

Kalathos+: Construcción de datasets para la clasificación automática de fragmentos de vasijas cerámicas de torno

Congreso Español de
Informática Gráfica
2022

Rafael J. Segura
Antonio J. Rueda
Carlos J. Ogáyar
José M. Fuertes
Ángel L. García-Fernández
Manuel J. Lucena
Alfonso López
Isabel Moreno
Manuel Molinos

The logo for CEIG22 is prominently displayed in the center-right of the slide. The letters 'CEIG' are stacked vertically in a large, bold, yellow font, with '22' to the right. The background of the slide features a stylized, wavy, red and yellow pattern that resembles a rising sun or a stylized 'K' shape, which complements the logo's design.

Contexto

- Arqueología moderna: utilización de modelos digitales.
 - Catalogación.
 - Conservación virtual.
 - Reconstrucción.
 - Investigación.
- Recipientes cerámicos muy fragmentados.
 - Sólo se conserva una mínima parte de estos.
 - Gran fragilidad de recipientes cerámicos.
- Deep Learning para reconocer el tipo de recipiente al que pertenece un fragmento y la posición del mismo dentro de la geometría original.



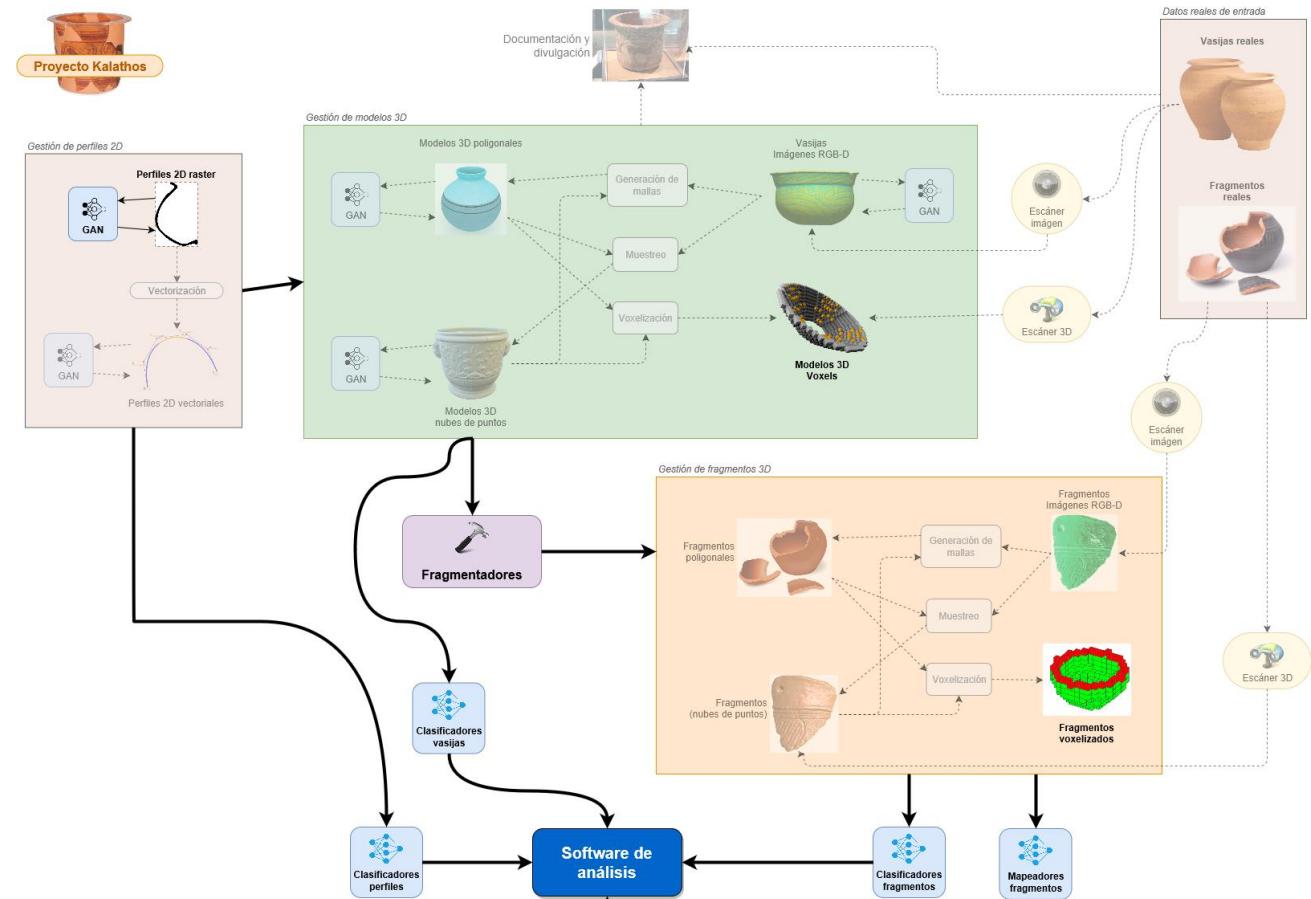
Patena de Cástulo, Linares (Jaén)

Contexto

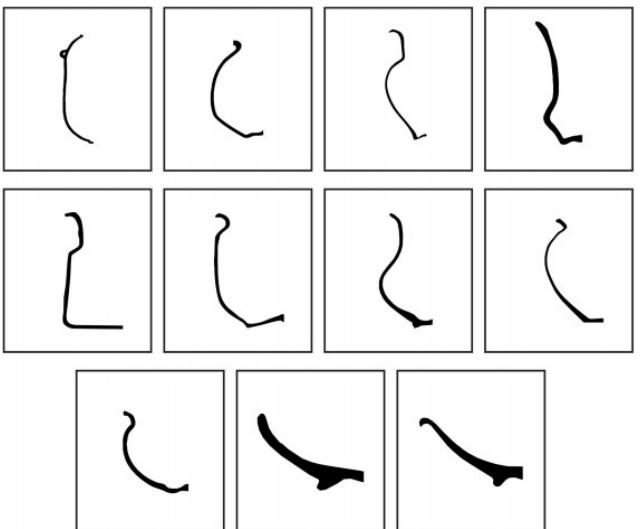
- Arqueología moderna: utilización de modelos digitales.

- Catalogación.
- Conservación virtual.
- Reconstrucción.
- Investigación.

- Kalathos + Pretende.

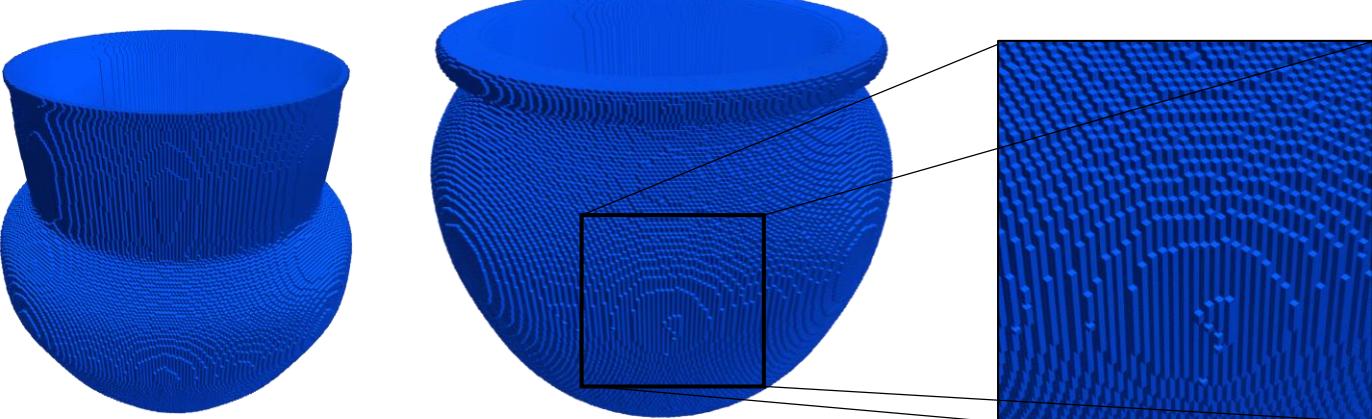


- Deep Learning para reconocer el tipo de recipiente al que pertenece un fragmento y la posición del mismo dentro de la geometría original.
 - Aprendizaje en 2D mediante perfiles de vasijas.
 - Fragmentos de vasijas.
 - Clasificación de fragmentos utilizando como referencia 11 tipos de vasijas íberas.
 - 1282 perfiles clasificados por expertos, pertenecientes al Valle del Guadalquivir.



Contexto

- Deep Learning para reconocer el tipo de recipiente al que pertenece un fragmento y la posición del mismo dentro de la geometría original.
 - Extensión a clasificación de fragmentos 3D.
 - Inviable obtener base de datos de fragmentos 3D a partir de digitalización.
 - Escasez.
 - Dispersión geográfica.
 - Generación realista de **modelos 3D** a partir de perfiles 2D.

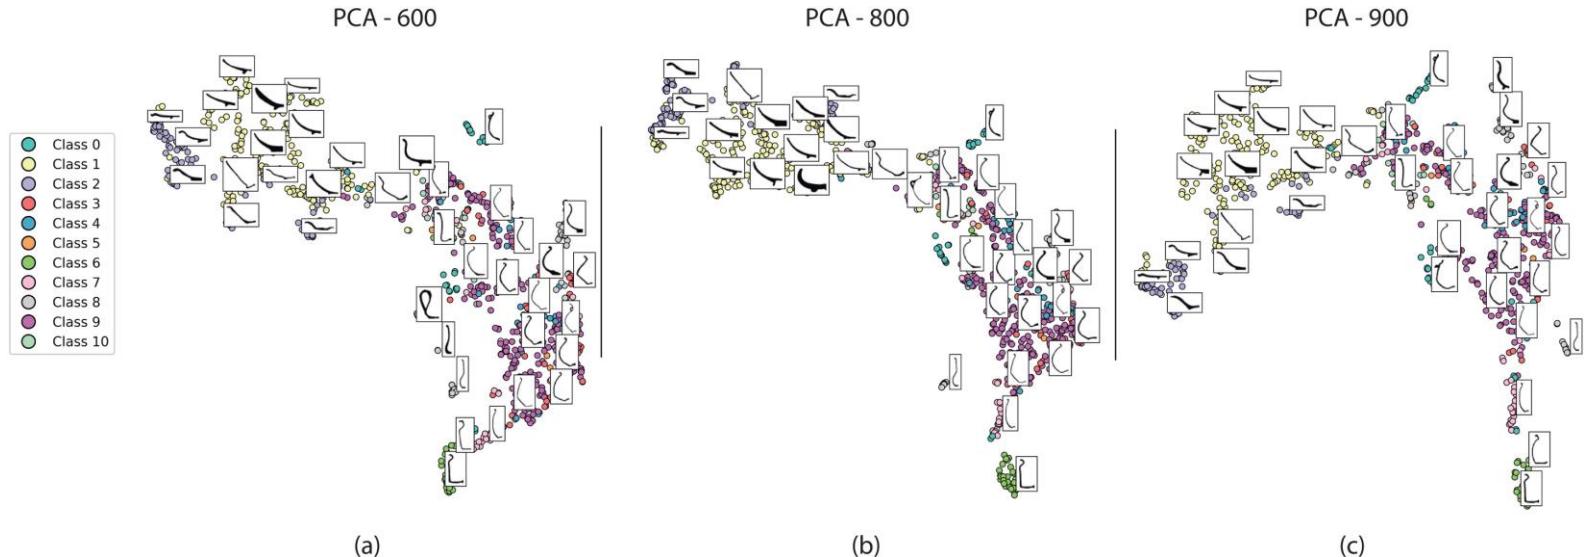


- Alternativas para la clasificación:
 - Construcción de tipologías morfométricas, analíticas y contextuales.
 - Análisis de contenido del recipiente.
- Base de datos de este trabajo.
 - Instituto Universitario de Investigación en Arqueología Ibérica de la Universidad de Jaén.

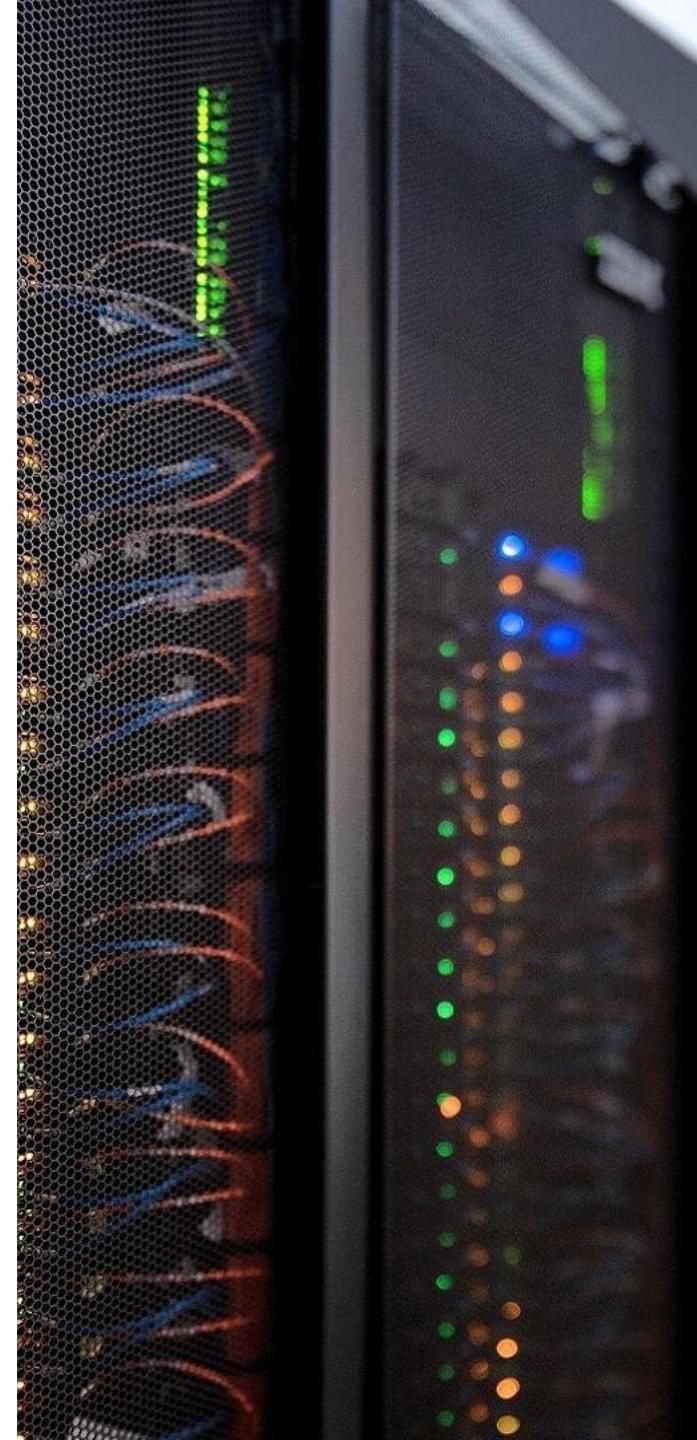


Contexto

- Abaratamiento de clusters de High Performance Computing.
- Deep Learning:
 - Redes neuronales convolucionales (CNN).
 - Clasificación.

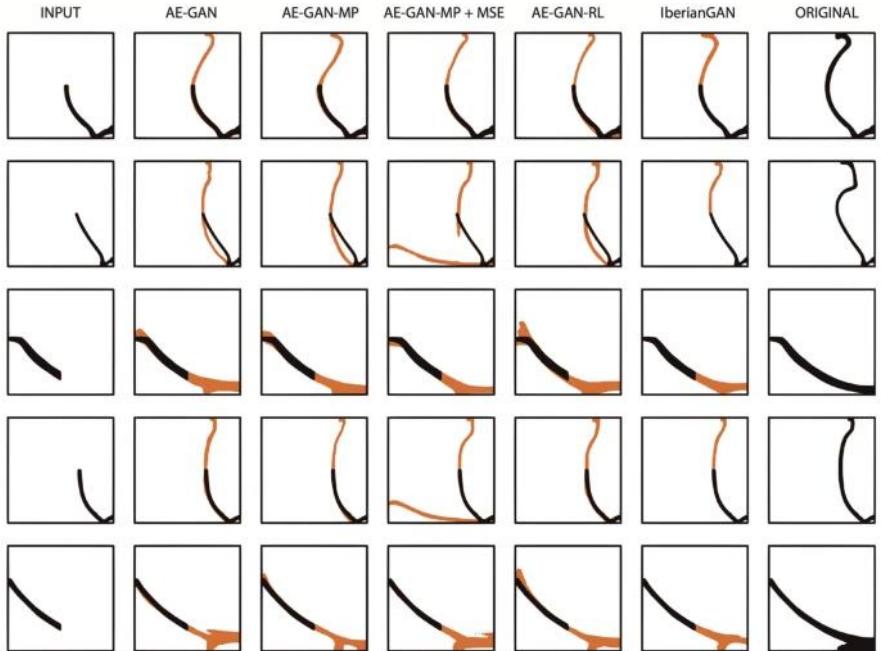


Pablo Navarro, Celia Cintas, Manuel Lucena, José Manuel Fuertes, Claudio Delrieux, Manuel Molinos. **Learning feature representation of Iberian ceramics with automatic classification models.** Journal of Cultural Heritage. Volume 48, 2021, Pages 65-73, ISSN 1296-2074, <https://doi.org/10.1016/j.culher.2021.01.003>.

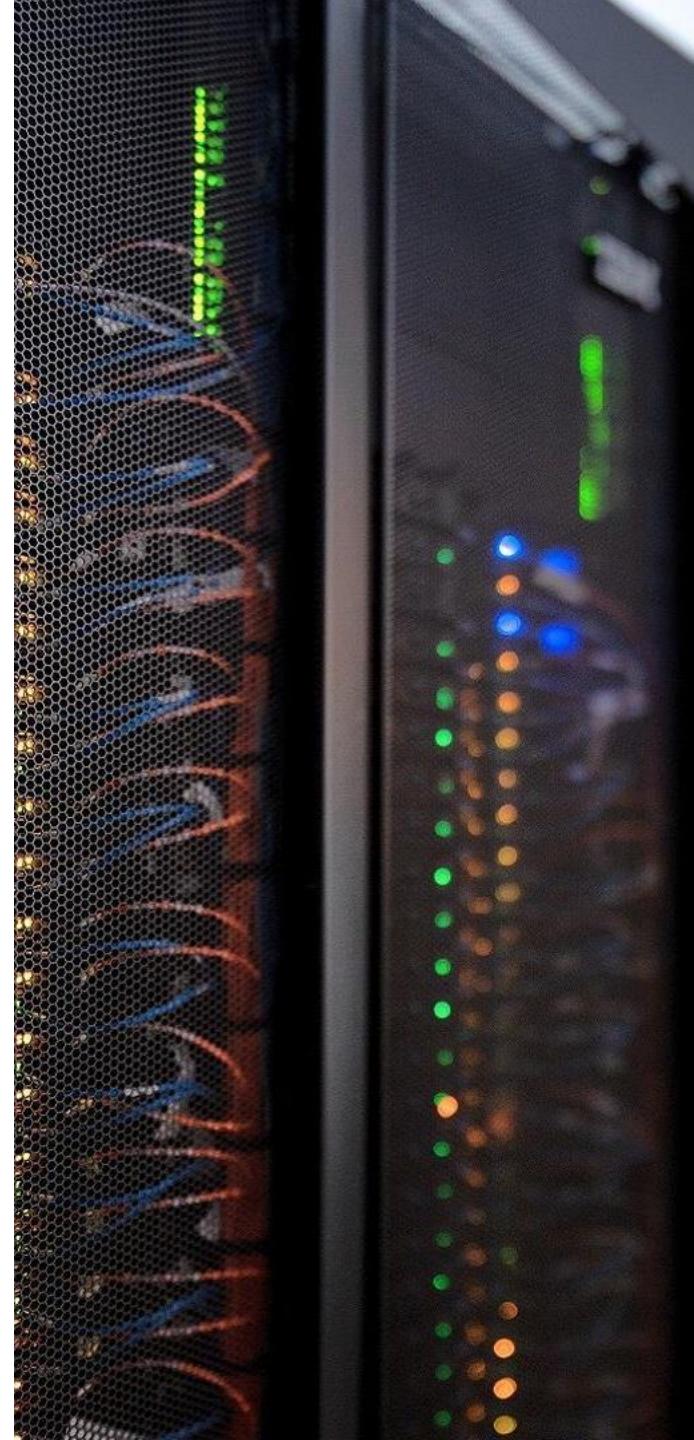


Contexto

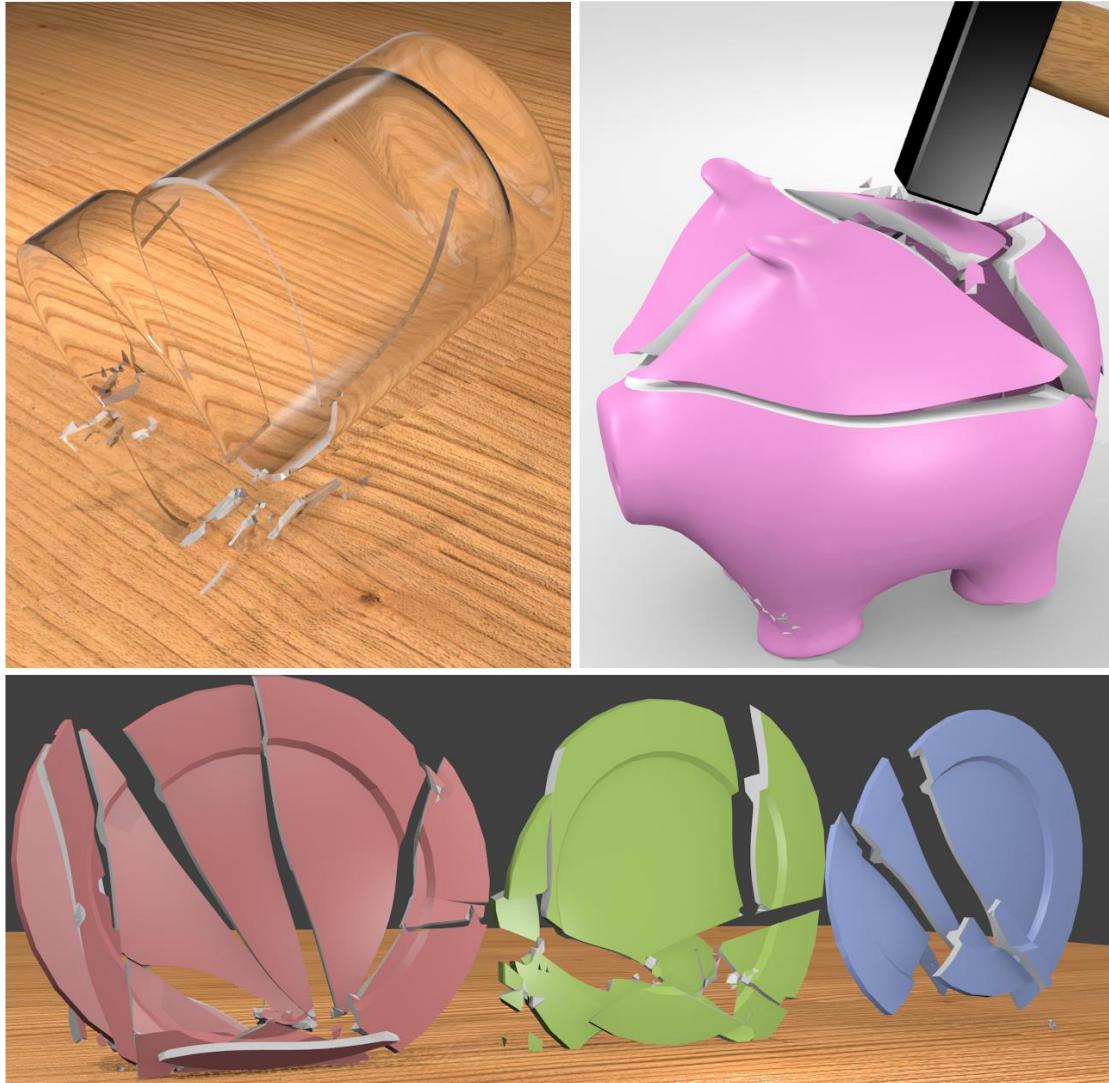
- Abaratamiento de clusters de High Performance Computing.
- Deep Learning:
 - Redes generativas adversarias (GAN).
 - Generación de nuevas vasijas sintéticas.



Navarro, P., Cintas, C., Lucena, M. et al. *Reconstruction of Iberian ceramic potteries using generative adversarial networks*. *Sci Rep* 12, 10644 (2022).
<https://doi.org/10.1038/s41598-022-14910-7>

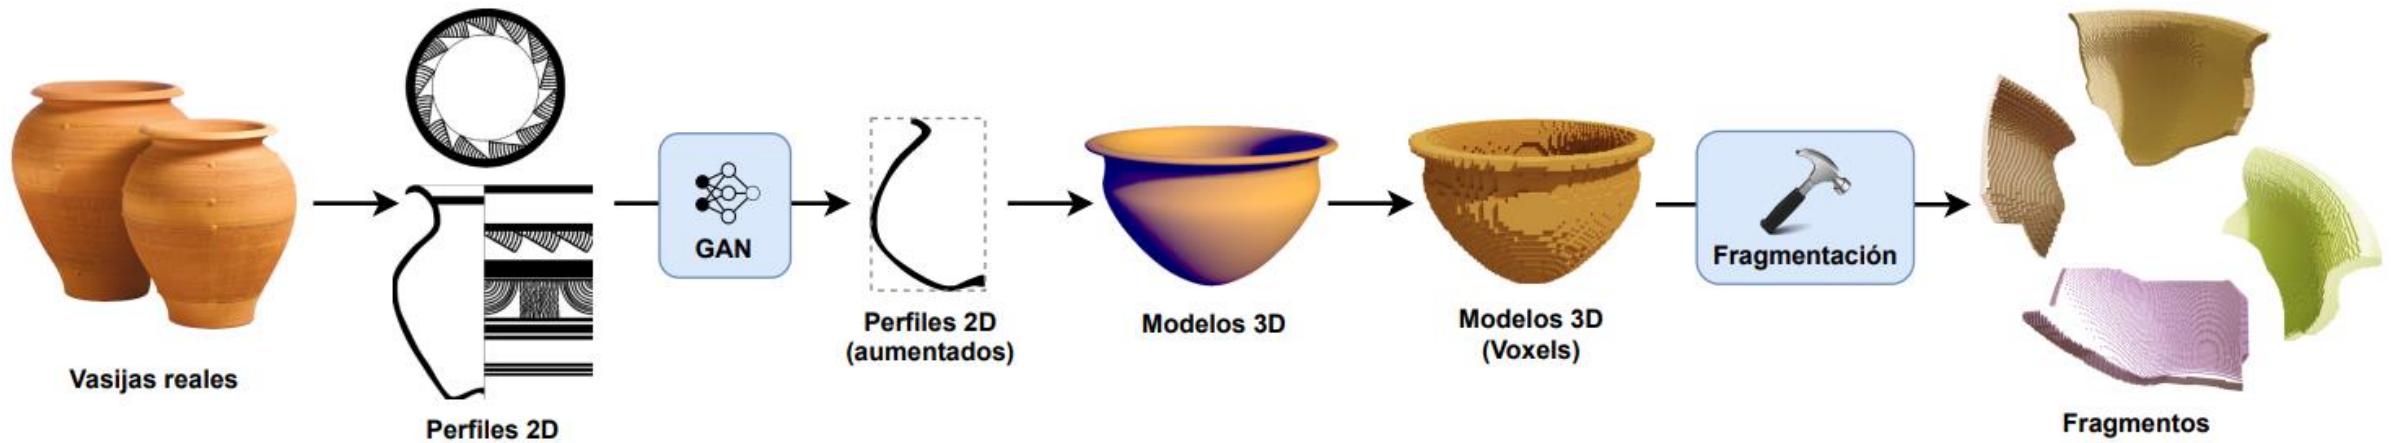


- Problema de clasificación 3D: escasez de datos de entrenamiento.
- Amplio trabajo previo en fragmentación de sólidos:
 - Más centrados en dónde y cómo se generan las fracturas.
 - Alto coste computacional.
 - Corrección desde el punto de vista físico.
- Simulación realista eliminando fundamento físico:
 - Aspecto realista.
 - Menor coste computacional.
 - Ejemplo: descomposiciones de Voronoi.



Metodología

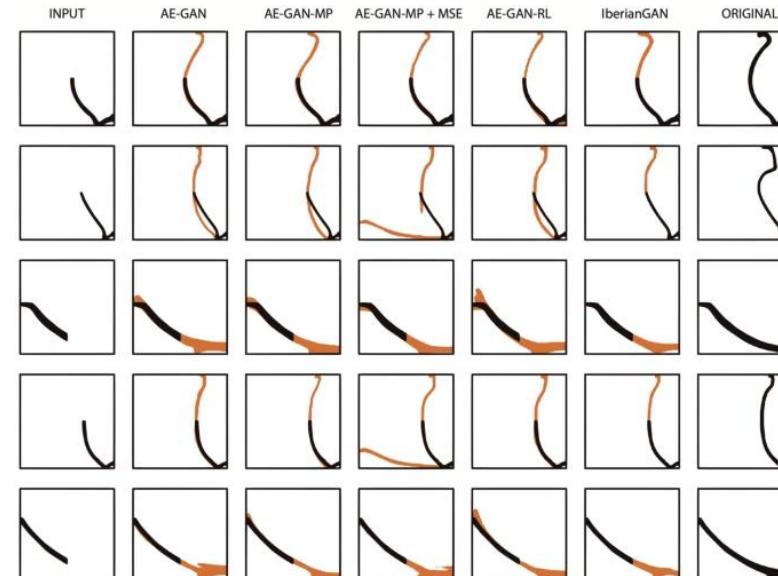
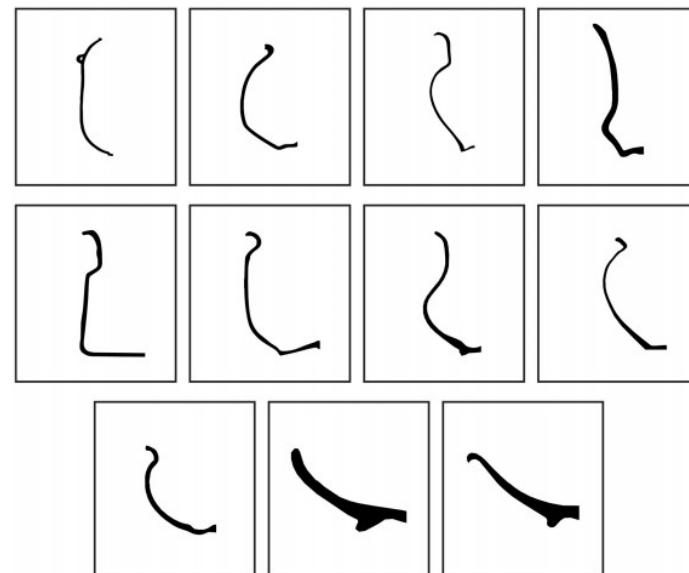
10



1

Integración de colección de perfiles 2D de cerámica ibérica.

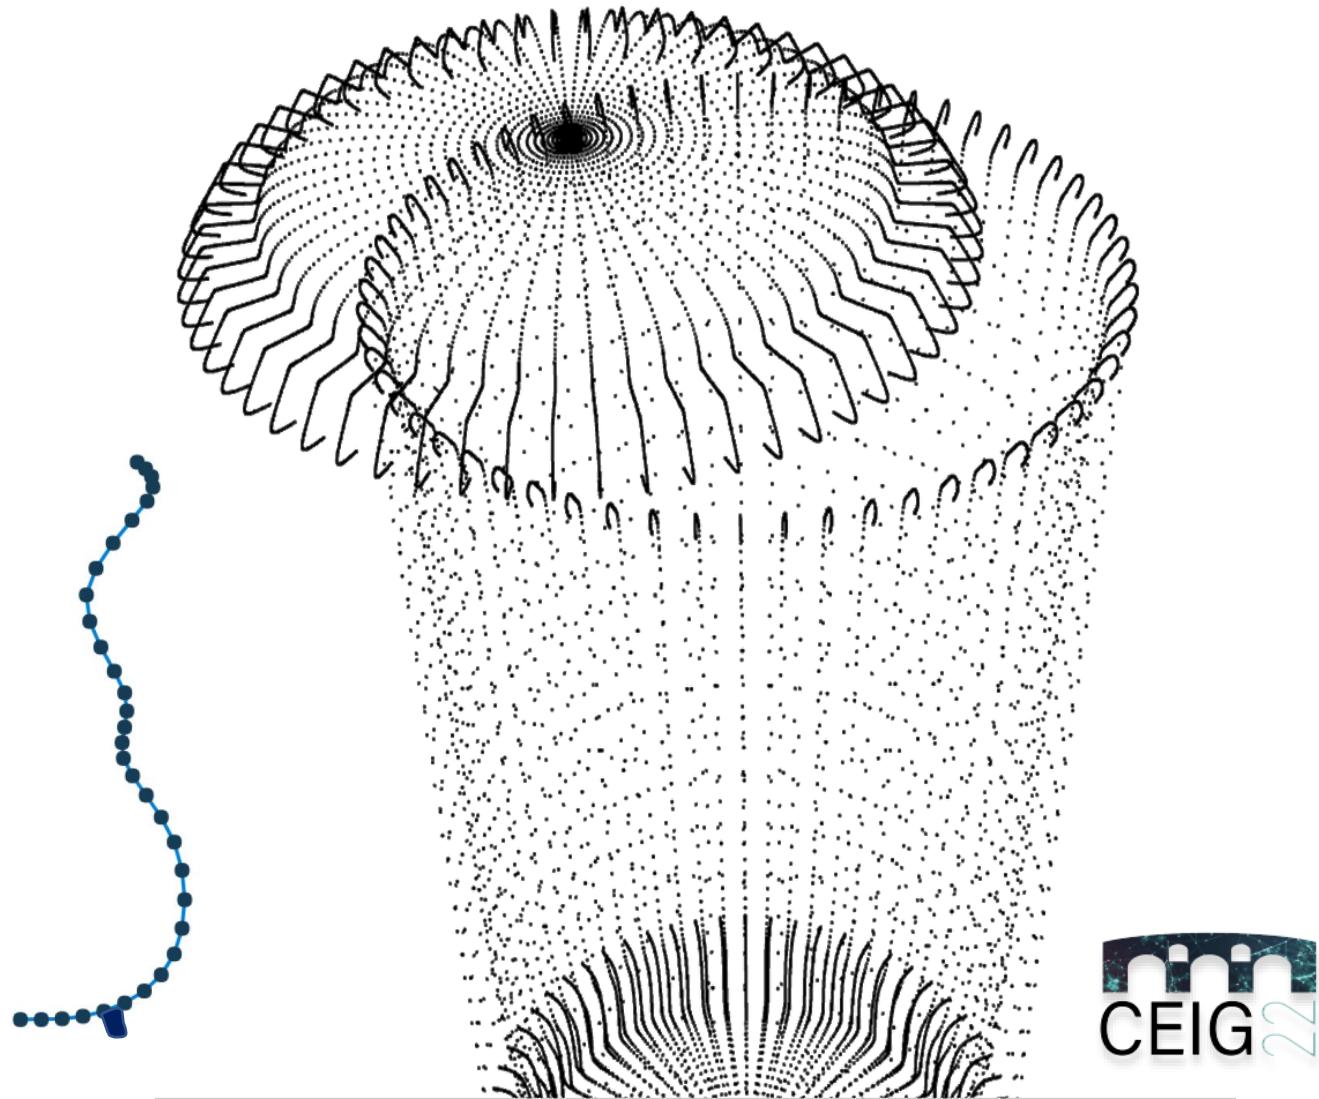
- Clasificados por expertos.
- Vectorización de perfiles.
- Perfiles generadas por redes generativas adversarias a partir de los perfiles previos.



2

Generación de modelos 3D.

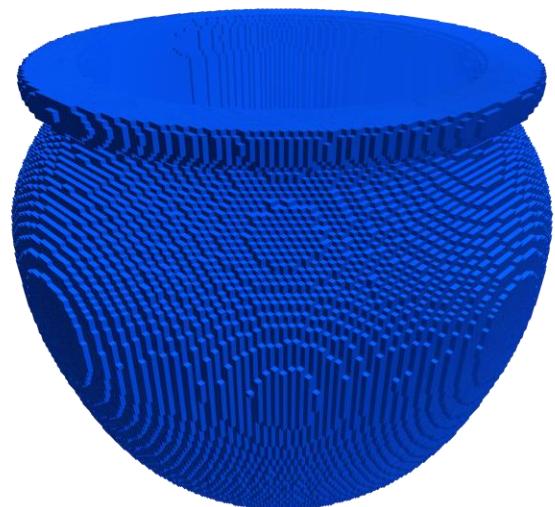
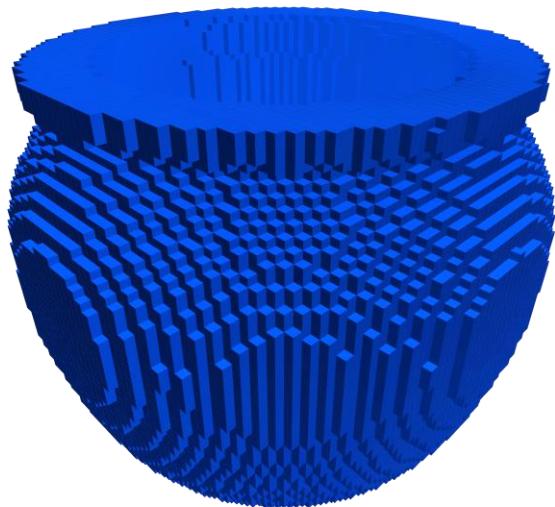
- Perfil de revolución para el núcleo de la vasija.
- Introducción de otros componentes a posteriori.
 - Asas, patas, etc.
- Creación de un lenguaje visual para inserción de estos elementos.



3

Voxelización de modelos volumétricos.

- Diferentes resoluciones: x64, x128, x256...



4

Fragmentación de voxelización en n piezas.

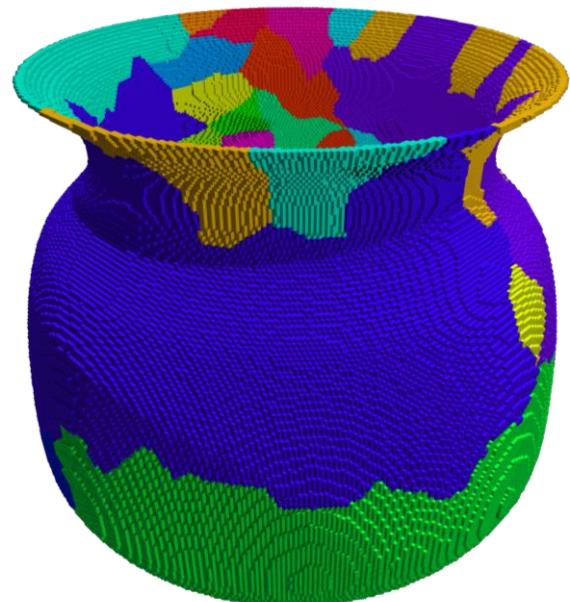
- Dispersión de n semillas en vóxeles.
 - Centro de regiones Voronoi.
- Inundación para determinar regiones.
- Voronoi imperfecto:
 - Un vóxel pertenece a una región si la inundación ha alcanzado dicho vóxel en menor tiempo.
 - En lugar de asignar región a vóxel por distancia a su centro.
 - Fragmentos cóncavos y convexos.
- Pueden someterse fragmentos a erosión.



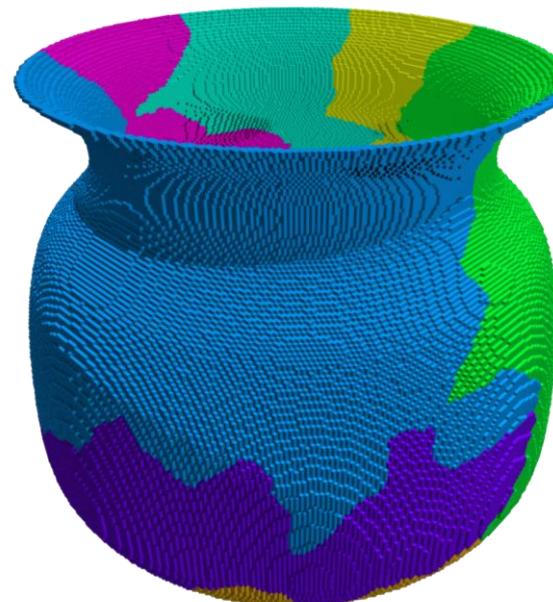
4

Fragmentación de voxelización en n piezas

- Dispersión de n semillas en vóxeles.
 - Diferentes funciones de distribución.



Pseudo-random

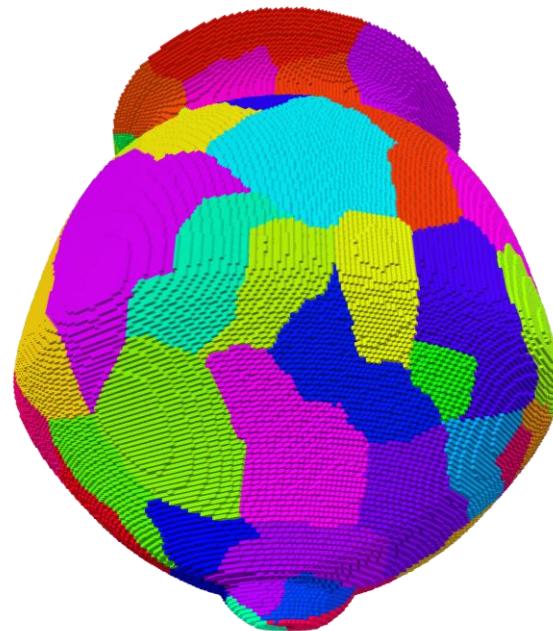


Halton

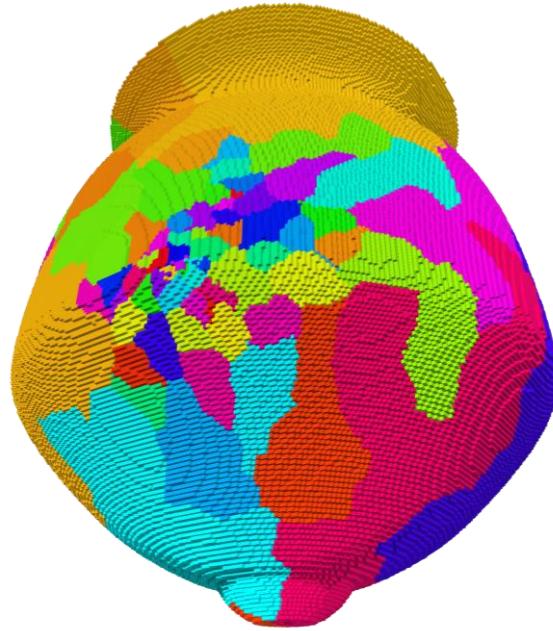
4

Fragmentación de voxelización en n piezas

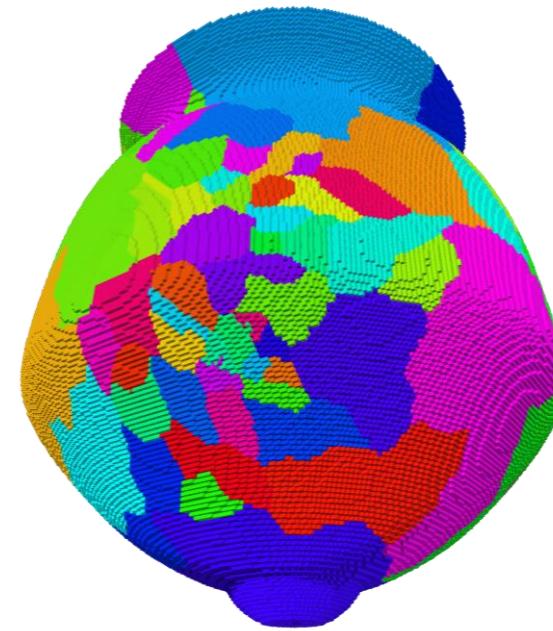
- Dispersión de n semillas en vóxeles.
 - Biased fractures.



n non-biased seeds



1 biased seed, ↓ spreading

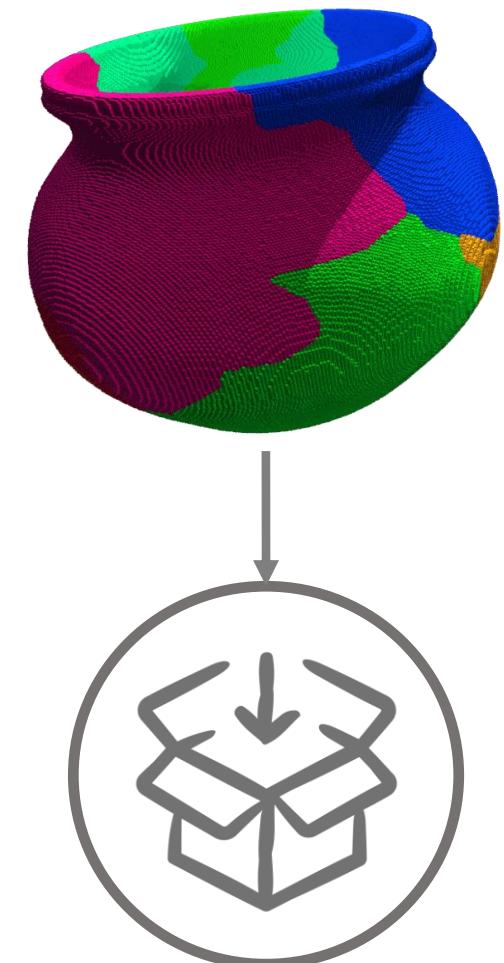


1 biased seed, ↑ spreading

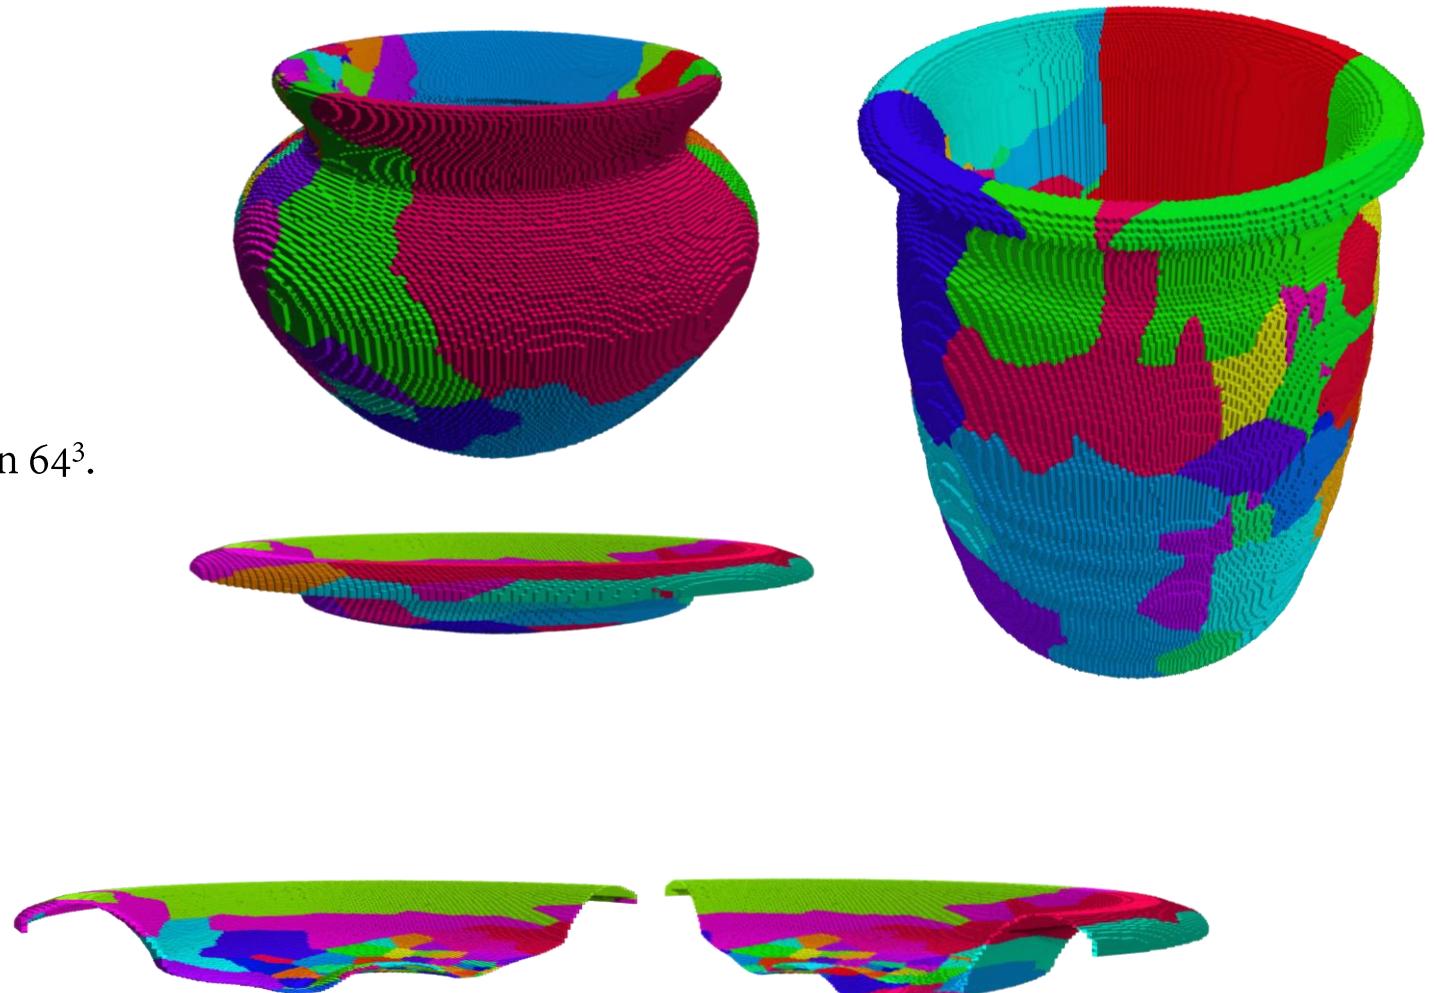
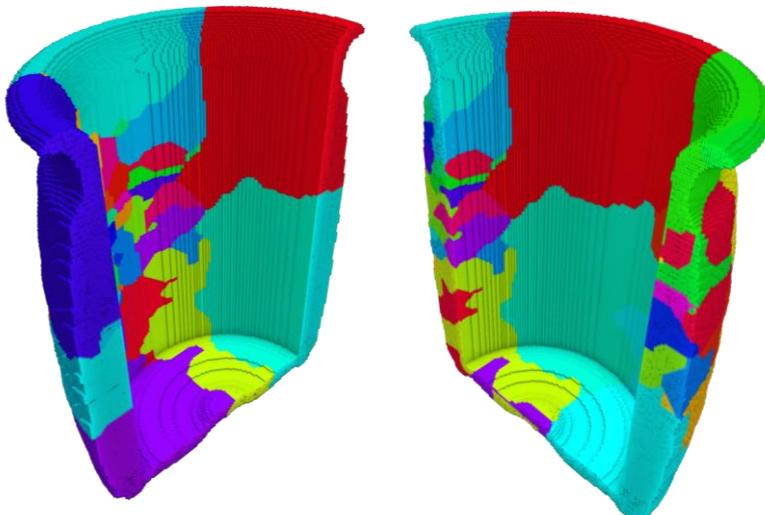
5

Almacenamiento de fragmentos generados

- **Modelo original almacenado con formato .vox.**
 - Utilizando un valor de voxel diferente para cada fragmento generado.
- **Fichero .csv con el número de voxels de cada uno de los fragmentos generados.**
- **Preclasificación de los fragmentos en dos categorías básicas:**
 - Fragmentos de borde superior.
 - Fragmentos de base.
 - Fragmentos de galbo.
 - Pueden pertenecer a varias categorías.

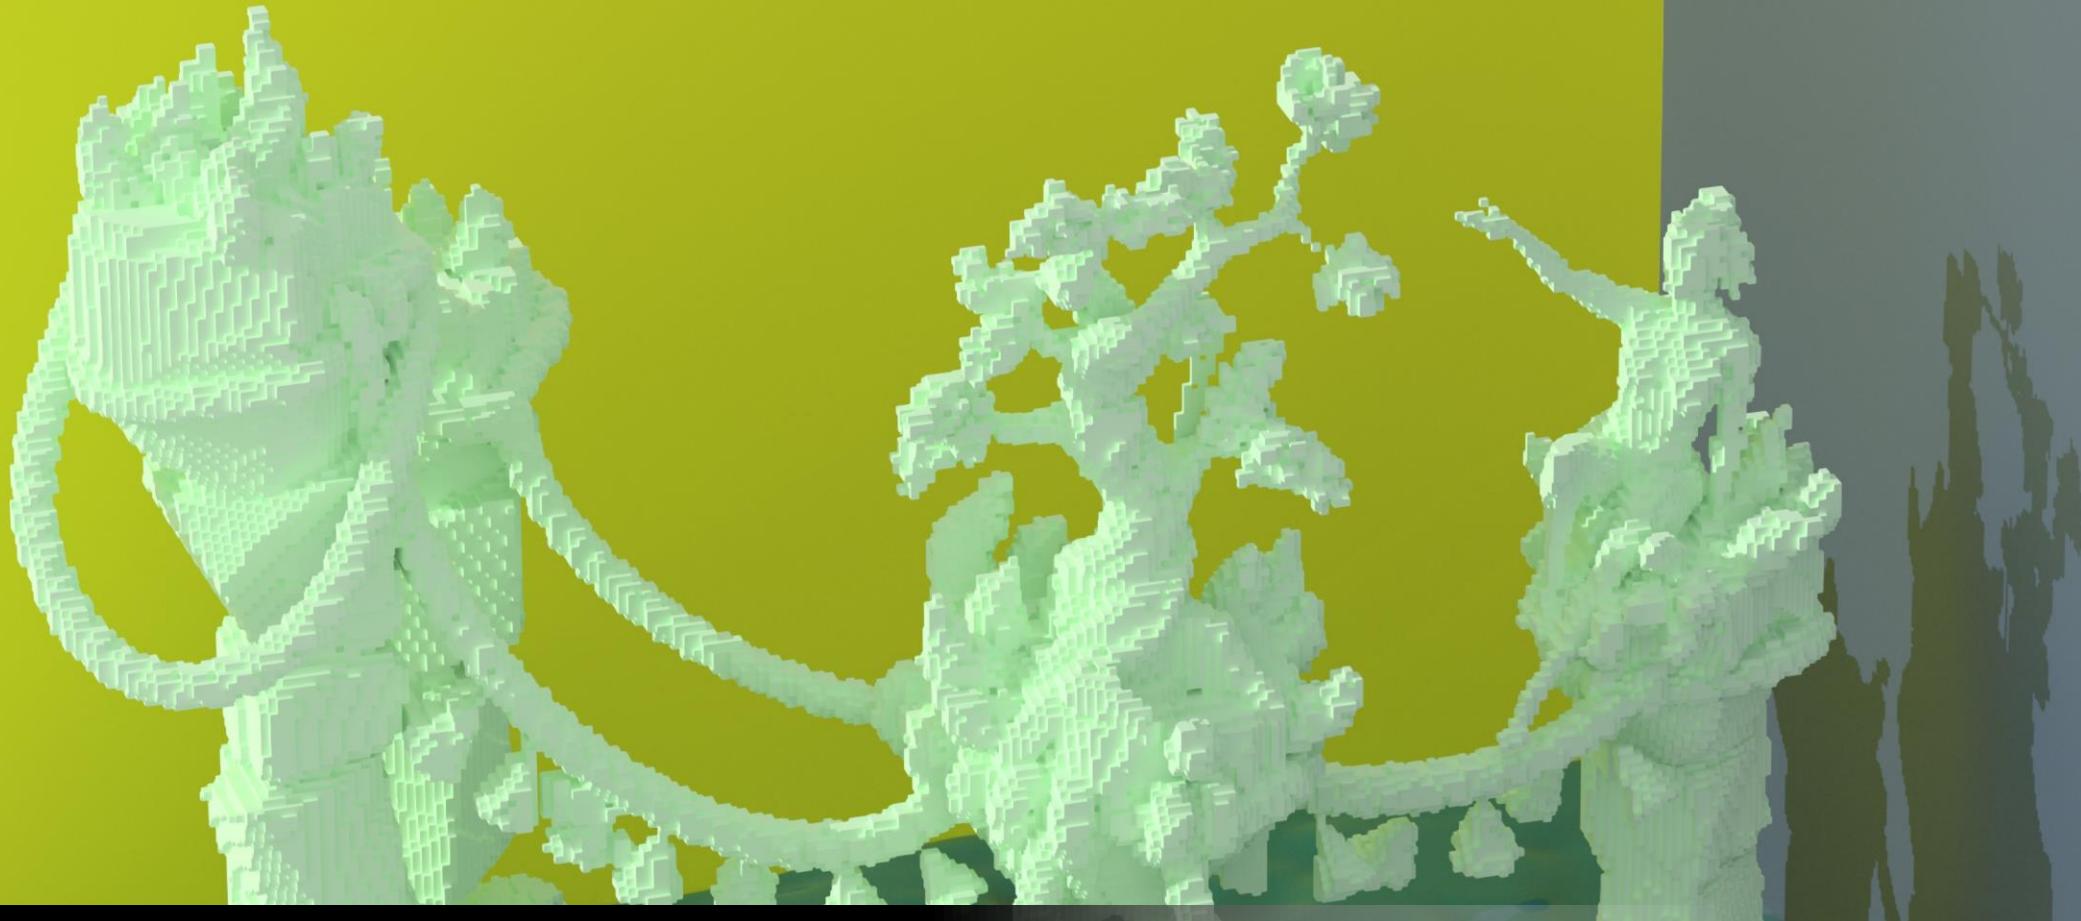


- 1,052 modelos disponibles.
- De 3 a 19 semillas.
- **Total: 196,724 fragmentos.**
 - Resoluciones de x64, x128 y x256.
 - 1,28 GB para fragmentos con resolución 64^3 .
 - 109 GB para los generados a 256^3 .



- El presente trabajo muestra un pipeline para la generación automática de fragmentos 3D para el entrenamiento de redes convolucionales.
- Clasificación de fragmentos de cerámica atendiendo a pertenencia al borde o pie de la vasija.
- En los resultados preliminares se obtienen resultados parecidos a los que se obtienen mediante el uso de imágenes.
- Implementación del método en GPU para construir modelos de entrenamiento en el aire.
 - 128^3 : 5s \rightarrow 0.2ms -96%
 - 256^3 : 44s \rightarrow 1.7s -96%
 - 512^3 : 314s \rightarrow 15s -95%





Gracias por vuestra atención



Grupo de Gráficos y
Geomática de Jaén



Universidad
de Jaén