

Caracterización de valores atípicos en nube de puntos en 3D para la reducción del tiempo de ejecución en memoria

Israel Sotelo Rodríguez¹, Jesús Carlos Pedraza Ortega¹, Luis Rogelio Román Rivera², Juan Manuel Ramos Arreguín¹, Efrén Gorrostieta Hurtado¹

¹ Universidad Autónoma de Querétaro Campus Aeropuerto,
Maestría en Ciencias en Inteligencia Artificial, Querétaro,
México

² Universidad Autónoma de Querétaro Cerro de las campanas,
Doctorado en Ingeniería, Querétaro,
México

{isotelol17, lronman26}@alumnos.uaq.mx, caryoko@yahoo.com,
jsistdig@yahoo.com.mx, efren.gorrostieta@gmail.com

Resumen. Para poder realizar la reconstrucción de objetos en 3D, puede recurrirse a un tipo de estructura geométrica llamada “Nube de puntos”. Una nube de puntos es un conjunto de coordenadas que representan la forma o superficie de un objeto. Uno de los principales problemas al hacer el mapeo 3D de escenas u objetos es la presencia de ruido y valores atípicos en una nube de puntos, producido por distintos factores como la luz solar o artificial, la reflexividad de los objetos, la geometría o limitantes relacionadas con el sensor [1]. La caracterización de los valores atípicos se realizó utilizando nubes de puntos con ruido blanco en distintas magnitudes, y nubes de puntos sin ruido, tomadas de la base de datos de Rakotosaona [2]. Se redujo el porcentaje de coordenadas de puntos, con intervalos de 10% en un rango de 10% a 90%. Se realizaron 144 inferencias utilizando el modelo de PointCleanNet [3] y el resultado se comparó con la etiqueta de los valores atípicos de cada una de las nubes, obteniendo una matriz de confusión para medir la precisión, valor F, y el error cuadrático medio. La matriz de confusión para cada nube mostró que al remover 20% o menos de los puntos pueden alcanzarse inferencias hasta con un 91% de precisión contribuyendo a la disminución del tiempo de inferencia.

Palabras clave: Nube de puntos, inferencia, matriz de confusión, caracterización, valores típicos.

3D Point Cloud Outlier Characterization for Memory Runtime Reduction

Abstract. To reconstruct 3D objects, a type of geometric structure called "point cloud" can be used. A point cloud is a set of coordinates that represent the shape or surface of an object. One of the main problems when doing 3D mapping of scenes or objects is the presence of noise and outliers in the point cloud, produced by different factors such as sunlight or artificial light, object reflectivity,

geometry, or sensor-related constraints [1]. Outlier characterization was performed using point clouds with noise at different magnitudes, and point clouds without noise, taken from the Rakotosaona database [2]. The percentage of point coordinates was reduced, within 10% intervals in a range from 10% to 90%. One hundred forty-four inferences were performed using the PointCleanNet model [3]. Each inference was compared with the outlier label obtaining a confusion matrix to measure the precision, F1-score, and mean square error. The confusion matrix for each cloud showed that by removing 20% or less of the points, inferences with up to 91% accuracy can be achieved, contributing to a decrease in inference time.

Keywords: Point cloud, inference, confusion matrix.

1. Introducción

Cuando un objeto en tercera dimensión es escaneado para obtener una nube de puntos normalmente es contaminada por distintos tipos de ruido o magnitudes, esto provoca que las nubes de puntos tengan que someterse a un preprocesamiento para poder realizar tareas de segmentación o clasificación de forma eficiente.

Existen diversas metodologías para remover los valores atípicos de una nube de puntos, algunas están basadas en extraer características de puntos vecinos para poder clasificar los valores atípicos y reducirlos. La ecuación (1) describe una nube de puntos con presencia de valores atípicos. Dónde P_i , describe el conjunto de puntos de la superficie del objeto y O describe el conjunto de valores atípicos presentes [3]:

$$P = \{p_1, \dots, p_n\} \cup \{O_j\}_{O_j \in O}. \quad (1)$$

De manera general se establecen las siguientes metodologías utilizadas para la reducción de ruido y valores atípicos en nubes de puntos [4]. La reducción de valores atípicos por radio establece que los puntos que corresponden a los valores atípicos tienen menor densidad de puntos vecinos que los puntos que conforman al objeto [10].

La reducción de valores atípicos por esparcimiento utiliza la distancia entre puntos y el número de vecinos, asumiendo que los valores atípicos tienen una distribución normal y que los puntos que tienen en promedio dos sigmas como desviación estándar deben de ser clasificados como valores atípicos [11]. PointCleanNet es un algoritmo que estima los puntos vecinos, para cada punto de la nube de puntos, esto permite que nubes de puntos densas puedan ser procesadas sin perder características esenciales.

Los puntos vecinos se calculan utilizando un radio r , el radio es calculado en base a la diagonal descrita por los valores máximos y mínimos de los puntos frontera. Este tipo de algoritmos están pensados para ser ejecutados en GPU. Las nubes de puntos son cada vez más densas debido a la resolución de los sensores utilizados para el escaneo o reconstrucción de superficies u objetos, produciendo que cada vez más puntos tengan que ser cargados en memoria [8].

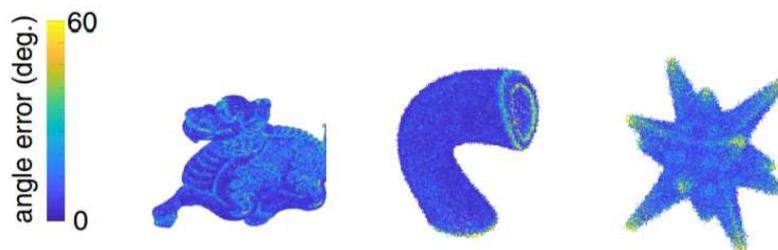


Fig. 1. Estimación de normales de PCPNet [6].

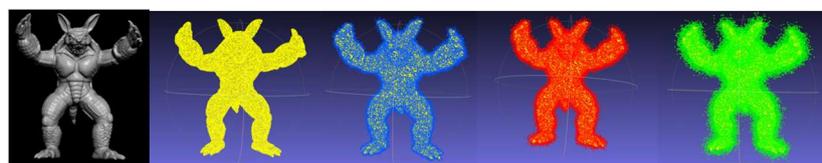


Fig. 2. Nube de puntos de armadillo con distintas magnitudes de ruido [3].

Existen distintas propuestas para evitar el consumo excesivo de memoria para el procesamiento de los puntos vecinos de una nube, por ejemplo, el algoritmo “*k nearest neighbors*” [5] que utiliza la localidad de puntos para intentar reducir el tiempo de ejecución. El tiempo de ejecución para el procesamiento de una nube de puntos está en función de la densidad de la nube de puntos y el algoritmo para la estimación de los puntos vecinos [8].

1.1. Trabajos relacionados

El aprendizaje profundo (en inglés, Deep Learning) es un subcampo del aprendizaje automático. Es una metodología en la que el enfoque principal es el aprendizaje en capas sucesivas de representaciones significativas [9].

Técnicas de aprendizaje profundo utilizadas en redes neuronales han demostrado tener buenos resultados en la reducción de ruido y la eliminación de valores atípicos para las nubes de puntos en 3D. Para atacar este problema han surgido distintos algoritmos como el algoritmo PCPNet [6], el cual mediante la estimación de propiedades locales logra reducir el nivel de ruido en una nube de puntos.

En la fig. 1 podemos observar el resultado cualitativo de PCPNet, contiene un error mínimo en la estimación de normales. Para el aprendizaje sugieren un método basado en parches, el enfoque principal es estimar propiedades de forma local para normales (orientadas y desorientadas) y la curvatura de nubes de puntos sin procesar con presencia alta de ruido [3]. PointNet [7] es un algoritmo enfocado en la clasificación de objetos, segmentación de partes y análisis semántico de la escena.

Una de las principales ventajas que tiene PointNet sobre otros algoritmos de clasificación y segmentación es que, al procesar una nube de puntos, dichos algoritmos requieren que las nubes de puntos sean regulares, por lo que estas tienen que ser sometidas a transformaciones. PointNet no necesita realizar transformaciones de este

tipo, ya que cada punto se trata de forma única e independiente debido a que utiliza un método llamado “*Max Pooling*” como método de discretización [7].

PointCleanNet es un algoritmo dedicado a la reducción de ruido y valores atípicos. Este algoritmo está basado en la reducción de valores atípicos por radio. El radio es utilizado para la estimación de vecinos el cual ayuda a manejar nubes de puntos con alta densidad. La base de datos que utiliza para el entrenamiento del modelo contiene 28 figuras con distintas magnitudes de ruido y su correspondiente nube de puntos sin ruido, de esta forma es posible conocer qué puntos de la nube son valores atípicos.

Para generar los valores atípicos de la nube se introdujo ruido gaussiano con una desviación estándar del 20% de acuerdo con la diagonal definida por los valores máximos y mínimos de cada nube [3].

2. Materiales y métodos

En esta sección se describe, el material utilizado, la caracterización de ruido, la red neuronal y métricas de validación.

2.1- Material utilizado

Para la creación y preprocesamiento de las nubes de puntos se utilizaron las siguientes herramientas.

- Laptop Hp Pavilion 4 Gb RAM, 500 Gb HDD, GTX1650, Rizen 7.
- MeshLab versión 2020.12.
- Pycharm versión 2020.1.
- Anaconda Python 3.7 64-Bit.
- Jupiter Notebook.

Los algoritmos para el preprocesamiento de la nube fueron desarrollados en Python 3.7 utilizando Jupiter Notebook, las nubes eran cargadas en la memoria de la GPU para el preprocesamiento, MeshLab fue utilizado como herramienta de visualización, una nube de puntos con una densidad de 140, 000 puntos al ser visualizada ocupaban 532 MB, por lo que las especificaciones de la Laptop HP Pavilion eran suficientes.

Para las inferencias el hardware y software utilizado fue el siguiente:

- Workstation NVIDIA GeForce RTX 3060 TI. 8GB GDDR6. 4864 CUDA Cores, AMD Ryzen 5600x, 6 Cores, 12 hilos, 3.7GHz 32MB L3 Cache 3MB L2 Cache, 16 GB RAM.
- Python 3.7 64-Bits.
- Docker container Linux Engine Versión 19.03.8.
- Ubuntu 20.04.2 LTS.

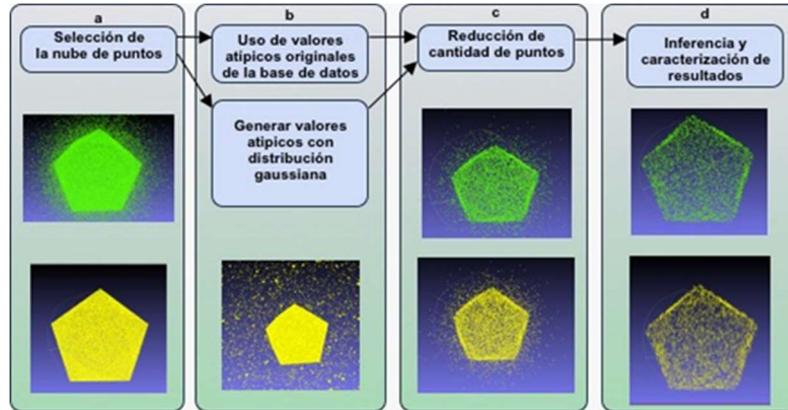


Fig. 3. Metodología propuesta para la caracterización del ruido en distintas magnitudes.

Las inferencias fueron realizadas en una estación de trabajo con las especificaciones antes mencionadas, esto debido a que la alta densidad de las nubes de puntos requiere un alto procesamiento en GPU. Se utilizó una tarjeta RTX 3060, con sistema operativo Ubuntu, y contenedores Docker para la manipulación del ambiente de programación.

2.2 Caracterización de ruido

La caracterización de ruido consta de 4 etapas principales como se muestra en la fig. 3., la selección de nubes de puntos a), generación de valores atípicos b), reducción de la densidad de la nube e inferencia c) y caracterización de resultados d).

La caracterización del ruido se realizó utilizando la metodología propuesta en la fig. 3. Se utilizaron nubes de puntos de la base de datos de PointCleanNet para reducción de valores atípicos (a).

De la base de datos se generaron 288 nubes, que corresponden a 4 figuras, de las cuales se obtuvo una nube de puntos con ruido gaussiano con una desviación estándar de 1%, 2.5% y 5% b). El modelo que describe la nube de puntos y el ruido está descrito por la ecuación (2). P' representa la nube de puntos con ruido, P son el conjunto de puntos que representan la superficie del objeto, n_i es el ruido aditivo, O es el conjunto de valores atípicos presentes en la nube [3]:

$$P' = \{p'_i\} = \{p_i + n_i\}_{p_i \in P} \cup \{o_j\}_{o_j \in O}. \quad (2)$$

Se generó un archivo en el que se clasifican cada uno de los puntos. Además, la densidad de las nubes varía con intervalos de 10% en un rango de 10% a 90% c).

Posterior a esto se realizaron 144 inferencias d), con el modelo propuesto por PointCleanNet [3], utilizando como entrada las nubes con distintas magnitudes de ruido y distinta densidad. El objetivo de la inferencia es obtener el rendimiento de la red neuronal con distintos niveles de ruido y densidad para determinar el punto de inflexión con el que la remoción de puntos no afecte el rendimiento y a la vez contribuya a reducir el tiempo de inferencia.

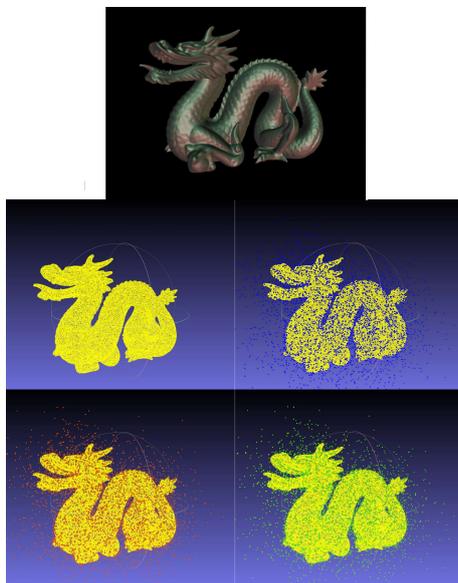


Fig. 4. Nube de puntos de dragón con distintas magnitudes de ruido con una desviación estándar de 1%, 2.5% y 5% y distinta densidad.

2.3 Red neuronal

La arquitectura de la red neuronal convolucional utilizada es la propuesta por PointCleanNet [3], tiene dos etapas principales, una etapa dedicada a reducir el número de valores atípicos y otra a reducción de ruido.

Para la reducción de valores atípicos la red neuronal está basada en las arquitecturas de PCPNet [6] y PointNet [7], debido a que utilizan Perceptrones de múltiples capas para la extracción de características significativas, además utilizan una metodología para saltar conexiones con el objetivo de promover la propagación del gradiente y mejorar el entrenamiento [3].

Esta arquitectura de red, además utiliza reducción de valores atípicos por radio, esta metodología es utilizada para estimar que tan probable es el punto central de ser un valor atípico.

El modelo de la nube de puntos es descrito por la ecuación (1), la nube de puntos está compuesta por los puntos que describen la superficie del objeto, y que además cuenta con presencia de ruido y valores atípicos. Para el entrenamiento se utiliza una función no lineal que es utilizada para remover los valores atípicos [3]:

$$\tilde{O}_i = g(P'_i) > 0.5 . \tag{3}$$

La ecuación (3) representa la probabilidad de valor atípico \tilde{O}_i , establece que un punto es añadido al conjunto de valores atípicos si la probabilidad de valor atípico es mayor al 0.5 [3].

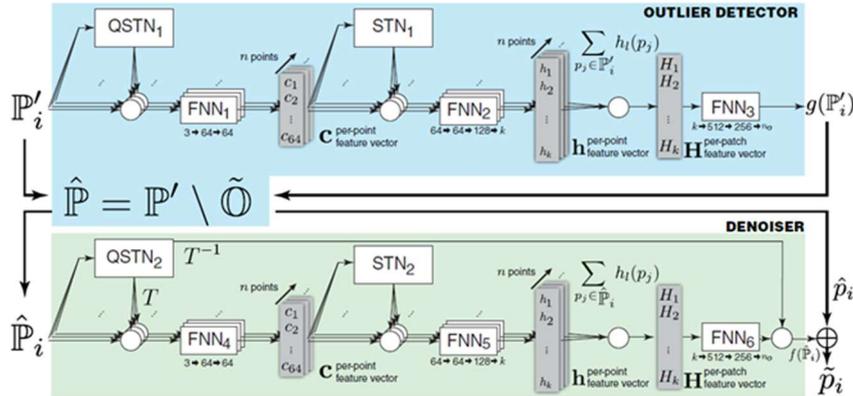


Fig. 5. Diagrama de red convolucional de PontCleanNet[3], la red recibe como entrada una nube de puntos con presencia de ruido P_i , ésta es procesada por una red neuronal utilizada para la clasificación de valores atípicos y obtener una nube de puntos con reducción de outliers y el conjunto de outliers removidos $\hat{P}_i \setminus \tilde{O}$ [3].

2.4 Criterios de evaluación

Cuando intentamos reducir el nivel de valores atípicos en una nube de puntos debemos de considerar que los puntos que se están removiendo con el modelo propuesto correspondan a los valores atípicos (True Positive), que la cantidad de puntos que se remuevan erróneamente sean cuantificados (False Positive). Estas dos métricas contribuyen a la Precisión (ecuación 4), Recall (ecuación 5), F1-Score (ecuación 6) y el Error Cuadrático Medio (ecuación 7) del modelo [3]:

$$\text{Precisión} = \frac{\sum \text{true positive}}{\sum \text{Predicted Positive Condition}}, \quad (4)$$

$$\text{True Positive Rate, Recall} = \frac{\sum \text{true positive}}{\sum \text{Positive Condition}}, \quad (5)$$

$$F1 - \text{Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}, \quad (6)$$

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2. \quad (7)$$

3. Resultados

En esta sección se describen los resultados cuantitativos y cualitativos obtenidos después de realizar las inferencias para la etapa de reducción de valores atípicos utilizando el modelo propuesto por PointCleanNet.

3.1 Resultados cuantitativos

La tabla 1 muestra los resultados de las inferencias de las nubes de puntos con presencia de valores atípicos realizadas con el modelo propuesto por PontCleanNet [3], cada columna de la tabla representa las métricas de evaluación así como el tiempo de ejecución en GPU. Se realizaron inferencias para 144 nubes de puntos con distintas magnitudes de ruido con una desviación estándar de 1%, 2.5% y 5% y distinta densidad como se muestra en la tabla 1.

La densidad de la nube está en función del porcentaje de puntos que se removieron, siendo de menor densidad aquellas nubes a las que se removió mayor porcentaje de puntos. Las inferencias se realizaron utilizando la estación de trabajo definida en la sección de material utilizado. Se puede observar en la tabla 1. que para una densidad de 112, 000 puntos se obtiene una Precisión del 87.32% (ecuación 4), Recall del 84.08 % (ecuación 5), F1-Score del 91.48% (ecuación 6), MSE del 05.09% (ecuación 7), y tiempo de ejecución en GPU de 68 minutos.

Para esta densidad de puntos el error cuadrático indica que el rendimiento del modelo no se degrada con la reducción de la densidad de puntos. Por otra parte, los resultados obtenidos en nubes de puntos con una densidad de 84, 000 puntos indican una degradación en la clasificación de los valores atípicos, en comparación con los resultados obtenidos con una densidad de 112,000 puntos.

3.2 Resultados cualitativos

La siguiente imagen muestra tres figuras distintas, las figuras cuentan con distinto nivel de valores atípicos y distinta densidad. Cabe recalcar que las inferencias corresponden al análisis hecho para 126,000 y 84,000 puntos respectivamente, el propósito principal es mostrar el punto en el que el rendimiento del modelo conlleva a una degradación en la clasificación de valores atípicos.

Nubes de puntos con una densidad de 84,000 puntos o menor, tienen a degradar el rendimiento del modelo. Por otro lado el tiempo de inferencia disminuye cuando la densidad es mayor a 112,000 puntos, dónde el rendimiento de la red no se ve perjudicado obteniendo F1-Score de 91.48%.

4. Conclusiones y trabajo futuro

La inferencia para el procesamiento de una nube con 140,000 puntos toma en promedio 85.71 minutos. Para una nube con 112,000 puntos toma en promedio 68.57 minutos. Reducir el tamaño de una nube de puntos en un 20% contribuye a la reducción del tiempo de inferencia en un 24.99%. El f1-score muestra que al remover el 20% de los puntos se obtiene 91.48%, es aquí cuando la reducción del tiempo de ejecución alcanza su óptimo, ya que se preserva la clasificación de los valores atípicos. Por el contrario, analizando los resultados de la nube con una densidad de 84,000 puntos, esta toma en promedio 51.31 minutos, pero la reducción del rendimiento para la clasificación de nubes de puntos es evidente con un 77.05% de f1-score.

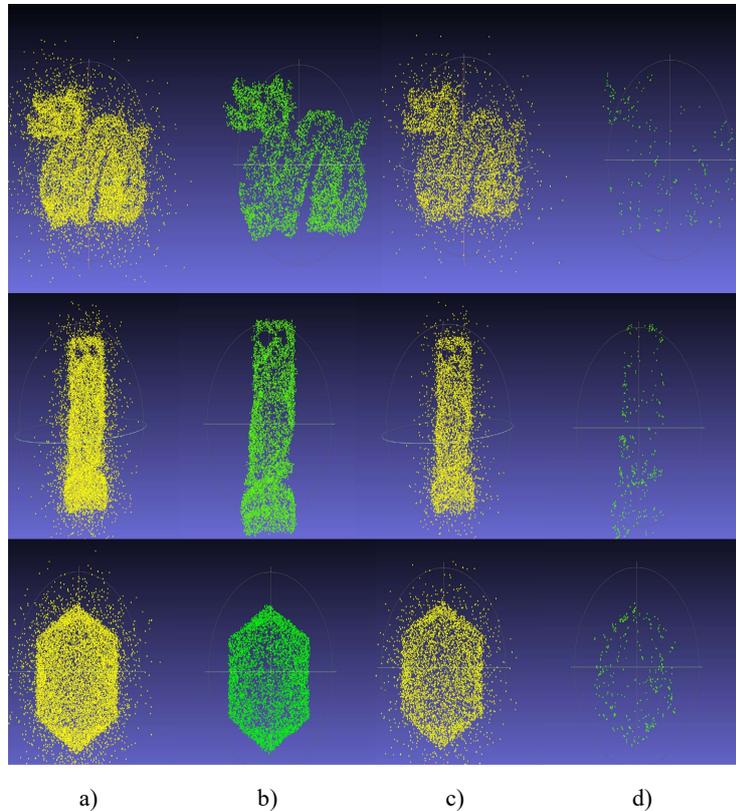


Fig. 6. Comparativa de resultados obtenidos para nubes de puntos con presencia de valores atípicos. De izquierda a derecha y de arriba abajo: a) Nubes con 126,000 puntos y valores atípicos. b) Inferencia utilizando el modelo propuesto por PointCleanNet para las nubes de 126, 000 puntos. c) Nubes con 84,000 puntos y valores atípicos., d) Inferencia utilizando el modelo propuesto por PointCleanNet para las nubes de 84, 000 puntos.

Las nubes de puntos procesadas permitieron analizar los resultados de las inferencias para verificar bajo qué circunstancias la red neuronal tiene resultados aceptables, es decir cuando la degradación de las características de la figura en si se ven perjudicadas, esto para determinar hasta qué punto es recomendable reducir la densidad de la nube, además permite determinar cuando la densidad de la nube afecta de manera significativa el rendimiento de la red.

Al hacer la inferencia en la nube de puntos podemos observar que uno de los factores que afectan a la reducción de ruido y valores atípicos es la forma o la figura de las nubes de puntos, así como el nivel de ruido presente. Nubes de puntos con formas complejas se ven afectadas dando como resultado a la pérdida de características en la nube.

Como trabajo futuro, se tiene considerado continuar con el desarrollo e implementación de una red neuronal convolucional que contribuya a mejorar el rendimiento de redes neuronales para la reducción de ruido y valores atípicos, así como mejorar el tiempo de ejecución de nubes de puntos densas. Continuar con la

Tabla 1. Comparación de resultados cualitativos.

Densidad de nube pts.	Precisión %	Recall %	F1-Score %	MSE %	GPU min
14, 000	29.78	100	45.89	72.71	8.58
28, 000	29.23	99.75	45.23	68.50	17.14
42, 000	32.84	99.26	49.39	58.14	25.71
56, 000	39.64	96.72	56.57	42.41	34.24
70, 000	50.19	94.68	66.40	27.92	42.78
84, 000	63.70	92.13	77.05	16.31	51.31
98, 000	77.93	87.43	86.33	08.59	59.85
112, 000	87.32	84.08	91.48	05.09	68.57
126, 000	95.38	80.75	95.03	02.84	77.14
140,000	99.61	90.78	94.99	02.75	85.71

implementación de pruebas para medir el desempeño de la red y determinar áreas de mejora.

Referencias

1. Sotoodeh, S.: Outlier detection in laser scanner point clouds. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 36, no, 5, pp. 297–302 (2006) doi: 10.3929/ethz-b-000037220
2. Rakotsaona, M. J., La Barbera, V., Guerrero, P., Mitra, N. J., Ovsjanikov, M.: Index of /projects/2019/pointcleannet/data. Recuperado 6 de enero de 2021, de <http://geometry.cs.ucl.ac.uk/projects/2019/pointcleannet/data/> (2021)
3. Rakotsaona, M. J., La Barbera, V., Guerrero, P., Mitra, N. J., Ovsjanikov, M.: PointCleanNet: Learning to denoise and remove outliers from dense point clouds. In *Computer Graphics Forum*, vol. 39, no. 1, pp. 185–203 (2019) doi: 10.1111/cgf.13753
4. Javaheri, A., Brites, C., Pereira, F., Ascenso, J.: Subjective and objective quality evaluation of 3D point cloud denoising algorithms. In: *Proceedings of IEEE International Conference on Multimedia & Expo Workshops (ICMEW)*, pp. 1–6 (2017) doi: 10.1109/ICMEW.2017.8026263
5. Sankaranarayanan, J., Samet, H., Varshney, A.: A fast all nearest neighbor algorithm for applications involving large point-clouds. *Computers & Graphics*, vol. 3, no. 2, pp. 157–174 (2007) doi: 10.1016/j.cag.2006.11.011
6. Guerrero, P., Kleiman, Y., Ovsjanikov, M., Mitra, N. J.: PCPNet learning local shape properties from raw point clouds. *Computer Graphics Forum*, vol. 37, no. 2, pp. 75-85 (2018) doi: 10.1016/j.cag.2006.11.011
7. 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 Conference On Computer Vision and Pattern Recognition*, pp. 652–660 (2017)

8. Javaheri, A., Brites, C., Pereira, F., Ascenso, J.: Subjective and objective quality evaluation of 3D point cloud denoising algorithms. In: Proceedings of IEEE International Conference on Multimedia & Expo Workshops ICMEW'17. pp. 1–6 IEEE (2017) doi: 10.1109/ICMEW.2017.8026263.
9. Chollet, F.: Deep learning with python: Das Praxis-Handbuch vom Entwickler der Keras-Bibliothek. MITP-Verlags GmbH & Co. KG (2017)
10. Schoenenberger, Y., Paratte, J., Vandergheynst, P.: Graph-based denoising for time-varyingpoint clouds. In: Proceedings of 3DTV Conference: The True Vision-Capture, Transmission and Display of 3D Video, Lisbon, Portugal, pp. 1–4 (2015) doi: 10.1109/3DTV.2015.7169366
11. Rusu, R. B., Marton, Z. C., Blodow, N., Dolha, M., Beetzet, M.: Towards 3D point cloud based object maps for household environments. *Robotics and Autonomous Systems*, vol. 56, no. 2, pp. 927–941 (2008) doi: 10.1016/j.robot.2008.08.005