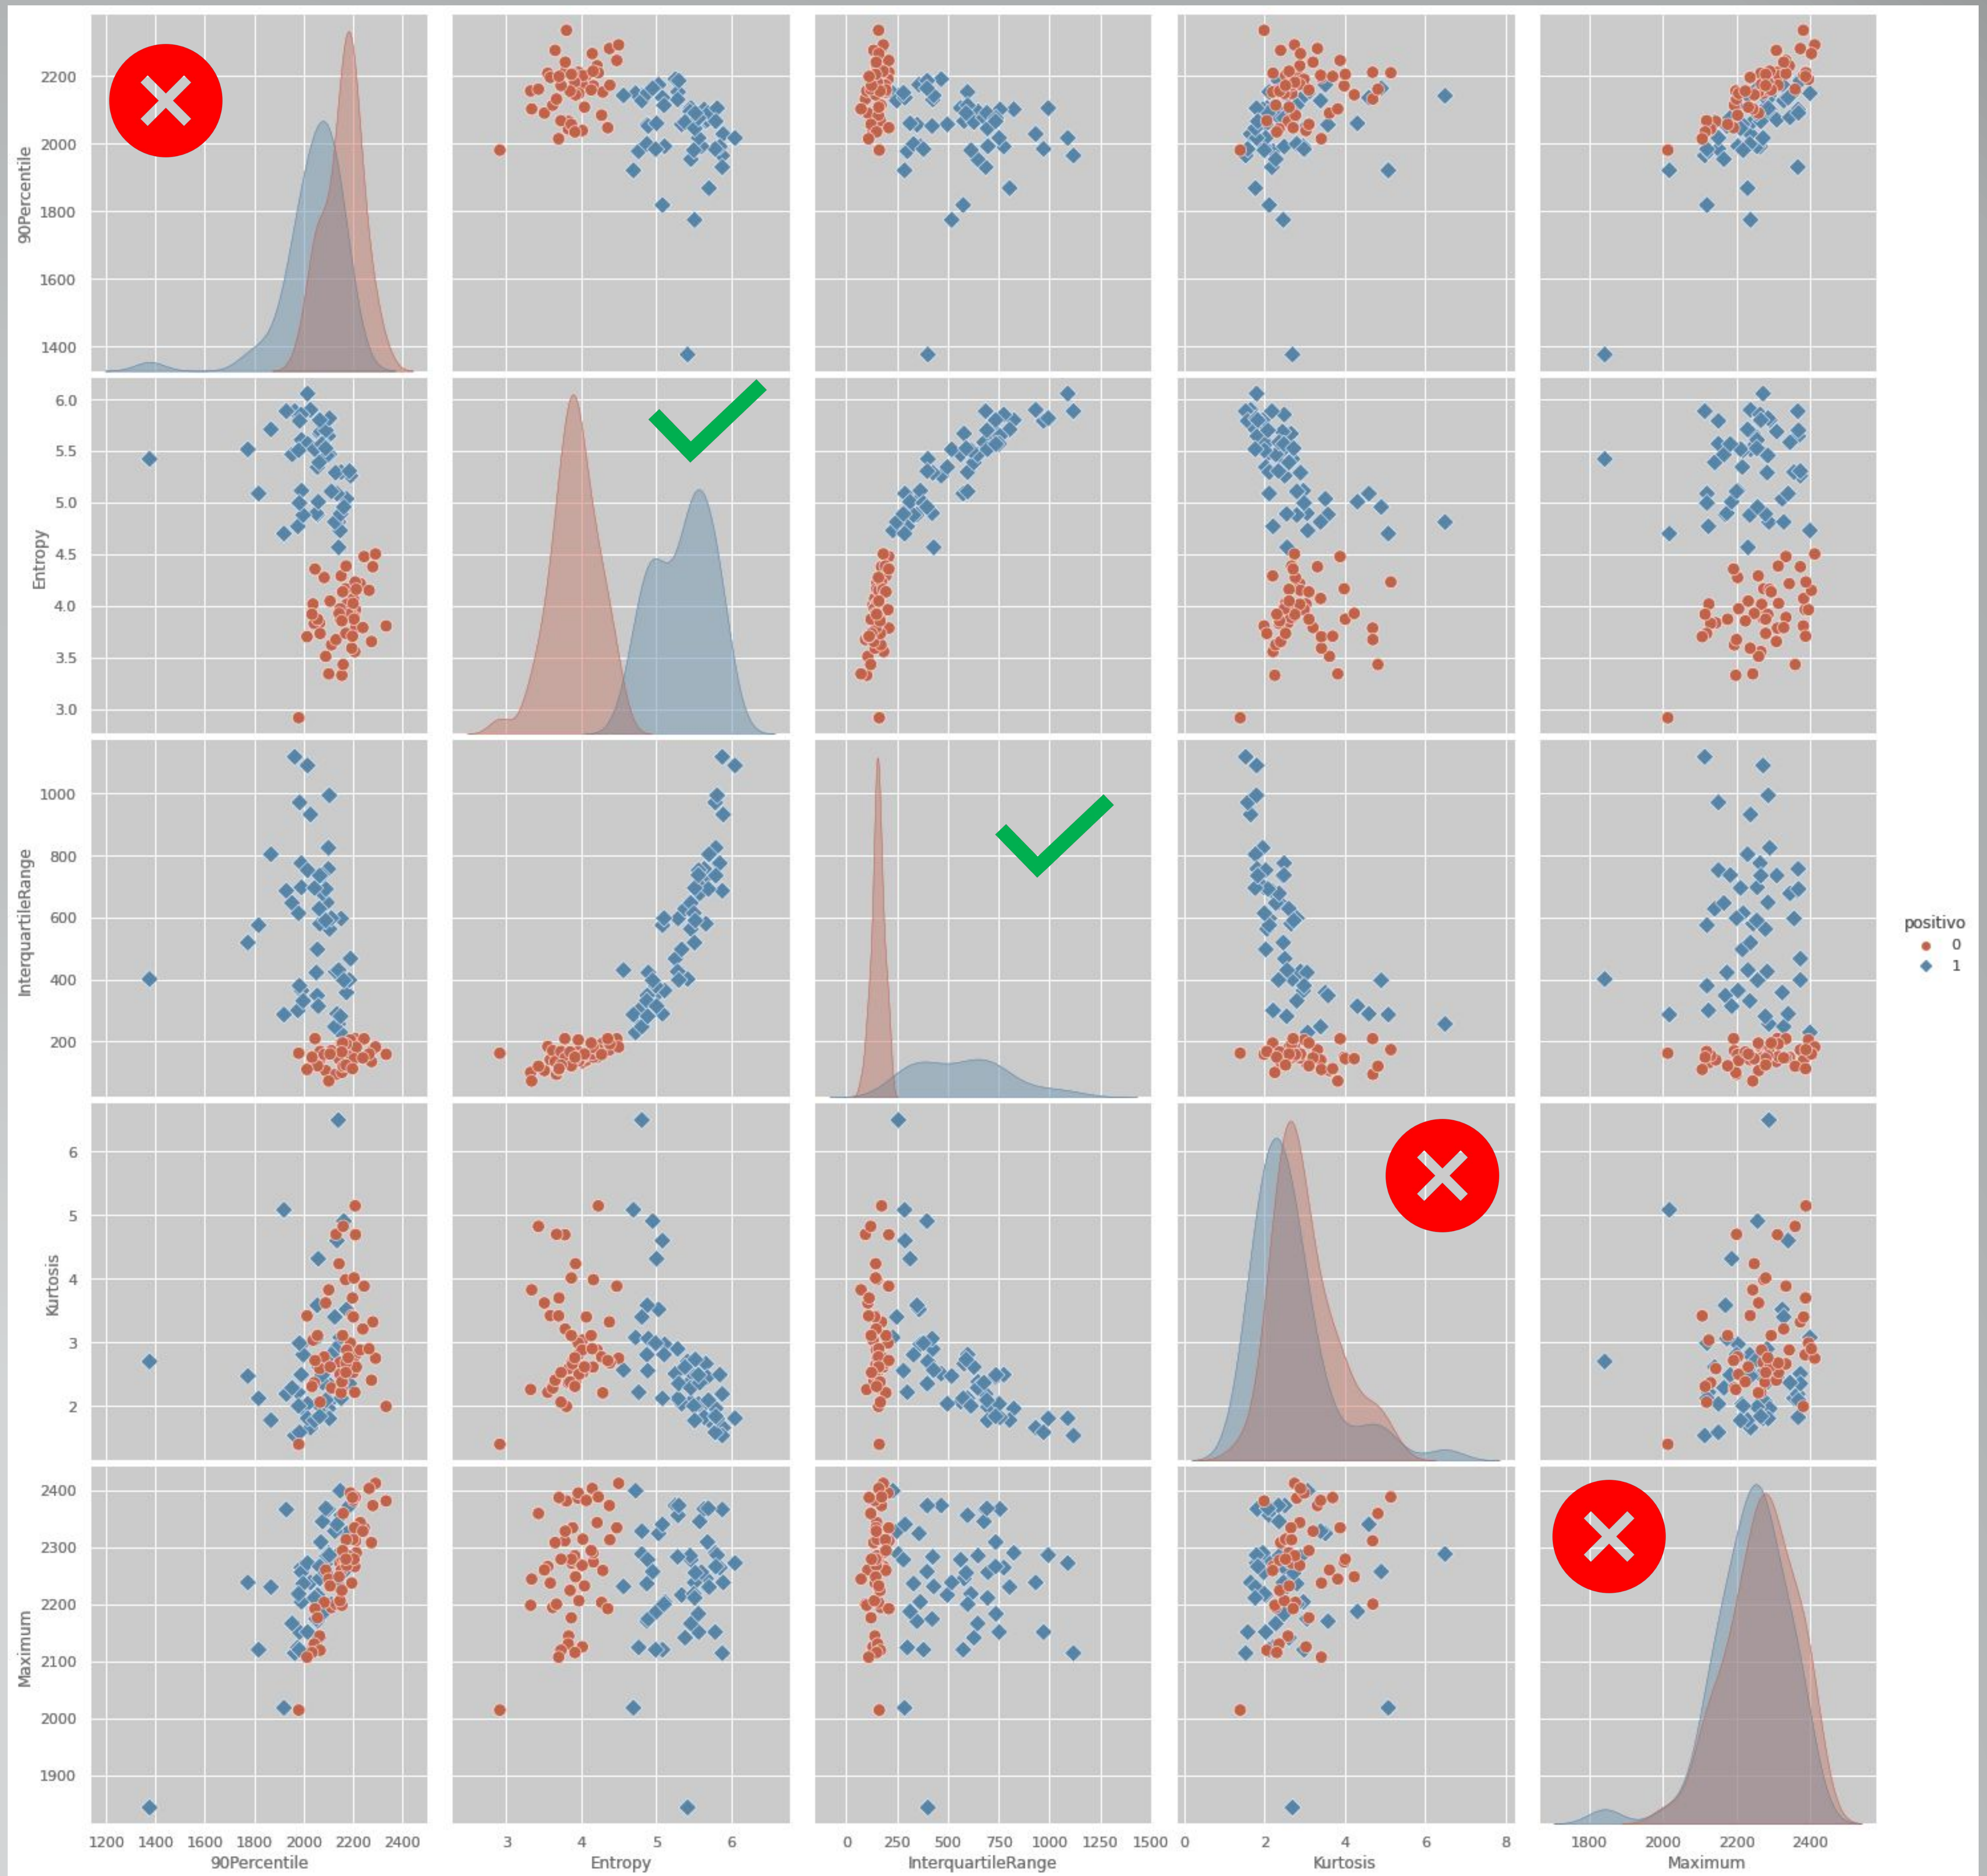
Su **sensibilidad fue del 92%** y su **especificidad del 100%**. La tasa de falsos positivos fue del 0%, y de falsos negativos del 7,7% con un VPN del 92,3% y VPP del 100%.

Estos datos demuestran que **ciertas variables** empleadas **son útiles para predecir la presencia de otosclerosis**.

	feature	correlation	abs_correlation	significance	significant
3	Entropy	0.915804	0.915804	0.000000	True
16	Uniformity	-0.907511	0.907511	0.000000	True
10	Minimum	-0.898577	0.898577	0.000000	True
11	Range	0.879762	0.879762	0.000000	True
7	MeanAbsoluteDeviation	0.865556	0.865556	0.000000	True
0	10Percentile	-0.860083	0.860083	0.000000	True
12	RobustMeanAbsoluteDeviation	0.826257	0.826257	0.000000	True
4	InterquartileRange	0.809388	0.809388	0.000000	True
17	Variance	0.802250	0.802250	0.000000	True
13	RootMeanSquared	-0.695983	0.695983	0.000000	True
9	Median	-0.620337	0.620337	0.000000	True
2	Energy	0.619792	0.619792	0.000000	True
6	Maximum	0.414966	0.414966	0.000022	True
5	Kurtosis	-0.271127	0.271127	0.006926	True
1	90Percentile	-0.171823	0.171823	0.090696	False
15	TotalEnergy	0.145560	0.145560	0.152686	False
14	Skewness	-0.106710	0.106710	0.295647	False
8	Mean	0.098477	0.098477	0.334690	False

Tabla 1. Grado de correlación y significación estadística de las variables de análisis de textura para detectar otosclerosis (calculado con correlación de Pearson). Las variables destacadas en rojo oscuro fueron estadísticamente significativas para dicha detección, siendo las más relevantes la entropía, uniformidad, densidad mínima y rango de densidades.

REGRESIÓN LOGÍSTICA

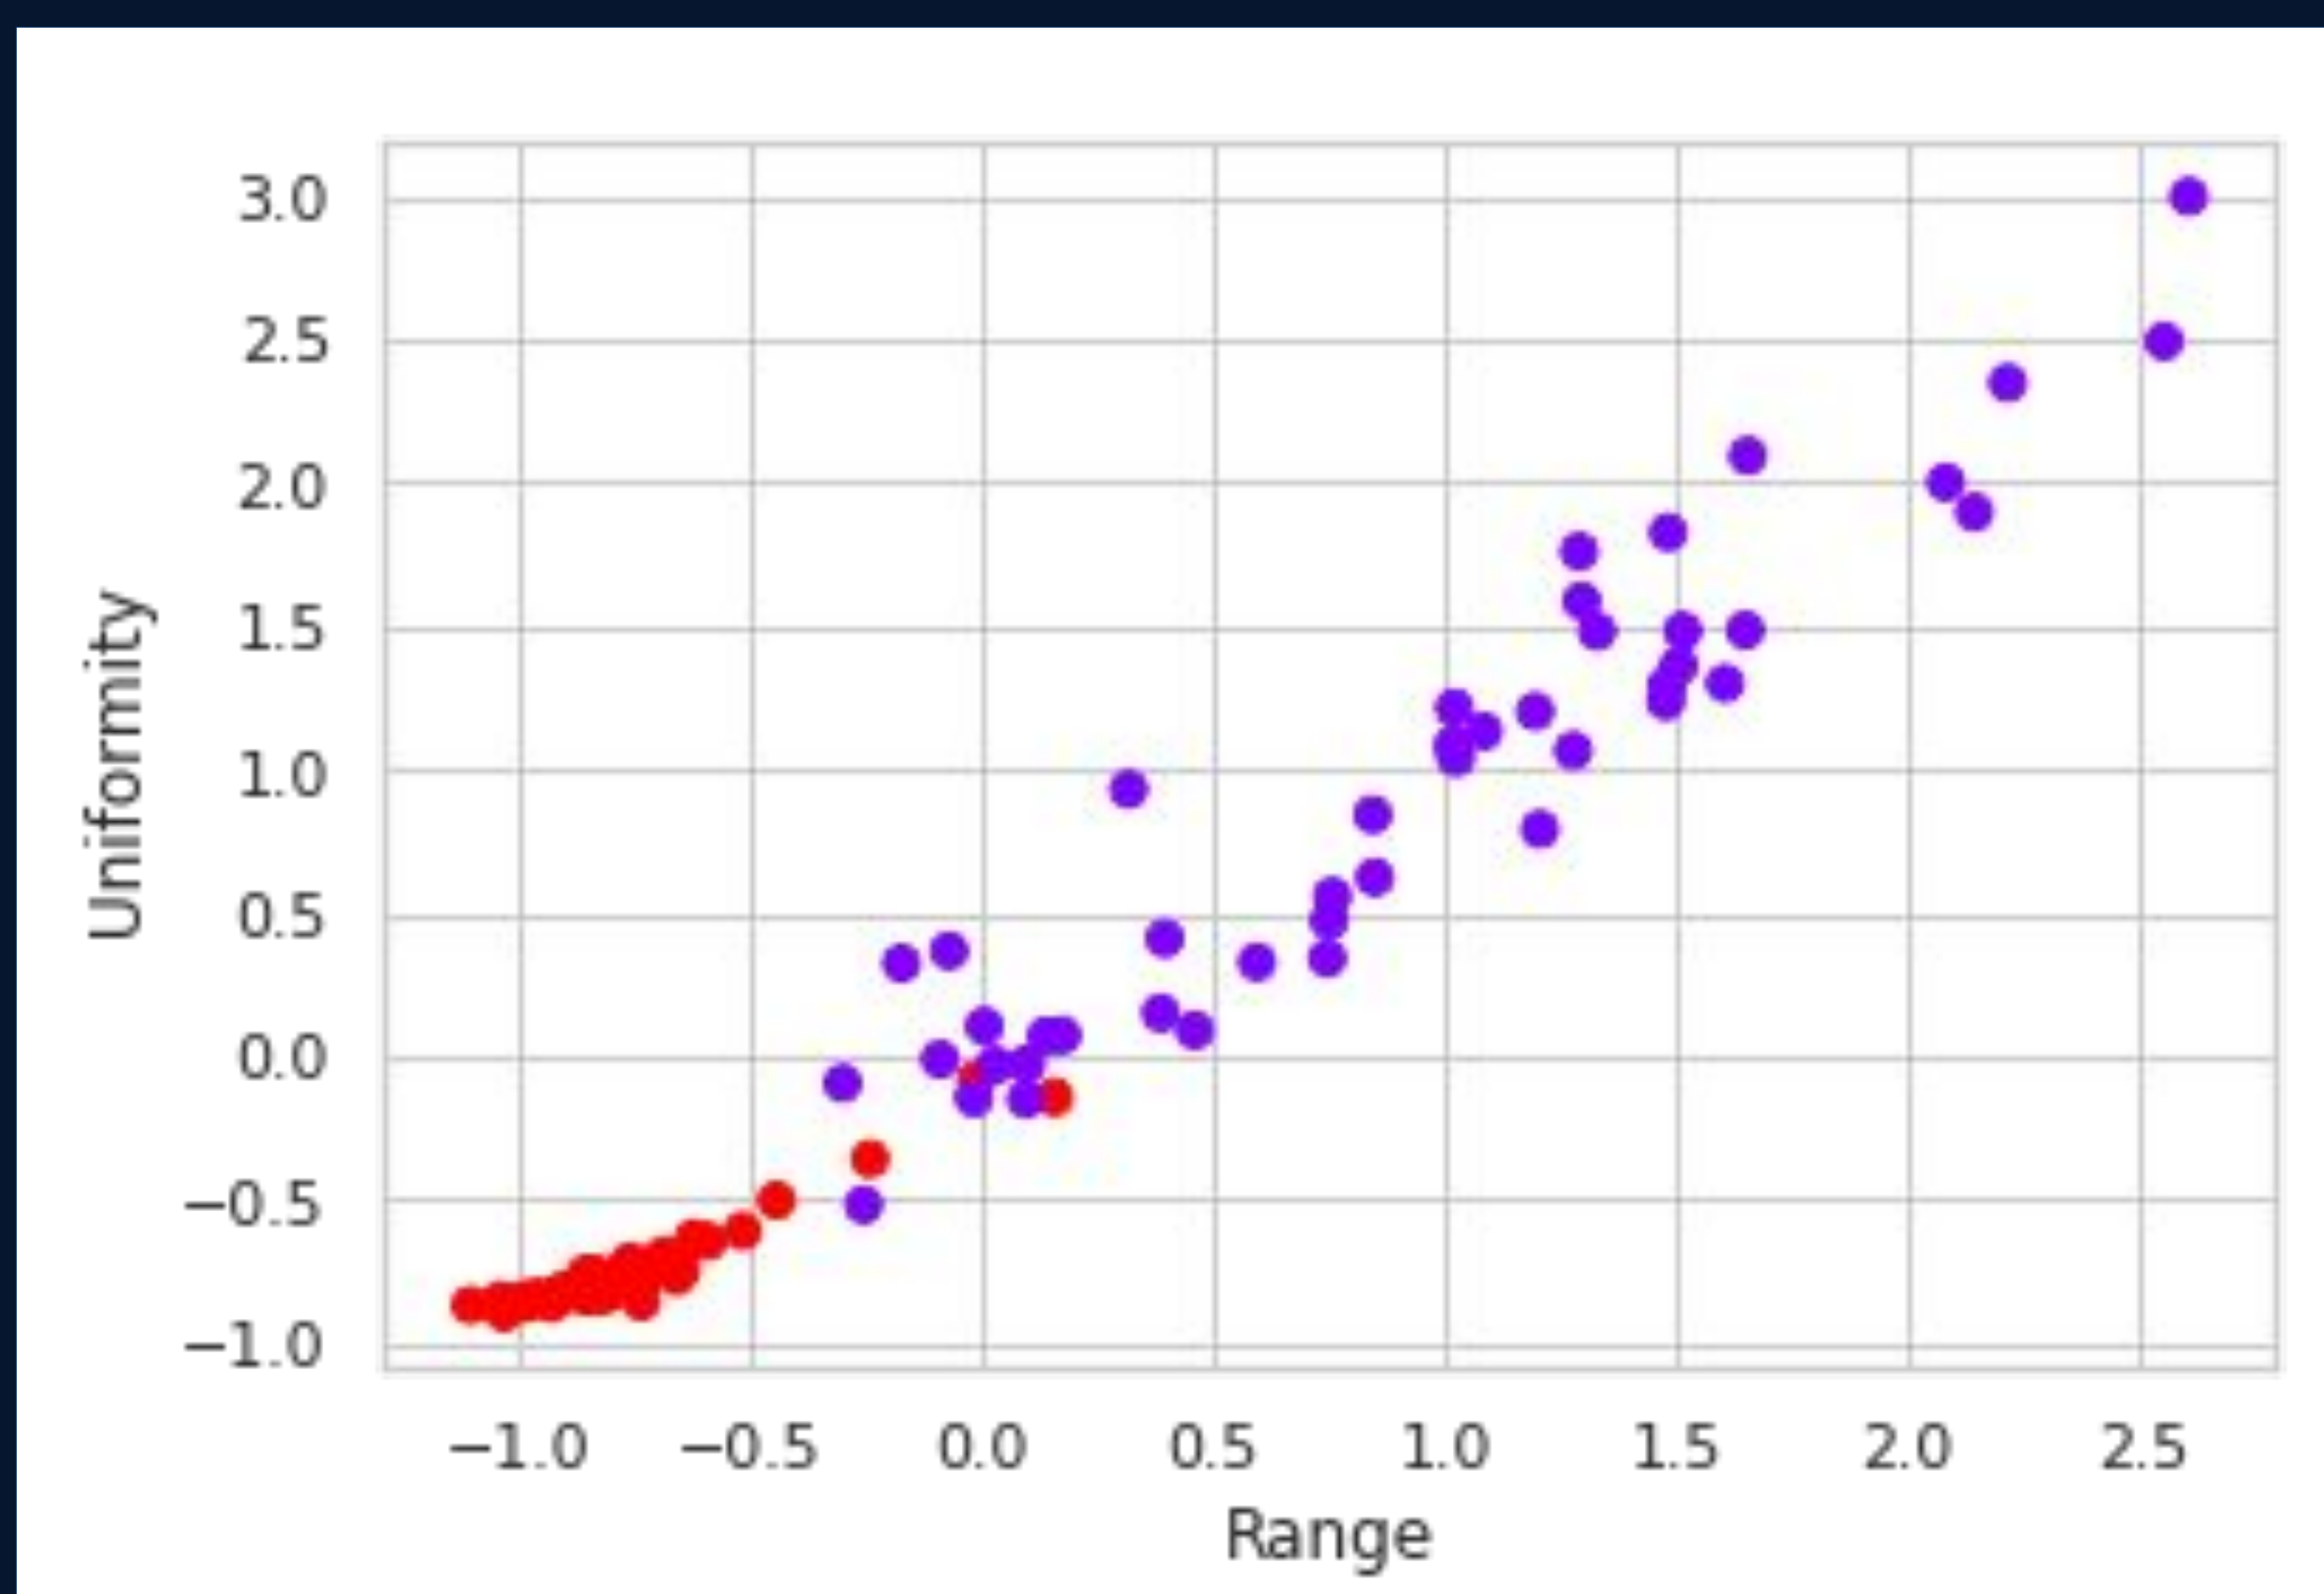


Grafica 1. Gráfica de dispersión de pares de variables, selección de algunos pares significativos. Ciertos predictores como el percentil 90 de densidad o la densidad máxima no permiten diferenciar entre el grupo control y el grupo de otosclerosis, mientras que otras variables como la entropía o el rango intercuartílico muestran buena separación de grupos y son útiles para diferenciar a estos pacientes.

K MEANS

Dado que el análisis de regresión logística demuestra que hay variables útiles para la predicción de otosclerosis, se construyen modelos de ML para mejorar los modelos estadísticos tradicionales.

El clasificador K MEANS mostró una **precisión del 93%** para detección de otosclerosis (sensibilidad del 100%, especificidad del 88%; VPP 87%, VPN 100%).



Gráfica 2.

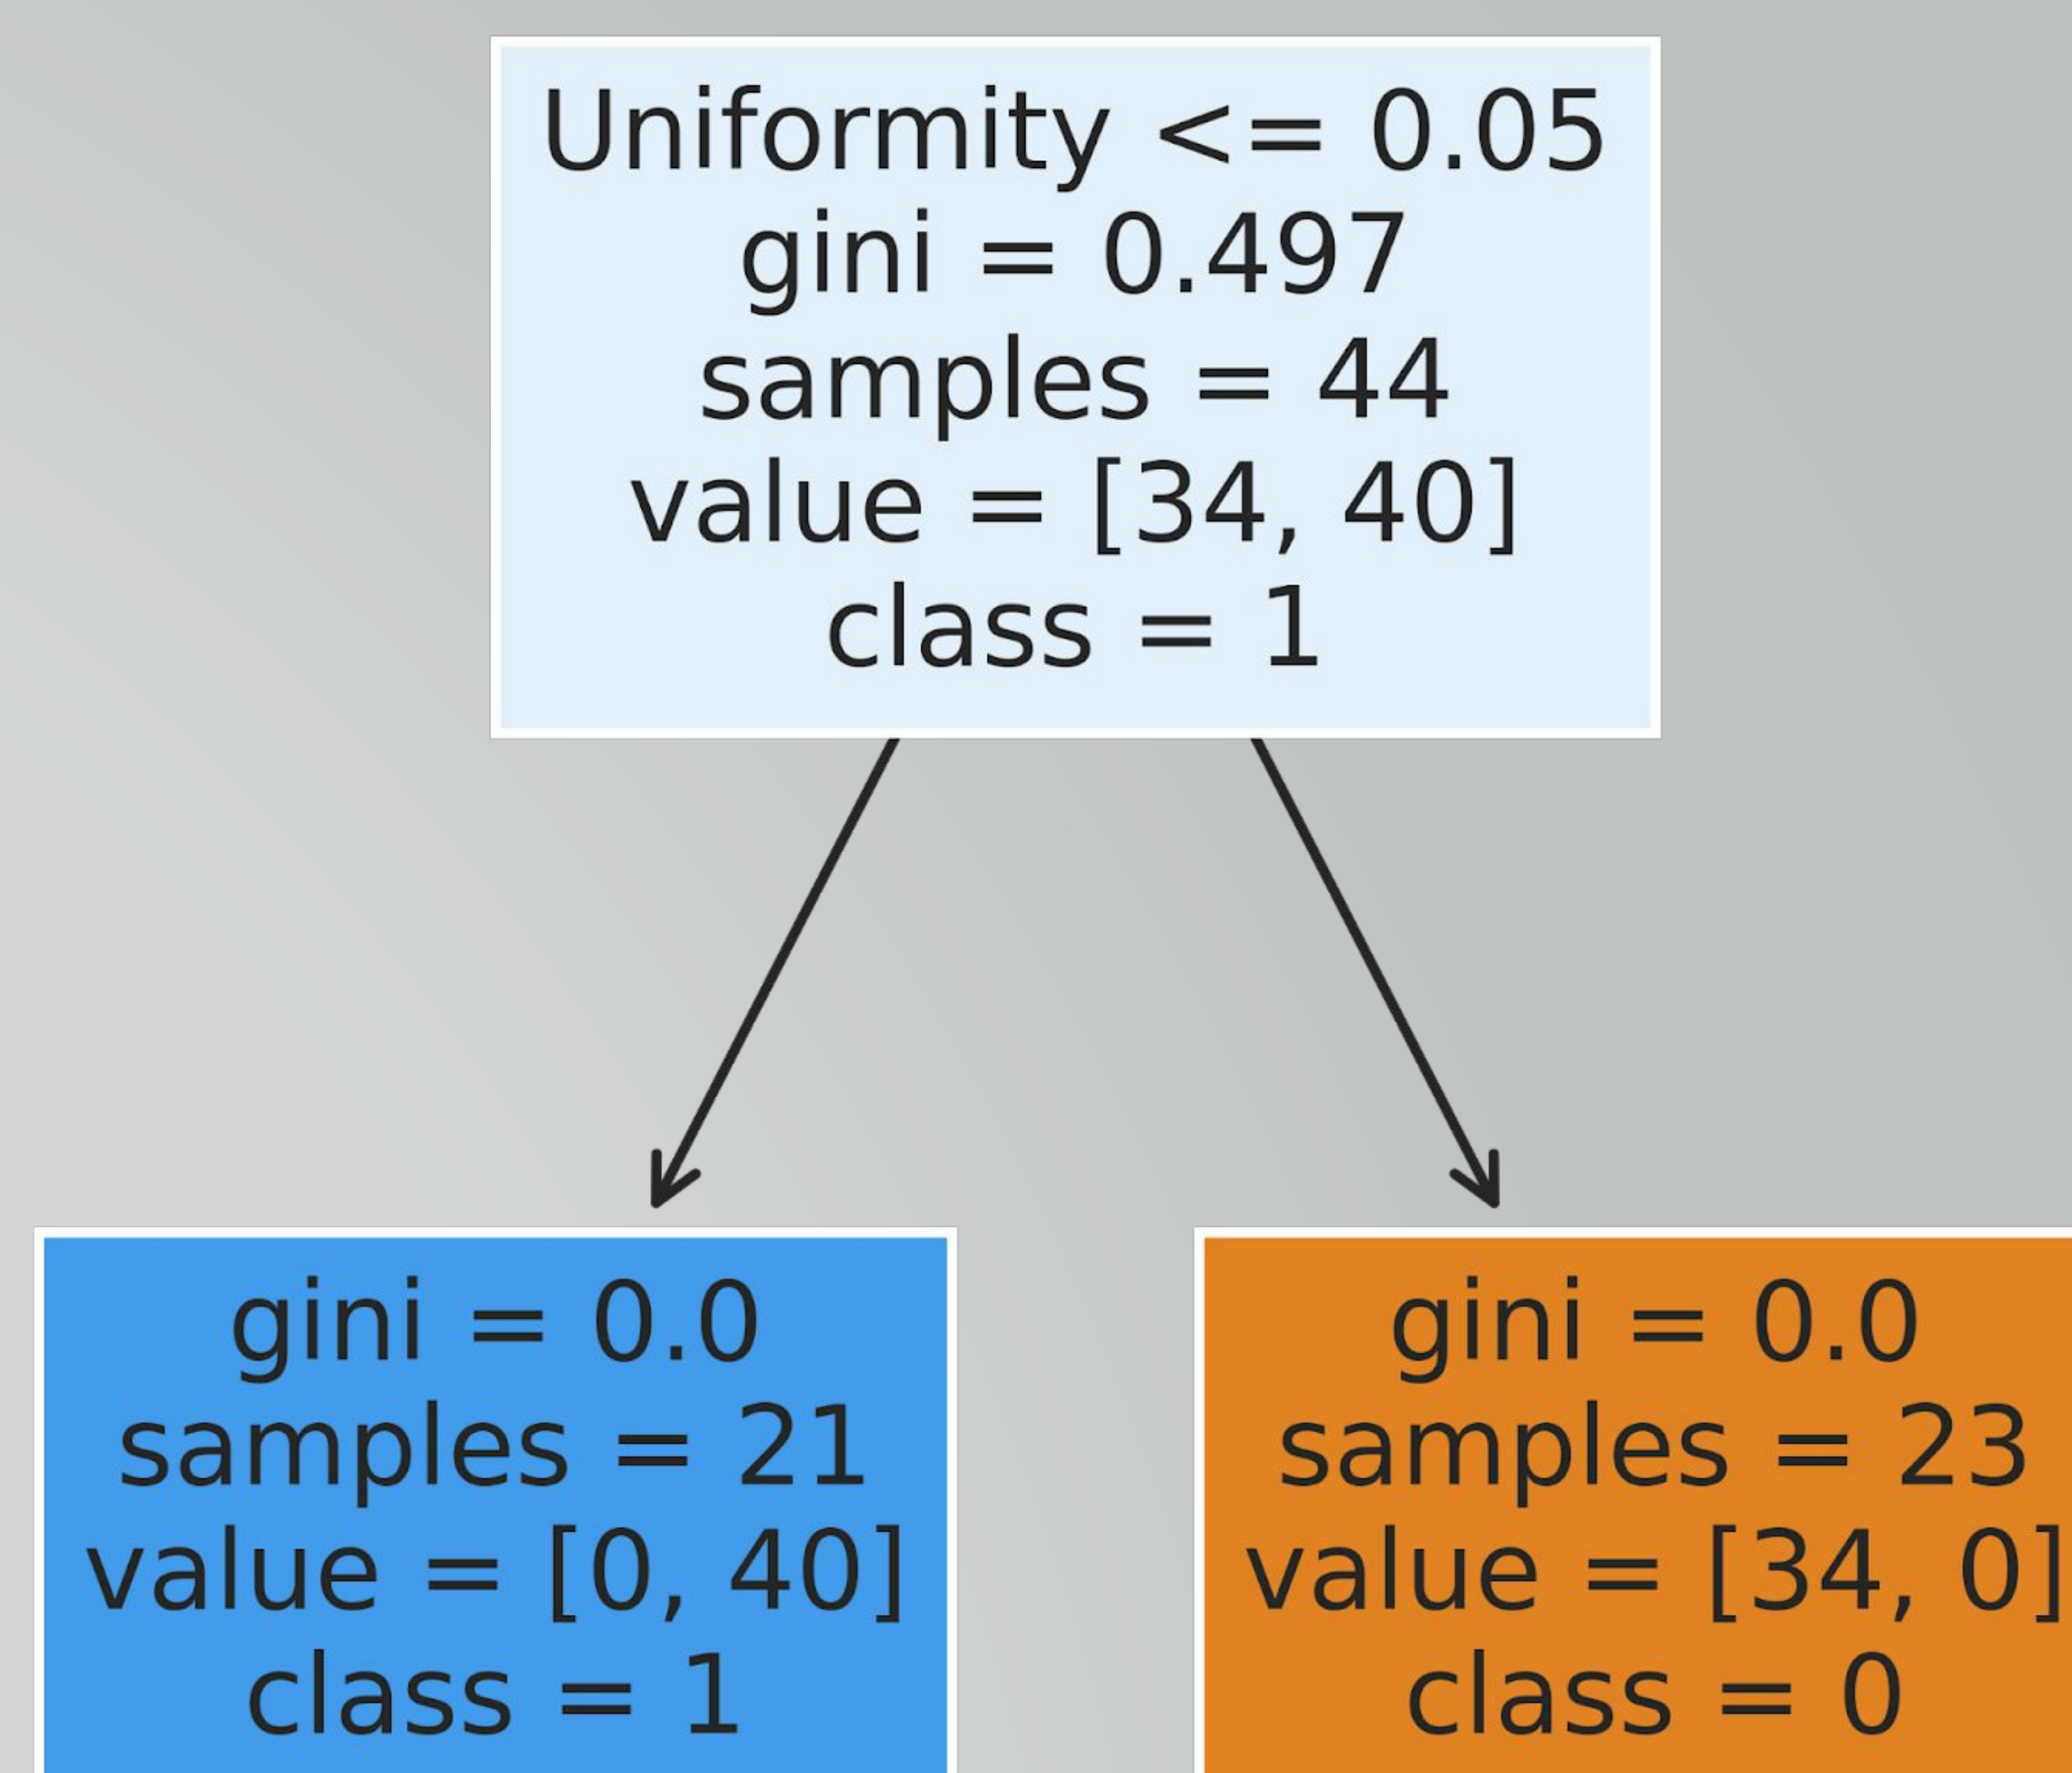
Representación en 2 dimensiones de dos variables, clasificador K MEANS.

Se observa una aceptable separación del grupo control y del grupo con otosclerosis mediante las variables ejemplo (uniformidad y rango intercuartílico). Estas variables ya demostraron su utilidad para la predicción de otosclerosis en el análisis de regresión logística.

RANDOM FOREST

Se emplea un clasificador Random Forest (RF) basado en las variables del análisis de textura para mejorar el rendimiento del modelo de ML.

El clasificador Random Forest mostró una precisión del 100% para predecir otosclerosis (sensibilidad del 100%, especificidad del 100%; VPP 100%, VPN 100%).



Ejemplo de árbol de decisión realizado con técnica Random Forest

RANDOM FOREST

Este clasificador demostró el **mayor rendimiento** de predicción, **clasificando adecuadamente al 100% de pacientes control y de pacientes con otosclerosis.**

18 variables mostraron ser de utilidad en la predicción, en orden decreciente de relevancia (expresado en %1):

FEATURE	IMPORTANCE
Uniformity	0.119552
MeanAbsoluteDeviation	0.118394
Minimum	0.116411
Entropy	0.113851
Variance	0.112979
RobustMeanAbsoluteDeviation	0.111040
InterquartileRange	0.110961
Range	0.076849
10Percentile	0.074985
Mean	0.026743
RootMeanSquared	0.011924
Median	0.004405
TotalEnergy	0.000912
90Percentile	0.000397
Energy	0.000294
Skewness	0.000178
Maximum	0.000089
Kurtosis	0.000036

COMPARATIVA DE PRECISIÓN DIAGNÓSTICA Machine vs Human

Se analizó la precisión diagnóstica de un radiólogo especializado en cabeza y cuello (CC); también se revisó el informe del TC de peñasco, realizado por radiólogos generales.

RADIOLOGO CC

- Diagnosticó correctamente 48 casos positivos.
- No identificó 2 casos positivos.
- Clasificó adecuadamente todos los casos negativos.

PRECISIÓN: 98%

ESPECIFICIDAD: 100%

SENSIBILIDAD: 96%

RADIOLOGO GENERAL


- Diagnosticó correctamente 42 casos positivos.
- No identificó 8 casos positivos.
- Clasificó adecuadamente todos los casos negativos.

PRECISIÓN: 92%

ESPECIFICIDAD: 100%

SENSIBILIDAD: 84%

COMPARATIVA DE PRECISIÓN DIAGNÓSTICA Machine vs Human



Atenuación media 1894 HU
Atenuación máxima 2641 HU
Atenuación mínima 1102 HU



Atenuación media 1806 HU
Atenuación máxima 2423 HU
Atenuación mínima 1033 HU

Fig 3. Ejemplo de casos de otosclerosis no clasificados adecuadamente por el radiólogo especializado en cabeza y cuello ni por el radiólogo general (A), y no clasificado adecuadamente por el radiólogo general pero sí por el radiólogo de cabeza y cuello (B). Ambos casos eran sintomáticos, tenían una audiometría compatible y el algoritmo de IA los clasificó de forma correcta.

COMPARATIVA DE PRECISIÓN DIAGNÓSTICA Machine vs Human


RADIOLOGO CC

La precisión de detección de otosclerosis por el radiólogo especialista en cabeza y cuello no demostró diferencias significativas con el modelo de Machine Learning ($p=0,29$, test de la Chi cuadrado)

LA PRECISIÓN DE
DETECCIÓN FUE
SIMILAR AL MODELO
DE INTELIGENCIA
ARTIFICIAL

RADIOLOGO GENERAL

La precisión de detección de otosclerosis fue menor que la del modelo de Machine Learning ($p=0,04$, test de la Chi cuadrado).



CONCLUSIONES

La utilización de algoritmos de inteligencia artificial basados en análisis de textura ha demostrado una precisión del 100% para identificar a pacientes con otosclerosis.

El algoritmo permite además descartar esta entidad con un VPN del 100%.

Si bien los hallazgos de otosclerosis en TC suelen ser evidentes, la utilización de técnicas de inteligencia artificial puede evitar falsos negativos y retrasos diagnósticos.

La precisión diagnóstica de un radiólogo de cabeza y cuello es similar a la del algoritmo de IA, si bien esta precisión es discretamente menor con radiólogos generales. En centros no especializados la utilización de algoritmos de IA podría evitar infradiagnosticar casos de otosclerosis.

BIBLIOGRAFÍA

1. Purohit B, Hermans R, Op de Beeck K. Imaging in otosclerosis: A pictorial review. *Insights Imaging*. 2014 Apr;5(2):245-52.
2. Rudic M, Keogh I, Wagner R, Wilkinson E, Kiros N, Ferrary E, Sterkers O, Bozorg Grayeli A, Zarkovic K, Zarkovic N. The pathophysiology of otosclerosis: Review of current research. *Hear Res*. 2015 Dec;330(Pt A):51-6
3. Casas M. JS, Rodríguez D. D, Miranda G. G, de Grazia K. JA. Otoesclerosis: Revisión de Aspectos etiopatogénicos, clínico-demográficos e imagenológicos. *Revista Chilena de Radiología*. 2016;22(3):108–13.
4. Sanghan N, Chansakul T, Kozin ED, Juliano AF, Curtin HD, Reinshagen KL. Retrospective Review of Otic Capsule Contour and Thickness in Patients with Otosclerosis and Individuals with Normal Hearing on CT. *AJNR Am J Neuroradiol*. 2018 Dec;39(12):2350-2355.
5. Shin YJ, Fraysse B, Deguine O, et al. Sensorineural hearing loss and otosclerosis: a clinical and radiological survey of 437 cases. *Acta Otolaryngol* 2001;121:200–04.
6. Virk JS, Singh A, Lingam RK. The role of imaging in the diagnosis and management of otosclerosis. *Otol Neurotol*. 2013 Sep;34(7):e55-60.