Mlada suradnica CIPOP-a **Dunja Božić Štulić** obranila je na FESB-u 30.06.2020.g. pod mentorstvom **prof.dr.sc.Darka Stipaničeva** doktorsku disertaciju s naslovom:
'Semantička segmentacija slika prirodnog krajolika temeljena na dubokom učenju'
. Disertacija je obramjena pred povjerenstvom u sastavu:

1. **Prof. dr. sc. Vladan Papić**, FESB, Sveučilište u Splitu (predsjednik)

2. **Prof. dr. sc. Sven Lončarić**, FER, Sveučilište u Zagrebu

3. **Izv.prof. dr. sc. Saša Mladenović**, PMF, Sveučilište u Splitu

4. **Izv. prof. dr.sc. Damir Krstinić**, FESB, Sveučilište u Splitu

5. **Prof. dr. sc. Viktor Sučić**, RITEH, Sveučilište u Rijeci

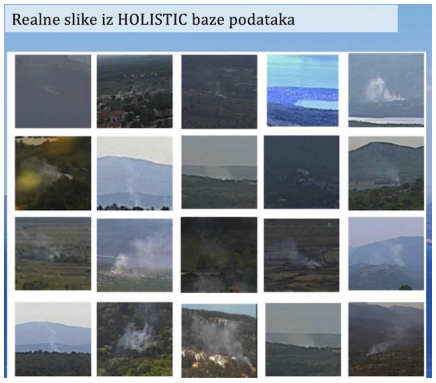




Semantička segmentacija slike značajni zadatak u području računalnog vida i strojnog učenja. Ova doktorska disertacija bavi se razvojem nove metode za semantičku segmentaciju slika prirodnog krajolika. Modifikacijom bazne konvolucijske mreže predložen je novi model za semantičku segmentaciju slika. Pri izradi modela posebna pažnja je posvećena slojevima sažimanja, koji u modelima dubokog učenja predstavljaju veliki problem zbog gubitka podataka, koji je u kasnijim slojevima mreže nemoguće vratiti. Novi model ima segment posebno zadužen za rekonstrukciju izgubljenih podataka, pa je probleme gubitka podataka sveden na minimum u odnosu na postojeće mreže. Predložen je novi završni sloj koji poboljšava rekonstrukciju piksela slike izgubljenih u slojevima sažimanja. Evaluacija modela potvrdila je početne pretpostavke. Drugi dio ove disertacija je razvoj metode za proširenje referentne baze slika prirodnog krajolika i to posebno slika koje sadrže dim požara raslinja u početnim fazama gorenja. Predložen je i evaluiran model za generiranje realističkih sintetičkih slika dima požara raslinja primjenom generičkih suparničkih mreža. Ove su slike uspješno korištene u fazi treniranja mreže za semantičku klasifikaciju slika prirodnog krajolika i to posebno regija koje predstavljaju dim požara raslinja, što će značajno unaprijediti detekciju u automatskim sustavima za rano otkrivanje požara raslinja.

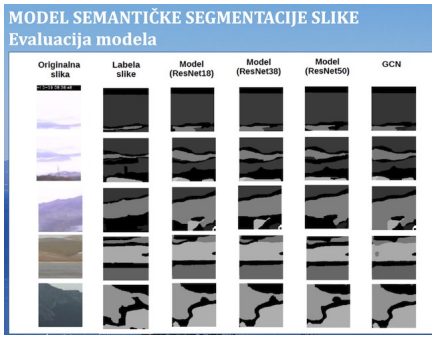
Disertacija je značajan doprinos problematici rane detekcije požara raslinja suvremenim metodama dubokog učenja, a jedan od njenih doprinosa je je razvoj metodologije za proširenje postojeće referentne baze slika prirodnog krajolika prilagođene primjeni kod metoda dubokog učenja korištenjem generičkih suparničkih mreža pri čemu je posebna pažnja posvećena slikama s poluprozirnim regijama dima požara raslinja u nastajanju.

Usporedba realnih slika dima raslinja iz novo formirane baze slika snimljene eksperimentalnim motrilačkim sustavom instaliranim u okviru EU projekta IPA Adriatic HOLISTIC i sintetički generiranih slika dima u okviru istraživanja disertacije:





Usporedba različitih postojećih i novo predloženih modela semantičke segmentacije slika na regije:



U prilogu je prezentaija obrane disertacije (kliknite na sliku):

