

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

Rafael J. Segura^{1,2}  Antonio J. Rueda^{1,2}  Carlos J. Ogáyar²  José M. Fuertes^{1,2}  Ángel L. García-Fernández^{1,2}  Manuel J. Lucena^{1,2}  Alfonso López²  Isabel Moreno¹  Manuel Molinos¹ 

¹Instituto Universitario de Arqueología Ibérica, Universidad de Jaén, Spain

²Centro de Estudios Avanzados en TIC, Universidad de Jaén, Spain

Abstract

En los últimos años las técnicas de aprendizaje profundo se han convertido en una poderosa alternativa a técnicas clásicas de aprendizaje automático orientadas a tareas de clasificación. Esta tecnología se ha aplicado con gran éxito en diversos campos, si bien es necesaria la existencia de un conjunto de datos etiquetados muy grande para afrontar el entrenamiento de las mismas. En este trabajo se presenta un framework para la generación automática de fragmentos de vasijas de cerámica de torno, convenientemente etiquetados, de manera que permitan el entrenamiento de CNNs para la clasificación de dichos fragmentos, y su posterior utilización en tareas de reconstrucción.

CCS Concepts

• **Applied computing** → *Arts and humanities*; • **Theory of computation** → *Unsupervised learning and clustering*; *Computational geometry*;

1. Introducción.

La arqueología moderna ha convertido en habitual el manejo de modelos digitales reconociendo su valor en procesos como la catalogación, la conservación virtual, la reconstrucción y la investigación. Los estudios cerámicos, que desde el siglo XVI se limitaban al estudio de recipientes completos y sus decoraciones, han incorporado como objeto de interés los propios fragmentos, utilizando sistemas de clasificación para identificar las piezas de las que proceden que por ahora son principalmente manuales. En la mayor parte de las ocasiones los recipientes cerámicos aparecen muy fragmentados y habitualmente se conserva sólo una fracción mínima. En este trabajo se plantea una primera etapa de un novedoso sistema de identificación automática de cerámicas de torno a partir de fragmentos mediante aprendizaje profundo. El objetivo último del sistema es el de proporcionar datos relevantes sobre la pertenencia de un fragmento cerámico a un recipiente o categoría de recipientes. Esta aplicación del aprendizaje profundo a la arqueología abre nuevos caminos con posibilidades de alto valor científico, extensibles a otros períodos históricos además del íbero.

El reto principal del proyecto Kalathos+ consiste en diseñar un sistema basado en aprendizaje profundo que trabaje tanto con modelos 3D de vasijas completas como con sus versiones fragmentadas, para conseguir la determinación de pertenencia de un fragmento a una cerámica o categoría en particular. Ya que este proceso de aprendizaje automático necesita de un complejo entrenamiento, será necesaria la generación de modelos 3D de vasijas sintéticas con variaciones realistas a partir de los perfiles 2D de recipientes

cerámicos registrados, ya que aunque las piezas cerámicas a tratar en este proyecto pertenecen al mismo periodo, el volumen del material catalogado y su dispersión geográfica en múltiples fondos públicos hace inviable la creación de una base de datos de modelos 3D a partir de los materiales originales digitalizados. Además, se presenta el problema adicional de no disponer de registros de fragmentos suficientes con los que realizar el entrenamiento del sistema. A tal fin, se ha diseñado un sistema de fragmentación virtual realista a partir de los modelos 3D generados.

2. Antecedentes y objetivos.

La historia de los estudios cerámicos en arqueología transcurre en varias fases [OTV97]. En los orígenes de la arqueología la atención se centraba fundamentalmente en los recipientes completos y especialmente en las decoraciones. Posteriormente se fijaron los primeros sistemas de clasificación, y se incorporaron al interés científico no sólo las formas completas sino también los fragmentos con información muy relevante. Hasta los años sesenta del pasado siglo la selección y clasificación de los fragmentos que podían aportar información [OTV97] [MCA14], de aquellos otros calificados como ‘irrelevantes’, constituyó la práctica habitual, con la pérdida de información que ello significaba. A partir de las últimas décadas del siglo XX, la irrupción de los sistemas informáticos para la captura y registro cambió el panorama, muy especialmente a partir del desarrollo de las corrientes procesualistas y el uso de la informática para el análisis cuantitativo de las grandes masas de información que genera la investigación arqueológica [PH12].




Figure 1: Descripción del perfil de revolución.

Desde la aparición del torno de alfarero la cerámica puede verse como una geometría de revolución (Figura 1). Su identificación es un problema básico de la investigación en el ámbito de la arqueología: para el arqueólogo, un recipiente cerámico es un artefacto con una combinación de atributos característicos reconocibles, medibles y cuantificables. Pero una de las características del material cerámico, aparte de su plasticidad, dureza, diversidad funcionalidad y capacidad para el almacenaje de multitud de productos diferentes (sólidos o líquidos), es su tremenda fragilidad. En los contextos arqueológicos, encontrar recipientes completos es un hecho excepcional salvo que se trate de contextos cerrados. En la mayor parte de las ocasiones los recipientes cerámicos aparecen muy fragmentados y en ocasiones se conserva sólo una fracción mínima de esa geometría alterada por los procesos erosivos de arrastres en el paso del tiempo. La información conservada es normalmente fragmentaria y desigual, lo que ha provocado que desde hace ya bastantes años [Ald87, OTV97, FM85, Lor91] se abrieran líneas de investigación que pretenden abordar el estudio integral de la información parcial que contienen los fragmentos cerámicos. Los avances en este sentido se han desarrollado en una doble dirección: en la construcción de tipologías morfométricas, analíticas y contextuales, y en el análisis de los contenidos de los recipientes. En esta dirección uno de los análisis más elaborados fue llevado a cabo desde el Instituto Universitario de Investigación en Arqueología Ibérica de la Universidad de Jaén a través del proyecto CATA [CAT14]. En dicho proyecto se intentó sistematizar y catalogar la colección de cerámica íbera de la Alta Andalucía, permitiendo obtener un mecanismo para visualizar los objetos y comparar las distintas colecciones documentadas [MCA14]. Como resultado del mismo se identificaron un total de 1,052 tipos de vasijas que constituyen el conjunto de datos de partida de nuestro proyecto.

Como se ha mencionado, la cerámica aparece habitualmente en forma de fragmento. Por ello, para los procesos de reconstrucción los arqueólogos normalmente ‘pegan los fragmentos evidentes’ (bordes, bases y galbos) y elementos que ‘casen’ con éstos, para recuperar formas completas o parcialmente reconocibles. Pero no solo para definir tipologías formales o para facilitar la difusión de las evidencias, sino porque los propios fragmentos integran informaciones que explican su proceso histórico particular, incluidas las que se derivan de la propia forma de rotura de los recipientes de los que formaron parte (tipologías espaciales y contextuales).

En los últimos años, el abaratamiento de las aplicaciones de HPC (High Performance Computing) ha permitido que las técnicas de aprendizaje profundo tengan un impulso muy grande, siendo aplicadas con éxito en bastantes disciplinas, mostrándose especialmente útiles en el caso del tratamiento y clasificación de imágenes. En nuestra propuesta de trabajo se pretende aplicar Redes Neuronales Convolucionales (CNNs) y Redes Generativas Adversarias (GANs) tanto sobre un conjunto de modelos 3D de vasijas completas como sobre sus versiones fragmentadas. De esta forma dispondremos de herramientas para la determinación de pertenencia de un fragmento a una vasija en particular y la generación de nuevas vasijas sintéticas con variaciones reales basándonos en el conjunto de vasijas generadas a partir de perfiles 2D existentes. En proyectos parecidos como ArchAIDE [BDC*17, Gat18] los trabajos se han planteado desde el campo de la imagen. Así, el proceso parte de una (o varias) fotografías del fragmento que son clasificadas por una red profunda, entrenada previamente mediante imágenes parciales de los modelos 3D existentes, generadas desde diversos puntos de vista. Para las fracturas de los modelos se usa el módulo cell-fracture de Blender. Este enfoque, aunque simple, continua evitando abordar el problema desde el 3D, perdiendo por tanto la riqueza que la geometría aporta al conocimiento del fragmento.

El uso de CNNs con modelos 3D sólo se ha abordado recientemente, debido a su mayor complejidad. Los enfoques utilizados pueden clasificarse atendiendo a la representación utilizada: múltiples vistas, mapas de profundidad, representación mediante descomposiciones de volumen, ya sean estáticas (vóxeles) o adaptativas (octrees), y nubes de puntos. Los dos primeros enfoques realmente transforman un modelo 3D en un conjunto de imágenes 2D (de color o profundidad) que pueden tratarse con CNNs, utilizando para ello una cámara virtual que realiza varias tomas del objeto desde distintas posiciones [SMKLM15, QSN*16]. Relacionada con este enfoque una reciente y prometedora línea de trabajo busca utilizar también en última instancia CNNs para la clasificación, pero para ello establece un mapeado completo de la superficie 3D en una superficie plana regular donde la operación de convolución está bien definida en cualquier punto [MGA*17]. El tercer enfoque puede considerarse una extensión de un enfoque convencional basado en el uso de CNNs pero usando en este caso kernels convolucionales 3D [QSN*16]. El cuarto enfoque puede considerarse el más interesante a priori, pero presenta dos importantes problemas: primero, en una nube de puntos no existe una estructura y por tanto no pueden aplicarse filtros convolucionales que sirvan de entrada a una CNN; y segundo, un mismo objeto puede ser representado por infinitas nubes de puntos diferentes (distinto número de puntos en diferentes posiciones). Para solucionar este problema se alimenta la red no con la nube original sino con una representación invariante al número y posición de los puntos, obtenida aplicando a la nube una función simétrica [QSMG17, QYSG17], u ordenando los puntos de la nube utilizando un Kd-tree y utilizando su estructura para definir la de la propia red [KL17]. La aparición de PointNet y Pointnet++ han permitido la utilización directa de las nubes de puntos como elementos de entrada de la clasificación.

Independientemente de la solución adoptada, uno de los problemas con los que debemos enfrentarnos en este proyecto es la no disponibilidad de fragmentos suficientes con los que realizar el entrenamiento de las redes propuestas. A tal fin, se hace nece-




Figure 2: Esquema general de secuencia de pasos: del perfil al fragmento.

saría la generación de fracturas virtuales realistas a partir de modelos sintéticos de piezas cerámicas, lo cual como paso previo al entrenamiento de la red neuronal es un aspecto fundamental de nuestro plan de trabajo. Existe una extensa literatura que ha abordado el problema de la rotura realista de objetos de materiales frágiles (cerámica, cristal, etc.). Los trabajos que abordan este problema utilizando métodos de la ciencia de materiales y la mecánica de medios continuos proporcionan soluciones de gran exactitud [FM95, CRDHvdG96], aunque el hecho de que el interés en estos campos se centre más en dónde y cómo aparece una fractura en un material que en la forma concreta de esta fractura, junto a su elevado coste computacional, los hace impracticables para muchas aplicaciones. Otras soluciones se centran no tanto en el aspecto y realismo de la fractura, sino más bien en la forma en que los fragmentos generados por la rotura se dispersan por el espacio circundante. Este tipo de funciones se basan en el planteamiento de sistemas dinámicos complejos que estudian los modelos de dispersión de los fragmentos, centrándose principalmente en que el aspecto visual de dicha dispersión sea efectiva. Entre ambos tipos de soluciones, han surgido otras que sacrifican en parte la corrección desde el punto de vista físico tanto de la rotura como de la dispersión por un menor consumo de recursos computacionales manteniendo un alto nivel de realismo. Finalmente, existen métodos que renunciando a un fundamento físico buscan un aspecto realista simulando la estructura de las fracturas reales mediante técnicas procedurales o descomposiciones de Voronoi [MCK13]. Las ventajas de estos últimos son su simplicidad, velocidad (cercana a tiempo real) y el grado de control que proporcionan sobre la estructura y complejidad de la fractura.

3. Metodología.

A la vista de los trabajos previos presentados, se optó por un enfoque inicial en el que se tuvieron en cuenta estrictamente características geométricas de las vasijas y de los fragmentos. Para una ampliación del proyecto se postergó el uso de información adicional como los materiales usados, apariencia, textura, etc. Con estas restricciones, la metodología de trabajo consistió en la resolución de las siguientes etapas (Figura 2):

1. Integración de una colección única de perfiles 2D de cerámica fibra del alto Guadalquivir. Digitalización de los perfiles, y ampliación del número de los perfiles 2D contemplados mediante el uso de GANs [CLF*20].
2. Generación de modelos 3D a partir de los perfiles 2D.

3. Conversión de modelos 3D poligonales a modelos volumétricos de diferente resolución (x64, x128, x256, x512).
4. Utilización de un módulo de fractura de modelos 3D para romper cada modelo en n fragmentos. Dicho módulo de fractura se aplicará sobre todos los modelos voxelizados, en todas las resoluciones.
5. Almacenamiento de los fragmentos generados.

Para la primera etapa, se contó con la información disponible en CATA. El principal problema es que las digitalizaciones existentes estaban realizadas en formato ráster a baja resolución, lo que a priori iba a afectar de manera importante la calidad de los modelos de revolución. Para resolver este problema se realizó un proceso de vectorización de los perfiles para mejorar la resolución de perfil. Como elemento complementario de este paso, y con el fin de aumentar en la medida de lo posible el número de elementos del conjunto de entrenamiento, se utilizó una GAN para generar nuevos perfiles de cerámica [CLF*20].

Una vez definidos los perfiles 2D, el siguiente paso consiste en la generación del modelo poligonal mediante rotación del perfil. Para ello, se realiza un muestreo sobre el perfil curvo a incrementos constantes sobre la curva y se realiza una rotación de los puntos un ángulo α , interconectando los puntos generados. Una mención especial merece el elemento de asa. La mayor parte de los perfiles de cerámica estaban constituidos por una curva cerrada (que delimita el interior y el exterior de la vasija). Sin embargo, muchos objetos cerámicos cuentan con elementos adicionales en su estructura, ya sea con fines ornamentales o funcionales. Aparecen así asas o patas que constituyen una segunda (o tercera) curva en el perfil. Estas curvas adicionales no deben considerarse a la hora de realizar la rotación del perfil principal, pero sí deben colocarse (en un número conocido) a lo largo del modelo. Para ello, en el modelo del perfil se incorporan como atributos adicionales los perfiles de las asas y/o patas, así como el número de ocurrencias que deben colocarse de las mismas una vez se realice la rotación.

Obtenidos los modelos poligonales 3D, la siguiente etapa es la preparación del modelo para su rotura. En nuestra primera aproximación se optó por seguir un enfoque de representación estática del volumen (mediante vóxeles) ya que estas representaciones proporcionan una representación uniforme de los modelos, pudiendo utilizarse kernels convolucionales 3D. Para la generación del modelo de vóxeles se optó por utilizar el framework propuesto en [OARRSS*20]. Con los modelos voxelizados, la siguiente etapa consistió en generar los fragmentos. Para la generación de las ro-

turas se utilizó un método basado en la generación de regiones de Voronoi. El método básico consiste en repartir por la superficie del modelo un conjunto de puntos (semillas) de manera que cada punto constituya el centro de una región de Voronoi sobre la superficie del modelo. Mediante un algoritmo de inundación, en cada iteración la semilla va agregando a su región de voronoi vóxeles del modelo que aún no hayan sido agregados a ninguna región. Este algoritmo sencillo presenta el inconveniente de que todas las regiones obtenidas son convexas, lo que impide obtener fracturas cóncavas. Para ello, se modificó el algoritmo, construyendo lo que denominamos un "Voronoi imperfecto"; de esta forma un vóxel es asignado a la región de Voronoi que lo alcanza en primer lugar, en lugar de utilizar como criterio el que un vóxel se asigne a la región de Voronoi a cuyo centro se encuentre más cerca. Con esta sencilla modificación, se obtienen fragmentos cóncavos y convexas.

Tras la rotura del modelo 3D, los fragmentos son orientados de forma que el mayor número de vóxeles quede encuadrado en el primer cuadrante. Opcionalmente el fragmento puede someterse a un proceso de erosión utilizando para ello diferentes máscaras que permitan simular los procesos erosivos de arrastres debido al paso del tiempo. Además de ello, el modelo original es almacenado utilizando el formato .vox, utilizando un valor de vóxel diferente para cada fragmento generado. También se genera un fichero .csv en el que para cada slice del modelo volumétrico se almacenan el número de vóxeles de cada una de los fragmentos generados que aparecen en esa loncha. Así es posible tener una preclasificación de los fragmentos en dos categorías básicas: fragmentos de borde superior y fragmentos de base; aquellos fragmentos que no caen en una de las dos categorías previas pueden considerarse como fragmentos de galbo. Es obvio que puede haber fragmentos que aparezcan en más de una categoría (de borde superior y de base), algo relativamente frecuente en modelos de vasijas de plato o modelos "estrechos".

Todo el proceso de rotura fue programado en Python y se aplicó sobre los 1,052 modelos disponibles en CATA, generando roturas desde 3 hasta 19 fragmentos. En total se generaron 196,724 fragmentos, a resoluciones de x64, x128 y x256. El tamaño total de los modelos generados es de 1,28 GB para los fragmentos con resolución 64³ y de 109 GB para los generados a 256³. Posteriormente se amplió el conjunto con la rotura de los modelos generados mediante perfiles obtenidos por GANs.

4. Conclusiones y trabajos futuros.

El presente trabajo muestra un pipeline para la generación automática de fragmentos 3D para el entrenamiento de redes convolucionales que clasifiquen un fragmento de cerámica atendiendo a su pertenencia al borde o pie de la vasija de pertenencia. Actualmente se está ultimando el entrenamiento de la red, si bien en los resultados preliminares se obtienen resultados parecidos a los que se obtienen mediante el uso de imágenes.

Este trabajo ha sido financiado por la Universidad de Jaén (mediante FEDER) a través del proyecto de investigación 1381115/2022.

References

- [Ald87] ALDENDERFER M.: *Quantitative Research in Archaeology: Progress and Prospects*. 1987, ch. On the structure of archaeological data. 2
- [BDC*17] BANTERLE F., DELLEPIANE M., CALLIERI M., SCOPIGNO R., ITKIN B., WOLF L., DERSHOWITZ N.: Vasesketch: Automatic 3d representation of pottery from paper catalogue drawings. In *14th IAPR ICDAR* (2017). 2
- [CAT14] Cata (corpus virtual de cerámica arqueológica a torno de andalucía-hum-890. URL: <http://cata.cica.es>. 2
- [CLF*20] CINTAS C., LUCENA M., FUERTES J. M., DELRIEUX C., NAVARRO P., GONZÁLEZ-JOSÉ R., MOLINOS M.: Automatic feature extraction and classification of iberian ceramics based on deep convolutional networks. *Journal of Cultural Heritage* 41 (2020), 106–112. 3
- [CRDHvdG96] CHUNG J. W., ROOS A., DE HOSSON J. T. M., VAN DER GIESSEN E.: Fracture of disordered three-dimensional spring networks: A computer simulation methodology. *Phys. Rev. B* 54 (Dec 1996), 15094–15100. 3
- [FM85] FERNANDEZ MARTINEZ VICTOR M.: La seriación automática en arqueología: Introducción histórica y aplicaciones. *Trabajos de Prehistoria* 42 (1985), 9. 2
- [FM95] FRÉDÉRIC D., MAGNIER S.-A.: Formulation of a 3-D numerical model of brittle behaviour. *Geophysical Journal International* 122, 3 (12 1995), 790–802. 3
- [Gat18] GATTIGLIA G.: *Archeologia, Quo vadis? Riessioni metodologiche sul futuro di una disciplina*. 2018, ch. Classificare le ceramiche: dai metodi tradizionali all'intelligenza artificiale. L'esperienza del progetto ARCHAIDE. 2
- [KL17] KLOKOV R., LEMPITSKY V.: Escape from cells: Deep kd-networks for the recognition of 3d point cloud models. In *Proceedings of the IEEE ICCV* (2017), pp. 863–872. 2
- [Lor91] LORRIO A.: Clasificación automática de formas cerámicas completas: un estudio comparativo de diversos métodos multivariante. *Complutum, ISSN 1131-6993, N° 1, 1991, pags. 99-112* (01 1991). 2
- [MCA14] MARTÍNEZ-CARRILLO A., A. R.-R.: *Nuevas tecnologías aplicadas al análisis de la cerámica ibérica a torno del Alto Guadalquivir (S. VI a.n.e-S. I d.n.e)*. Doctoral dissertation, 2014. 1, 2
- [MCK13] MÜLLER M., CHENTANEZ N., KIM T.-Y.: Real time dynamic fracture with volumetric approximate convex decompositions. *ACM Transactions on Graphics (TOG)* 32, 4 (2013), 1–10. 3
- [MGA*17] MARON H., GALUN M., AIGERMAN N., TROPE M., DYM N., YUMER E., KIM V. G., LIPMAN Y.: Convolutional neural networks on surfaces via seamless toric covers. *ACM Trans. Graph.* 36, 4 (2017), 71–1. 2
- [OARRS*20] OGAYAR-ANGUITA C. J., RUEDA-RUIZ A. J., SEGURA-SÁNCHEZ R. J., DÍAZ-MEDINA M., GARCÍA-FERNÁNDEZ L.: A gpu-based framework for generating implicit datasets of voxelized polygonal models for the training of 3d convolutional neural networks. *IEEE Access* 8 (2020), 12675–12687. 3
- [OTV97] ORTON C., TYERS P., VINCE A.: *La cerámica en arqueología*. Crítica, 1997. 1, 2
- [PH12] PARIKH D., HALL K.: The two archaeologies: crossing the great divide. *ARCHAEOLOGICAL REVIEW FROM CAMBRIDGE* 1, 27 (2012), 1–8. 1
- [QSMG17] QI C. R., SU H., MO K., GUIBAS L. J.: Pointnet: Deep learning on point sets for 3d classification and segmentation. In *Proceedings of the IEEE CVPR* (2017), pp. 652–660. 2
- [QSN*16] QI C. R., SU H., NIESSNER M., DAI A., YAN M., GUIBAS L. J.: Volumetric and multi-view cnns for object classification on 3d data. In *Proceedings of the IEEE CVPR* (2016), pp. 5648–5656. 2
- [QYSG17] QI C. R., YI L., SU H., GUIBAS L. J.: Pointnet++: Deep hierarchical feature learning on point sets in a metric space. *Advances in neural information processing systems* 30 (2017). 2
- [SMKLM15] SU H., MAJI S., KALOGERAKIS E., LEARNED-MILLER E.: Multi-view convolutional neural networks for 3d shape recognition. In *Proceedings of the IEEE ICCV* (2015), pp. 945–953. 2