

Krzysztof Dyba

Interpretacja danych geoprzestrzennych przy użyciu wyjaśnialnych metod uczenia maszynowego

Streszczenie

Uczenie maszynowe niewątpliwie stało się wszechobecne w różnych dyscyplinach naukowych uwzględniając nauki o Ziemi i środowisku, rewolucjonizując przy tym sposób analizy i interpretacji danych geoprzestrzennych. Postępy te umożliwiły opracowanie zaawansowanych modeli typu czarnej skrzynki do zadań takich jak klasyfikacja pokrycia terenu, przewidywanie stref ryzyka powodziowego czy optymalizacja tras. Jednak, rozwój tych modeli wprowadził nowe wyzwania związane z przejrzystością ich działania oraz interpretowalnością wyników.

Przedstawiona dysertacja analizuje przydatność wyjaśnialnych metod uczenia maszynowego do interpretacji danych geoprzestrzennych, odpowiadając na pytanie czy niniejsze metody mogą wspomagać proces interpretacji czynników prowadzących do uzyskania wyniku. Cel dysertacji został zrealizowany przez trzy eksperymenty badawcze związane z zastosowaniem:

- 1) analizy regresji do estymacji temperatury powierzchniowej jezior w Polsce na podstawie termalnych zdjęć satelitarnych i pomiarów in-situ temperatury wody;
- 2) klasyfikacji nadzorowanej do automatycznego kartowania form geomorfologicznych na podstawie Cyfrowej Mapy Geomorfologicznej Polski i zmiennych geomorfometrycznych;
- 3) klasyfikacji nienadzorowanej do wyznaczenia i interpretacji typów powierzchni terenu na podstawie zmiennych geomorfometrycznych.

Na podstawie uzyskanych wyników stwierdzono, że zastosowane metody wyjaśniające są przydatne do interpretacji działania modeli typu czarnej skrzynki w kontekście analizy danych przestrzennych używanych do regresji i klasyfikacji. Pozwoliły one na lepsze zrozumienie decyzji podejmowanych przez modele i ujawnienie relacji pomiędzy zmiennymi wyjaśniającymi a wynikiem modelu. Wykorzystane metody wyjaśniające wskazały, nie tylko, które cechy są istotne, ale przede wszystkim, w jaki sposób wpłynęły na wynik predykcji. W efekcie zwiększyła się przejrzystość procesu modelowania, co ma kluczowe znaczenie do dalszego doskonalenia modeli i budowania zaufania oraz pomaga w podejmowaniu bardziej świadomych decyzji.

Słowa kluczowe: dane geoprzestrzenne, uczenie maszynowe, wyjaśnialność, model czarnej skrzynki