

Perkembangan teknologi yang pesat juga membawa kepada perkembangan ragam data yang ada. Salah satu data yang menjadi mudah didapatkan adalah data 3D dalam bentuk *point clouds*. Data 3D memberikan informasi spasial dan geometri yang lebih mendalam dibandingkan data 2D. Pengolahan data 3D memerlukan metode khusus yang berbeda dibandingkan jenis data lain. Tugas akhir ini bertujuan untuk mengembangkan model *deep learning* yang digunakan untuk tugas klasifikasi pada data 3D *point clouds*. Fokus utama dari pengembangan model adalah menganalisis pengaruh penggunaan beberapa metode *sampling* dan *grouping* dalam mengolah data 3D *point clouds*. *Point clouds* dipilih karena data 3D ini merupakan data *raw* yang didapat dari *sensing device* seperti sensor *light detection and ranging* (LiDAR). Selain itu, *point clouds* memiliki ukuran dan beban komputasi yang lebih kecil dibandingkan dengan data 3D lain, namun tetap dapat mempertahankan informasi spasial dan geometri dengan baik. Model *deep learning* dikembangkan menggunakan arsitektur PointNet++. Arsitektur ini dipilih karena PointNet++ merupakan model yang dapat memanfaatkan struktur lokal *point clouds*. Pada pengembangan model, diterapkan beberapa metode *sampling* dan *grouping* pada layer abstraksi model. Layer abstraksi model menerapkan dua metode *sampling* yaitu, *furthest point sampling* (FPS) dan *random sampling* serta dua metode *grouping* yaitu, *K nearest neighbour* (KNN) dan *radius ball*. Pelatihan model dilakukan dengan beberapa konfigurasi jumlah *neighbour* pada metode *grouping* mulai dari 6 hingga 80 *neighbour*. Model kemudian dianalisis berdasarkan metrik akurasi dan waktu *training*. Hasil penelitian menunjukkan bahwa model yang menggunakan FPS dan KNN memberikan akurasi terbaik serta performa yang stabil pada berbagai konfigurasi jumlah *neighbour*. Model yang menggunakan *radius ball* memiliki waktu *training* yang jauh lebih cepat dibandingkan dengan *grouping* KNN. Namun, metode tersebut memberikan akurasi yang lebih rendah dibandingkan KNN. Metode *random sampling* mampu meningkatkan efisiensi waktu *training* model tanpa mengorbankan performa akurasi yang signifikan. Metode FPS melakukan *sampling* dengan mempertahankan fitur objek sehingga memberikan performa yang lebih baik.

Kata kunci : *neural networks, deep learning, geometry processing, classification, point clouds*

ABSTRACT

The rapid development of technology has also led to the development of a variety of existing data. One of the data that has become easy to develop is 3D data in form of point clouds. Data 3D data provides more in-depth spatial and geometric information than 2D data. Processing 3D data requires special methods that are different from other types of data. This undergraduate thesis aims to develop a deep learning model used for classification tasks on 3D point clouds data. The main focus of the model development is to analyze the effect of using several sampling and grouping methods in processing 3D point clouds data. Point clouds are chosen because this 3D data is raw data obtained from sensing devices such as light detection and ranging (LiDAR). Point clouds have smaller size and computational load compared to other 3D data, while still maintaining spatial and geometry information well. The deep learning model is developed using the PointNet++ architecture. This architecture was chosen because PointNet++ is a model that can utilize the local structure of point clouds. structure of point clouds. In the model development, several sampling and grouping methods were applied to the model abstraction layer. The abstraction layer of the model applies two sampling methods namely, furthest point sampling (FPS) and random sampling and two grouping methods namely, K nearest neighbour (KNN) and radius ball. Model training is performed with several configurations of the number of neighbors in the grouping method ranging from 6 to 80 neighbors. The model was analyzed based on accuracy and training time metrics. The results show that the model using FPS and KNN provides the best accuracy and stable performance on various configurations of the number of neighbors. The model that uses radius ball has a much faster training time compared to the KNN grouping. However, it provides lower accuracy than KNN. The random sampling method was able to improve the efficiency of the model training time without sacrificing significant accuracy performance. The FPS method performs sampling by preserving the object features so it provides better performance.

Keywords : *neural networks, deep learning , geometry processing, classification, point clouds*