

Człowiek postrzega otaczającą go rzeczywistość jako zbiór obiektów zlokalizowanych w przestrzeni trójwymiarowej. Aby móc scharakteryzować własności geometryczne tych obiektów oraz zlokalizować je w przestrzeni, niezbędne jest określenie ich wymiarów oraz współrzędnych określających ich położenie. W celu pomiaru kształtu skomplikowanych obiektów, niezbędne jest wyznaczenie współrzędnych wielu punktów na ich powierzchni. Może to zostać osiągnięte poprzez zastosowanie metod teledetekcyjnych. Techniki te pozwalają na pomiar obiektu i ustalenie jego lokalizacji za pomocą urządzeń, które nie mają kontaktu z mierzonym obiektem. Wyniki pomiarów mogą zostać przedstawione na różnorodne sposoby, jednak produktem najbardziej zbliżonym do trójwymiarowego postrzegania świata przez człowieka jest tzw. chmura punktów. Chmurę punktów stanowi nieuporządkowany zbiór punktów przedstawiających powierzchnię mierzonych obiektów. Każdemu punktowi przypisane są trzy współrzędne mówiące o jego położeniu w przestrzeni 3D.

Chmury punktów można pozyskać na kilka sposobów. Jednym z nich jest wykorzystanie skanera laserowego, którego działanie oparte jest o pomiar czasu, jaki zajmuje impulsowi laserowemu dotarcie do obiektu, odbicie się a następnie powrót do urządzenia. Znając prędkość światła i kąt, pod którym wiązka promieniowania laserowego została wysłana, można określić współrzędne punktu na powierzchni obiektu, od którego został odbity impuls laserowy. Skanera laserowego można używać w sposób stacjonarny lub umieścić go na poruszającym się obiekcie, np. dronie czy samolocie. Pomiar obiektów o dużych rozmiarach, np. całych miast, jest powszechnie wykonywany przy pomocy lotniczego skaningu laserowego (z ang. ALS – *airborne laser scanning*). Jednak pozyskana w ten sposób chmura punktów przedstawia powierzchnię bardzo dużej liczby obiektów różnego typu (budynki, drzewa, itp.). W związku z tym, aby dane te mogły być dalej przetwarzane i wykorzystywane niezbędne jest przypisanie każdemu punktowi opisu wskazującego na jego przynależność do pewnej grupy obiektów (klasy), np. drzew, powierzchni terenu, itp. Ta czynność nazywana jest klasyfikacją.

Ze względu na wysoką gęstość danych, ich manualna analiza jest bardzo czasochłonna i podatna na błędy w interpretacji. Dlatego też obecnie wykorzystuje się automatyczne algorytmy pozwalające na wykonanie tej czynności. Metody te oparte są często o uczenie maszynowe, które polega na wytrenowaniu algorytmu, na podstawie pewnej próbki danych ukazującej prawidłowe przypisaniu punktów do poszczególnych klas, aby przyporządkowywał pozostałe punkty do odpowiednich klas. Zwykle taka klasyfikacja była wykonywana w oparciu o tzw. algorytmy „uczenia płytkiego” polegające na statystycznym rozróżnieniu obiektów na podstawie ich cech definiowanych przez człowieka i obliczanych na podstawie chmury punktów. Jednak cechy takie silnie zależą od charakterystyki chmury punktów czy wykorzystanego skanera laserowego. Dlatego też od niedawna popularność zyskują metody „uczenia głębokiego”, które wykorzystują sztuczne sieci neuronowe. Koncepcja sieci neuronowych opiera się na próbach odtworzenia sposobu działania ludzkiego mózgu. Głębokie sieci neuronowe składają się zatem z wielu warstw pojedynczych neuronów. Zastosowanie tego typu metod pozwala na uniknięcie definiowania cech, ponieważ są one automatycznie wyznaczane w trakcie uczenia się sieci. Jednak ze względu na jej skomplikowany charakter, trenowanie głębokiej sieci neuronowej jest czasochłonne i wymaga dużej ilości danych uczących, które są trudno dostępne. **Zatem opracowanie metodologii pozwalającej na jednokrotne wytrenowanie sieci neuronowej a następnie wykorzystywanie jej do klasyfikacji danych pozyskanych przy pomocy różnego sprzętu i posiadających różną charakterystykę (np. gęstość) pozwoliłoby na wyeliminowanie tych wad.** Jednak ze względu na wspomnianą słabą dostępność danych uczących, odtwarzalność klasyfikacji przy pomocy wytrenowanych sieci neuronowych na danych o innej charakterystyce pozostaje niezbadana.

W ostatnim czasie, coraz więcej krajów decyduje się na udostępnienie pozyskanych przez siebie zestawów danych przestrzennych, w tym danych ALS. W większości przypadków dane te są już sklasyfikowane za pomocą metod automatycznych. Jednak niektóre kraje (np. Polska, Austria czy Holandia) zdecydowały się na zlecenie ręcznej korekty wyników automatycznej klasyfikacji w celu podniesienia jej dokładności. Inicjatywa ta otwiera bardzo obiecujące możliwości klasyfikacji danych ALS, ponieważ umożliwia kompleksowe trenowanie głębokich sieci neuronowych. W związku z tym, celem niniejszego projektu jest opracowanie metodologii pozwalającej na klasyfikację chmur punktów ALS o różnej charakterystyce z użyciem jednokrotnie wytrenowanej sieci neuronowej. Opracowanie metodologii zostanie przeprowadzone w oparciu o publicznie udostępnione dane ALS.

Klasyfikacja chmury punktów jest pierwszym krokiem większości algorytmów przetwarzania danych ALS. **Opracowanie wspomnianej metodologii pozwoli zatem na ulepszenie szybkości działania i dokładności algorytmów używanych do analizy chmur punktów w różnorodnych zastosowaniach, takich jak precyzyjne leśnictwo, planowanie przestrzenne, modelowanie 3D budynków, badanie deformacji, monitorowanie zjawisk geomorfologicznych i wiele innych.** Z drugiej strony, pozwoli w przyszłości na zmniejszenie kosztów wykonania dokładnej klasyfikacji danych ALS pozyskiwanych i udostępnianych przez poszczególne państwa.