PREDIKCIA FLUVIÁLNEJ POVODŇOVEJ HROZBY POMOCOU STROJOVÉHO UČENIA TRÉNOVANÉHO NA HYDRAULICKY ODVODENÝCH DÁTACH

PREDICTION OF FLUVIAL FLOOD HAZARD USING MACHINE LEARNING TRAINED ON HYDRAULICALLY DERIVED DATA

Matej VOJTEK[1], Dávid DRŽÍK[2], Jana VOJTEKOVÁ[3]

Abstrakt

Fluviálne povodne vznikajú vtedy, keď povodňová vlna prekročí kapacitu koryta, čo vedie k zaplaveniu priľahlých území. Tento príspevok sa zameriava na predikciu rozsahu fluviálnej povodne a hĺbok vody pomocou strojového učenia, a to konkrétne modelu eXtreme Gradient Boosting (XGBoost).

Skúmané územie predstavoval 8,8 km dlhý úsek rieky Kysuca. Modely XGBoost boli trénované na hydraulicky vytvorených mapách hĺbky vody pre päť povodňových scenárov (Q_{10}, Q_{20}, Q_{50}, Q_{100} a Q_{1000}) s využitím hydraulického modelu MIKE+. Trénovanie modelov XGBoost zahŕňalo rozdelenie modelovaného úseku na desať segmentov, pričom v rámci každého povodňového scenára bolo použitých päť variantov rozdelenia segmentov na trénovaciu a testovaciu zložku.

Na trénovanie modelov strojového učenia bolo zároveň využitých sedem prediktorov s priestorovým rozlíšením 1 m. Multikolinearita medzi prediktormi bola hodnotená pomocou Pearsonovho korelačného koeficientu a Variance Inflation Factor (VIF). Na hodnotenie klasifikačných a regresných XGBoost modelov bolo použitých viacero metrík. Výsledky potvrdili, že model XGBoost dokáže poskytovať výpočtovo efektívne a relatívne presné mapy rozsahu povodne a hĺbok vody pri povodni vo všetkých variantoch rozdelenia trénovaniach/testovacích dát a povodňových scenárov.

Hodnota F1-skóre pri klasifikácii rozsahu zaplavenia sa pohybovala od 0,87 do 0,97 naprieč všetkými skúmanými scenármi a variantmi rozdelenia segmentov. Pri predikcii hĺbok vody dosiahli XGBoost modely v jednotlivých scenároch a variantoch rozdelenia trénovaniach/testovacích dát nasledovné hodnoty metrík: odmocnina strednej kvadratickej chyby (RMSE) 5 – 8 %, priemerná absolútna chyba (MAE) 3 – 5 % a koeficient determinácie (R^2) 81 – 95 %. Vo všetkých prípadoch segmentácie, okrem jedného, model XGBoost mierne nadhodnotil (<4 %) hydraulicky modelované hĺbky vody. Maximálny čas trénovania bol 31 sekúnd pre klasifikačný model a 48 sekúnd pre regresný model, čo umožňuje potenciálne nasadenie XGBoost modelu pre operačné mapovanie fluviálnej povodňovej hrozby.

[1] doc. RNDr. Matej VOJTEK, PhD., Katedra geografie, geoinformatiky a regionálneho rozvoja, Fakulta prírodných vied a informatiky, Univerzita Konštantína Filozofa v Nitre, Trieda A. Hlinku 1, 949 01 Nitra, mvojtek@ukf.sk

doc. RNDr. Matej VOJTEK, PhD., Geografický ústav SAV, v. v. i., Štefánikova 49, 814 73 Bratislava, matej.vojtek@savba.sk

[2] RNDr. Dávid DRŽÍK, PhD., Katedra informatiky, Fakulta prírodných vied a informatiky, Univerzita Konštantína Filozofa v Nitre, Trieda A. Hlinku 1, 949 01 Nitra, ddrzik@ukf.sk

[3] doc. RNDr. Jana VOJTEKOVÁ, PhD., Katedra geografie, geoinformatiky a regionálneho rozvoja, Fakulta prírodných vied a informatiky, Univerzita Konštantína Filozofa v Nitre, Trieda A. Hlinku 1, 949 01 Nitra, jvojtekova@ukf.sk

Financované EÚ NextGenerationEU prostredníctvom Plánu obnovy a odolnosti SR v rámci projektu č. 09I03-03-V03-00085.

Kľúčové slová: fluviálne povodne, strojové učenie, hydraulický model, priestorové dáta, prediktory

Keywords: fluvial floods, machine learning, hydraulic model, spatial data, predictors