



Inteligencia artificial para restauración de material arqueológico



ALEXIS MENDOZA Estudiante de pregrado de la Escuela de Ciencia de la Computación, Universidad Nacional San Agustín, Perú.
ALEXANDER APAZA Estudiante de pregrado de la Escuela de Ciencia de la Computación, Universidad Nacional San Agustín, Perú.
IVÁN SIPIRÁN Profesor Asistente del Departamento de Ciencias de la Computación, Universidad de Chile.
CRISTIÁN LÓPEZ Profesor Asistente del Departamento de Ingeniería, Universidad de Ingeniería y Tecnología, Perú.

En 2018, el museo Josefina Ramos de Cox en Lima - Perú inició un proceso de digitalización de los objetos arqueológicos que albergan en su colección. El museo administra más de siete mil piezas provenientes de diferentes culturas prehispánicas, principalmente culturas de la costa central del Perú. Para el proceso de digitalización, el museo usó un escáner 3D de escritorio que utiliza tecnología de luz estructurada. Sin embargo, el proceso de digitalización no se desarrolló de forma satisfactoria por dos razones:

1. La mayoría de los objetos eran frágiles y, al no poder sostenerse sobre la base del escáner, se tuvo que colocar bases artificiales. Estas bases artificiales

fueron posteriormente removidas en las superficies 3D generadas, dejando grandes porciones de la base de los objetos sin información.

2. El escáner de luz estructurada tiene problemas para escanear superficies cuyo ángulo con respecto al haz de luz es casi perpendicular. Por lo tanto, hay bases de objetos que no fueron correctamente escaneadas por la limitación del escáner.

El problema en la digitalización trajo como consecuencia que un gran número de objetos tengan una superficie incompleta después del escaneo (ver Figura 1). Nosotros propusimos una forma de

solucionar el problema de la geometría faltante desde un enfoque basado en datos y usando inteligencia artificial.

Nuestra propuesta

Nuestro método consiste de una red neuronal que recibe un objeto 3D con superficie incompleta y produce el objeto completo reparado. Nuestra premisa es que si contamos con suficientes ejemplos de objetos dañados y objetos completos, la red neuronal puede encontrar una buena correspondencia entre la geometría de la superficie incompleta y



Figura 1. Vista frontal y superior de algunos objetos escaneados. Note la falta de geometría en la base de los objetos.

la superficie de los objetos completos. Además, si seguimos un protocolo de entrenamiento adecuado, podemos esperar que la red neuronal generalice bien a diferentes geometrías faltantes.

El problema es que la colección escaneada del museo Josefina Ramos de Cox no contiene muchos ejemplos de objetos completos, como para permitir hacer un entrenamiento adecuado de una red neuronal. En este punto, hicimos una observación clave para solu-

cionar el problema. Lo que requerimos de la red neuronal es que aprenda la estructura de objetos arqueológicos, por lo que cualquier otro conjunto de datos con estructura similar podría servir para nuestro cometido. Así, logramos recolectar un conjunto de 1458 objetos desde el 3D Pottery Benchmark [1] y las clases "Bowl" y "Jar" del dataset ShapeNet [2]. Todos estos objetos tienen estructura común a objetos arqueológicos y sirvieron para entrenar nuestra red neuronal.

Con respecto a la arquitectura de la red neuronal, típicamente el problema de "shape completion" se aborda desde una perspectiva de un modelo tipo *encoder-decoder*, en donde el encoder procesa la geometría de entrada y la transforma en un vector numérico. Posteriormente, el vector numérico es la entrada al decoder, que finalmente reconstruye la geometría completa [3, 4]. Sin embargo, un problema con este tipo de arquitectura es que generan una representación transformada de la geometría completa. En nuestro caso, la geometría de entrada no tiene que ser cambiada ni transformada, y más bien lo que necesitamos es generar una buena representación de la superficie que falta. Es así que nosotros presentamos una nueva arquitectura para este problema específico, en donde una primera red neuronal produce una región faltante candidata. La unión del objeto incompleto y la región candidata es posteriormente refinada con una segunda red neuronal, la cual produce el objeto completo. Ambas redes neuronales son entrenadas en conjunto y en forma *end-to-end*. Para la representación de los modelos 3D, escogimos las nubes de puntos [5]. La arquitectura puede verse en la Figura 2.

Para entrenar este modelo, usamos el conjunto de datos recolectado y

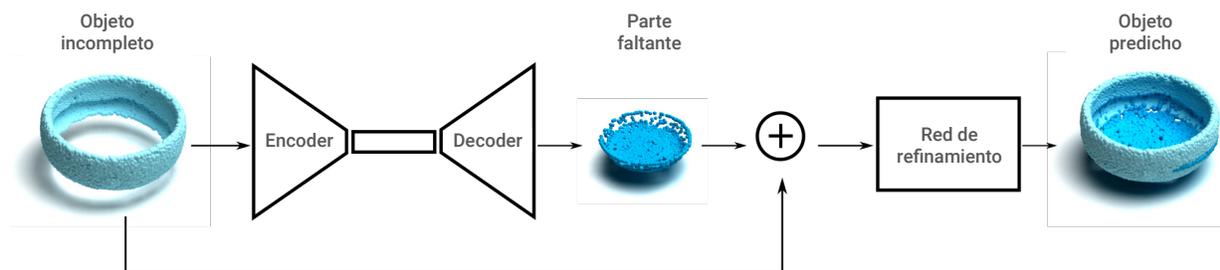


Figura 2. Arquitectura de nuestra red neuronal. El modelo consiste en un *encoder-decoder* para generar la parte faltante a partir del objeto incompleto. Ambos objetos son luego usados por la red de refinamiento para obtener el objeto reparado final.

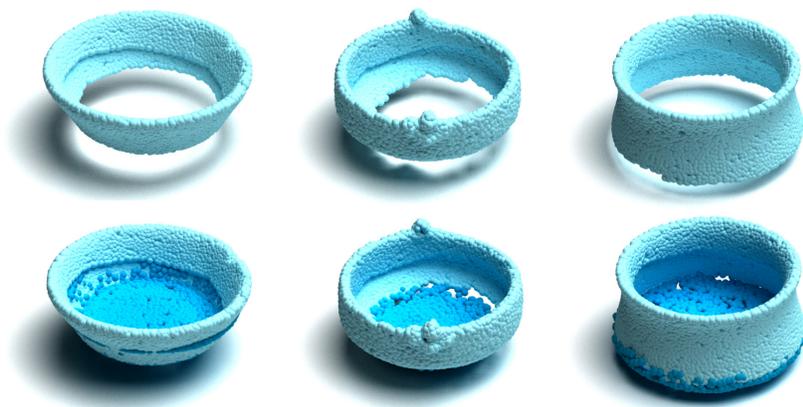


Figura 3. Ejemplos de objetos reparados con nuestra herramienta.

realizamos la generación de pares de entrenamiento (objeto incompleto, objeto completo) durante el mismo entrenamiento. Creamos un protocolo para generar pares aleatorios de objetos, aplicando un algoritmo que simula la eliminación de geometría en la base de un objeto de entrada. Este algorit-

mo nunca genera dos objetos iguales durante el entrenamiento, por lo que esto garantiza que la red no memorice los ejemplos de entrenamiento.

Una vez que la red fue entrenada, usamos el conjunto de objetos arqueológicos del museo como objetos de prueba.

Como la red procesa nubes de puntos, implementamos un algoritmo que reconstruye la superficie de los objetos 3D. La Figura 3 muestra algunos resultados de nuestro método.

Consideraciones finales

Abordamos un problema de restauración de piezas arqueológicas desde una perspectiva de datos. Este trabajo se pudo llevar a cabo gracias a los recientes avances en análisis de formas y procesamiento geométrico a través del uso de técnicas de aprendizaje automático. Nuestros resultados muestran que las redes neuronales que procesan geometría pueden extraer información de estructura de los objetos. Esta estructura puede ser empleada para el diseño asistido por computadora, y específicamente en nuestro caso fue útil para predecir la geometría faltante de objetos con defectos de escaneo. ■

REFERENCIAS

- [1] Koutsoudis A., Pavlidis G., Liami V., Tsiafakis D., Chamzas C., "3D Pottery content-based retrieval based on pose normalisation and segmentation". *Journal of Cultural Heritage*, 11(3), pp 329-338, 2010.
- [2] Chang A., Funkhouser T., Guibas L., Hanrahan P., Huang Q., Li Z., Savarese S., Savva M., Song S., Su H., Xiao J., Yi L., Yu F., "ShapeNet: An Information-Rich 3D Model Repository". CoRR abs/1512.03012. Arxiv, 2015.
- [3] Yuan W., Khot T., Held D., Mertz C., Hebert M., "PCN: Point Completion Network". In *Proc: International Conference on 3D Vision (3DV)*, pp. 728-737. 2018.
- [4] Tchapmi L., Kosaraju V., Rezatofighi H., Reid I., Savarese S., "TopNet: Structural Point Cloud Decoder". In *Proc: IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 383-392. 2019.
- [5] Qi R., Su H., Kaichun M., Guibas L., "PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation". In *Proc: IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 77-85. 2017.