

## Wnioski

- Dane hiperspektralne zawierają unikatowe informacje o roślinności, pozwalając na identyfikację zbiorowisk oraz ich układów przestrzennych;
- Sieci neuronowe są właściwym narzędziem do klasyfikacji skomplikowanych układów przestrzennych (symulator wykorzystuje informacje o przestrzennym ułożeniu i sąsiedztwie analizowanego obiektu), pozwoliły one na klasyfikację przeważającej większości typów roślinności wysokogórskiej (w rozpatrywanym przypadku 40 na 42 jednostki), przy wysokiej dokładności wyników (najwyższa średnia dokładność producenta dla wszystkich klas wyniosła 93%, a dokładność użytkownika 84%, natomiast średnia dokładność wszystkich klasyfikacji wyniosła odpowiednio 86 i 75%);
- Lepsze wyniki klasyfikacji uzyskuje się dla dużych, zwartych zbiorowisk roślinnych o jednorodnej strukturze (dokładność całkowita wyższa o 3-4% i o 2-4% mniejsze odchylenia standardowe w porównaniu do zbiorowisk tworzących mozaikowe kompleksy topograficzne);
- Mapa powstała w wyniku klasyfikacji obrazów hiperspektralnych wykazuje wysokie podobieństwo do mapy powstałej jako efekt badań terenowych, podobieństwo to waha się w zależności od linii zobrazowania i typu klasyfikowanych danych na poziomie 81-84% (wskaźnik kappa);
- Duża jest także powtarzalność wyników, uzyskanych z poszczególnych linii zobrazowania; odchylenie standardowe waha się na poziomie kilku procent. Oznacza to, że można mapę powstałą w wyniku przetwarzania danych hiperspektralnych traktować jako podstawę do sporządzania map roślinności gór w skali szczegółowej;
- Najważniejsze etapy pracy, których prawidłowe przeprowadzenie warunkuje satysfakcjonujące wyniki końcowe, to: badania terenowe podczas trwania zobrazowania (zebranie danych referencyjnych do korekcji geometrycznej oraz atmosferycznej), stworzenie odpowiednio dużych wzorców poligonów poszczególnych klas do uczenia sieci oraz weryfikacji poklasyfikacyjnej, wykonanie prawidłowej korekcji geometrycznej i atmosferycznej, optymalny dobór kanałów oraz parametrów sieci do klasyfikacji;
- Optymalny wzorzec do uczenia sieci powinien składać się z co najmniej 400 pikseli danej klasy oraz 40 kanałów;
- Czynnikiem wydłużającym klasyfikację jest liczba zadanych kanałów, dlatego zalecana jest analiza jakości i informacyjności poszczególnych wyciągów spektralnych;
- Zastosowanie danych po kompresji MNF przyspiesza klasyfikację, jednakże uzyskane wyniki są o kilkukilkanaście procent gorsze od klasyfikacji przeprowadzonej na danych oryginalnych (po korekcji geometrycznej i atmosferycznej);
- Dla obszarów górskich wymagana jest pełna korekcja atmosferyczna (obejmująca także normalizację dwukierunkowości odbicia promieniowania). Pozwala to wyeliminować wpływ orografii atmosfery i geometrii słońce-obiekt detektor na odbicie sygnału;
- Darmowy dostęp do symulatorów oraz aktywnych grup dyskusyjnych poświęconych sieciom neuronowym pozwala z optymizmem patrzeć na przyszłość tego typu prac, tym bardziej, że operatorzy satelitarnego systemu hiperspektralnego EnMAP zapowiedzieli otwartą dystrybucję danych, co ma nastąpić po umieszczeniu sensora na orbicie w 2011/12 roku.