



Strojno učenje in časovne vrste satelitskih posnetkov za klasifikacijo poljščin **Machine learning and Satellite Image Time Series for crop classification**

Matej Račič, Luka Čehovin Zajc, Krištof Oštir

POVZETEK

S satelitskimi posnetki lahko opazujemo in analiziramo kaj se dogaja na površju našega planeta skoraj v realnem času. S pogostimi posnetki istega območja, recimo satelitov Sentinel, ki jih omogoča sistem Copernicus, lahko pripravimo goste časovne vrste satelitskih posnetkov, ki so ključne za analizo vzorcev, spremljanje stanje in določanje trendov. Na podlagi časovnih vrst lahko z uporabo metod strojnega učenja ločimo med različnimi tipi površja.

Proces priprave gostih časovnih vrst satelitskih posnetkov vključuje tri korake. Prvi korak je določitev območja interesa in pridobitev pripadajočih posnetkov za izbran časovni interval iz obsežnega arhiva posnetkov. Pogosto uporabimo posnetke Sentinel-2, ki je optični satelit z deset metrsko resolucijo in pet dnevnim intervalom zajema površja. Alternativno lahko uporabimo posnetke Sentinel-1, ki je radarski satelit, informacijo o površju lahko zajame tudi skozi oblake. Pridobljeni podatki vsebujejo posnetke in pripadajoče metapodatke ter podatke o kakovosti, recimo maske oblakov, ki jo generirajo ponudniki. Naslednji korak vključuje odstranjevanje oblačnih vrednosti na podlagi maske, saj te ne odražajo dejanskih vrednosti na površju. Z zlaganjem zaporednih posnetkov zgradimo časovno vrsto satelitskih posnetkov. Zloženi posnetki zajemajo spremembe za izbrano regijo, vendar za namene analize praviloma potrebujemo manjša homogena območja, kot so na primer posamezni travnik, gozd, njiva. Te pridobimo na podlagi referenčnih podatkov, recimo vektorjev GERK, z njimi izrežemo goste časovne vrste za posamezno izbrano območje in izračunamo statistiko posameznih enot kartiranja.

Z analizo posameznega posnetka lahko ločimo med osnovnimi kategorijami, vendar ne more ločiti med podobnimi površinami, saj nimamo informacije o trendu (časovnem razvoju območja). Z gostimi časovnimi vrstami lahko v kombinaciji z metodami strojnega učenja ločimo tudi med podobnimi površinami, kot so poljščine. Metode strojnega učenja omogočajo avtomatsko prepoznavanje vzorcev in trendov v gostih časovnih vrstah, kar bi zahtevalo obsežno ročno delo in strokovno znanje. Izbira metode je odvisna od problema, ki ga naslavljamo, računske moči in količine referenčnih podatkov, ki so na voljo. Za ločevanje med različnimi tipi površja pogosto uporabimo metode klasifikacije z nadzorovanim učenjem izbranega modela. Vse pogosteje se uporabljajo metode globokih nevronske mreže, kot so Transformerji.

V prispevku bomo posebno pozornost namenili metodam strojnega učenja na primeru uporabe Transformerja prilagojenega za goste časovne vrste satelitskih posnetkov za klasifikacijo poljščin. Model na podlagi gosti časovni vrsti določil enega izmed 30 razredov poljščin. Izbrali smo 1.5 milijona poljščin ločenih na 30 razredov. Za učenje smo uporabili 55% primerov in uspešnost učenja ovrednotili na 11%, preostale podatke smo uporabili

za analiziranje uspešnosti na še ne videnih podatkih. Z evalvacijo modela na teh podatkih smo dosegli F1 vrednost 91%, ki je utežena s številom primerov za posamezen razred, s tem lahko potrdimo pravilnost 91% poljščin v Sloveniji.

V kmetijstvu lahko nato spremljamo rast in razvoj rastlin na poljih skozi čas. Kar omogoča tudi zgodnje odkrivanje težav, kot sta suša ali bolezen, optimizacijo intervalov namakanja, gnojenje ... S tem lahko povečamo učinkovitost kmetovanja in zmanjšamo potencialni negativni vpliv na okolje in pridelavo.

KLJUČNE BESEDE: Časovne vrste, strojno učenje, Copernicus, Sentinel

Matej Račič

Fakulteta za gradbeništvo in geodezijo, Jamova cesta 2

e-naslov: matej.racic@fgg.uni-lj.si

doc. dr. Luka Čehovin Zajc

Fakulteta za računalništvo in informatiko, Večna pot 113

e-naslov: luka.cehovin@fri.uni-lj.si

prof. dr. Krištof Oštir

Fakulteta za gradbeništvo in geodezijo, Jamova cesta 2

e-naslov: kristof.ostir@fgg.uni-lj.si