

STROJNO UČENJE U OBRADI ASTROFIZIČKIH PODATAKA MODERNIH PREGLEDA NEBA

Karlo Mrakovčić, mag. phys.

SAŽETAK PREDAVANJA:

Veliki pregledi neba, poput LSST-a (Legacy Survey of Space and Time) iz Opservatorija Vera Rubin, revolucionirat će naše razumijevanje svemira. Ovi instrumenti će prikupiti ogromne količine podataka o milijardama astrofizičkih objekata, i time omogućiti detaljne studije kozmičke evolucije, tamne tvari, tamne energije i temeljnih astrofizičkih procesa.



Fotografija zvjezdarnice Rubin u sumrak snimljena u travnju 2021.
Izvor: Rubin Obs./NSF/AURA

Istraživanja se danas sve više fokusiraju na metode koje maksimiziraju znanstveni učinak iz ovih masivnih skupova podataka. LSST će, zahvaljujući desetljećem dugom prikupljanju podataka omogućiti detaljna istraživanja svemira u prostornoj i vremenskoj komponenti. Strojno učenje (ML) igra ključnu ulogu u ovakvom istraživanju, omogućuje obradu i analizu visokodimenzionalnih podataka poput fotometrijskih mjerjenja, svjetlosnih krivulja i astronomskih slika. Ove tehnike pomažu identificirati uzorke, anomalije i nove fenomene koje tradicionalne metode često propuštaju.

Značajan napredak već je postignut u razumijevanju Mliječnog puta korištenjem podataka iz Sloan Digital Sky Survey-a (SDSS). Primjerice, fotometrijska metoda paralakse mapirala je trodimenzionalnu distribuciju oko 48 milijuna zvijezda, otkrivajući složenost strukture galaksije. LSST će dodatno unaprijediti ove analize, omogućujući procjenu zvjezdanih parametara za oko 200 milijuna zvijezda. Osim toga, LSST-ova sposobnost detekcije brzih objekata, poput potencijalno opasnih asteroida (PHA) i objekata blizu Zemlje (NEO), ključna je za unapređenje planetarne obrane.

Unatoč postignućima, i dalje postoje izazovi, poput procjene udaljenosti zvijezda u Mliječnom putu koristeći samo fotometrijske podatke. Razvoj pouzdanog ML modela za preciznu procjenu udaljenosti, uz procjenu pogreške, ključno je za mapiranje galaktičke strukture i razumijevanje njenog nastanka. Također, potrebno je poboljšati algoritme za detekciju brzih objekata kako bi se riješili problemi poput "trailing losses" efekta, kao i razviti sustave za klasifikaciju prolaznih pojava ("real or bogus") u stvarnom vremenu unutar LSST-ovih podataka.

Moje istraživanje koristi neuronske mreže s prilagođenim arhitekturama, uključujući konvolucijske mreže (CNN), za analizu LSST-ovih fotometrijskih podataka. Modeli se treniraju na superračunalima kako bi učinkovito obradili velike i složene skupove podataka. Cilj je nadmašiti tradicionalne metode poput modeliranja i statističkih tehniki, pružajući precizniji uvid u astrofizičke fenomene. Time želimo optimizirati analizu podataka i omogućiti dublje razumijevanje svemira, uz otkrivanje novih astronomskih pojava.