SVEUČILIŠTE U SPLITU FAKULTET ELEKTROTEHNIKE, STROJARSTVA I BRODOGRADNJE

POSLIJEDIPLOMSKI STUDIJ ELEKTROTEHNIKA I INFORMACIJSKA TEHNOLOGIJA

KVALIFIKACIJSKI ISPIT

PRIMJENA STROJNOG UČENJA U PROMATRANJU ZEMLJE DALJINSKIM ISTRAŽIVANJIMA

Antonia Ivanda

Split, svibanj 2022.

Sadržaj

1.	Uvod							
2.	Daljinska istraživanja							
	2.1. Rezolucija senzora							
	2.2.	Vrste senzora						
		2.2.1.	Aktivni senzori	6				
		2.2.2.	Pasivni senzori	7				
	2.3.	Satelits	ske misije	8				
	2.4.	Predob	rada satelitskih snimki	11				
		2.4.1.	Atmosferska korekcija	12				
3.	Temeljne tehnike prepoznavanja uzoraka u satelitskim podacima							
	3.1.	Nadzir	ano učenje	16				
	3.2.	Nenad	zirano učenje	19				
	3.3.	Polunadzirano učenje						
4.	Duboko učenje							
	4.1.	1. Neuronske mreže						
	4.2.	2. Konvolucijske neuronske mreže						
		4.2.1.	Arhitektura konvolucijske neuronske mreže	28				
		4.2.2.	Proces obuke konvolucijske neuronske mreže	34				
	4.3.	Dubok	o učenje i daljinska istraživanja	36				
		4.3.1.	Semantička segmentacija	37				
		4.3.2.	Predviđanje točkastih parametara	39				
		4.3.3.	Poboljšanje kvalitete slike	41				
	4.4.	Izazov	i dubokog učenja u daljinskim istraživanjima	42				
5.	Zak	ljučak		44				
LITERATURA								
PC) PIS (OZNAK	KA I KRATICA	55				

1. Uvod

Daljinska istraživanja služe kao veliki izvor informacija koji nam pomaže u boljem razumijevanju Zemljinog sustava i učinkovitom upravljanju njezinim resursima. Porast populacije, iscrpljivanje prirodnih resursa i posljedice klimatskih promjena samo su dio izazova uzrokovanih ljudskim djelovanjem na koje je potrebno usmjeriti određene akcije. Sustavi daljinskog istraživanja sastoje se od senzora dizajniranih za mjerenje, praćenje i predviđanje različitih fizičkih, kemijskih i bioloških aspekata Zemljine površine i atmosfere. Senzori se prema principu rada dijele na aktivne i pasivne, odnosno na senzore kojima je za detektiranje refleksije površine potrebno generirati izvor energije u smjeru ispitivane površine i senzore koji mogu mjeriti reflektiranu ili emitiranu energiju površine dobivenu uz prisutnost vanjskog izvora. Sva mjerenja se odrađuju bez stvarnog kontakta s promatranim objektom, a najčešće se mjeri elektromagnetska energija promatranog objekta. Slike daljinskog istraživanja mogu prenijeti informacije o položaju, veličini i međusobnom odnosu pojedinih objekata, a posebnu prednost imaju kod praćenja promjena tijekom vremena i kod površina koje je teško pratiti drugim sredstvima. Također, ove slike uključuju zračenja elektromagnetskog spektra koje nije vidljivo ljudskom oku, a mogu biti od iznimne važnosti u proučavanju Zemljine površine. Stoga je važno primijeniti adekvatne tehnologije za izdvajanje ovih vrsta informacija koje čovjeku nisu urođene, a mogu sadržavati odnose između značajki koje inače mogu izgledati neovisno. Učinkovita upotreba podataka daljinskog istraživanja zahtijeva analizu, predprocesiranje i interpretaciju kako bi se podaci pretvorili u informacije. Ponekad se za rješavanje specifičnih problema, satelitske slike mogu kombinirati i s drugim geoprostornim podacima, kao što su podaci o tlu ili geološki podaci.

Kako bi se otkrili, klasificirali ili prepoznali različiti uzorci u slikama daljinskog istraživanja koriste se metode strojnog učenja. Algoritmi strojnog učenja korištenjem statističkog pristupa mogu automatski učiti iz podataka i pronaći poveznicu između uzorka i oznake klase. Osim strojnog učenja, u analizi velikih skupova podataka dobivenih daljinskim istraživanjem uspješno se primjenjuje i duboko učenje. Algoritmi dubokog učenja imaju izvanredne izvedbe u usporedbi s nekim tradicionalnim algoritmima učenja, s obzirom da je arhitektura okarakterizirana kao umjetna neuronska mreža inspirirana radom ljudskog mozga. Prednost dubokog učenja u odnosu na tradicionalne algoritme je ta što ne zahtijeva ručno izrađene značajke na temelju znanja istraživača promatrane domene, već se tehnike dubokog učenja oslanjaju na automatsko učenje značajki na višim razinama apstrakcije uz minimalno korištenje unaprijed poznatih značajki. Glavni model dubokog učenja su konvolucijske neuralne mreže koje su nadmašile većinu algoritama u vizualnom prepoznavanju, gdje se ističe njihova sposobnost korištenja dvodimenzionalne strukture ulazne slike. Postoje različite arhitekture konvolucijskih neuralnih mreža, a mnoge od njih su uspješno primijenjene i u području daljinskog istraživanja, kao što su primjerice ResNet, ALexNet, VGG, itd. Arhitekture se općenito konstruiraju u ovisnosti o njihovoj namjeni i dostupnosti resursa, pa se tako broj konvolucijskih slojeva razlikuje za pojedinu arhitekturu.

U ovome radu dan je pregled glavnih aspekata koji se odnose na daljinsko istraživanje i njegovu primjenu. Opisane su različite vrste senzora i rezolucije popularnih satelitskih misija, kao i načini predobrade satelitskih snimki i utjecaj atmosfere na samu kvalitetu podataka daljinskog istraživanja. Nadalje, izdvojene su različite tehnike strojnog učenja koje se koriste u svrhu prepoznavanja uzoraka u satelitskim podacima. Na kraju su opisani glavni principi dubokog učenja, najčešće korištene arhitekture i primjena dubokih neuralnih mreža u proučavanju različitih prirodnih fenomena.

2. Daljinska istraživanja

Daljinska istraživanja (engl. *Remote Sensing*) formalno se opisuju kao stjecanje informacija o Zemljinoj kopnenoj i vodenoj površini putem senzora instaliranih na zrakoplovima ili satelitima koji primaju elektromagnetsku energiju emitiranu ili odbijenu s promatrane površine [1]. Elektromagentsko zračenje je širenje elektromagnetskih valova prostorom, gdje se elektromagnetska energija može odrediti pomoću frekvencije ili valne duljine. Najpoznatiji oblik elektromagnetskog zračenja je vidljiva svjetlost koja se nalazi unutar dometa ljudskog vida. Osim vidljive svjetlosti, koja čini jedan mali, ali važan dio elektromagnetskog spektra, postoje rasponi elektromagnetskog spektra koji zauzimaju puno veće segmente, primjerice spektri gama zračenja (engl. γ -rays), rendgenskog zračenja (engl. *X*-rays), ultraljubičastog zračenja (engl. *Ultraviolet* - *UV*), infracrvenog zračenja (engl. *Infrared* - *IF*), mikrovalnog zračenja (engl. *Microwave*) i radiovalova [2]. Na Slici 2.1 prikazan je shematski izgled elektromagnetskog spektra.



Slika 2.1: Elektromagnetski spektar [3]

Elektromagnetska energija, koju isijava Sunce, putuje kroz vakuum brzinom svjetlosti od $3 * 10^8$ m/s i dolazi u interakciju sa Zemljinom atmosferom i površinom, nakon čega se reflektirano Sunčevo zračenje sa Zemljine površine vraća do satelitskih senzora. Na Slici 2.2 prikazan je put koji elektromagnetski valovi Sunca prođu do senzora satelita. Kada Sunčevo zračenje upadne na površinu Zemlje, ono se može reflektirati od njezine površine, apsorbirati ili prenijeti kroz njezinu površinu, pri čemu vrijedi zakon očuvanja energije [4]:

$$E_I(\lambda) = E_R(\lambda) + E_A(\lambda) + E_T(\lambda)$$
(2.1)

gdje je:

- λ valna duljina elektromagnetskog zračenja,
- *E_I* izvorna upadna energija (engl. *Incident energy*),
- *E_R* reflektirana energija (engl. *Reflected energy*) reflektirano zračenje mjereno senzorom koji se nalazi na početku atmosfere (engl. *TOA - Top of Atmosphere*), a poznato je kao i TOA radijanca (engl. *radiance*). Spektralna refleksija (engl. *spectral reflectance*) koja se koristi kao ključna mjerna jedinica u daljinskom istraživanju, ne mjeri se izravno senzorom nego je definirana kao omjer TOA radijance i upadnog zračenja,
- E_A apsorbirana energija (engl. *Absorbed energy*) energija zračenja se apsorbira ili pretvara u druge oblike energije,
- *E_T* propusna energija (engl. *Transmitted energy*) nastaje kada zračenje prolazi kroz medij bez značajnog slabljenja. Sposobnost medija da prenosi energiju mjeri se kao propustljivost (engl. *transmittance*).

Na upadno Sunčevo zračenje utječe propusnost atmosfere koja ovisi o fizičkim svojstvima plinova i broju suspendiranih čestica. Slabljenje Sunčevog zračenja ovisit će o apsorpciji i raspršivanju Sunčevih zraka s molekulama i česticama u atmosferi, a kao rezultat toga TOA radijanca neće nikad biti jednaka spektralnoj refleksiji, nego će njena vrijednost biti zbroj refleksije od površine, oblaka i raspršenja od molekula zraka i čestica aerosola u atmosferi.



Slika 2.2: Interakcija Sunčeve energije sa Zemljinom površinom [4]

U ovome poglavlju biti će predstavljeni teorijski aspekti daljinskog istraživanja, opisi satelita i njihovih senzora, karakteristike koje nam omogućuju odabir najprikladnijeg senzora u svrhu promatranja i daljinskog ispitivanja Zemlje, kao i utjecaj atmosferske korekcije na kvalitetu podataka.

2.1. Rezolucija senzora

Rezolucija senzora odnosi se na njegovu sposobnost razlikovanja informacija, odnosno kako zabilježiti fine detalje promatranog područja na prepoznatljiv način [5]. Rezolucija senzora odnosi se na sustav kao cjelinu, a ne na njegove pojedinačne komponente (poboljšanje objektiva ne podrazumijeva stjecanje veće fotografske razlučivosti, ako drugi element ograničava razlučivost konačne slike). Koncept rezolucije daljinski očitanih podataka obuhvaća nekoliko aspekata, a to su [2]:

- **Prostorna rezolucija** (engl. *spatial resolution*) predstavlja mjeru kojom se najmanji objekt može razlučiti senzorom. Osim objekta, prostorna rezolucija predstavlja mjeru površine tla snimljene za trenutno vidno polje (engl. *IFOV Instantaneous Field of View*) senzora, kao i mjeru linearne dimenzije na tlu koju predstavlja svaki piksel [6].
- **Spektralna rezolucija** (engl. *spectral resolution*) opisuje broj i širinu spektralnih pojaseva u senzorskom sustavu. Većina senzorskih sustava ima pankromatski pojas, gdje je jedan široki pojas u vidljivom spektru i multispektralni pojas u vidljivo bliskom infracrvenom ili termalnom infracrvenom spektru. Hipersprektralni sustavi imaju bolju sposobnost detekcije s obzirom da sadrže na stotine spektralnih pojaseva u kontinuiranim rasponima [6].
- Vremenska rezolucija (engl. *temporal resolution*) mjera je koja se odnosi na frekvenciju promatranja kojom senzor posjećuje isti dio Zemljine površine. Ovaj ciklus može se predstaviti kao funkcija koja ovisi o orbitalnim karakteristikama satelita (visina, brzina i deklinacija) i vidnom polju senzora. Također, vremenska rezolucija ovisi o atmosferskim uvjetima gdje neki senzori ne mogu detektirati površinu ispod naoblake. Nadalje, ovisi i o ciljevima postavljenima za senzor. Tako primjerice meteorološki sateliti, moraju ažurirati podatke u kratkim vremenskim intervalima od 15 do 30 minuta s obzirom da promatraju vrlo dinamične pojave [7].
- Radiometrijska rezolucija (engl. *radiometric resolution*) odnosi se na osjetljivost senzora, odnosno na njegovu sposobnost mjerenja i razlikovanja elektromagnetske energije koja se predstavlja različitim intezitetima radijacije unutar istog spektralnog pojasa [8]. U digitalnoj slici, radiometrijska rezolucija prikazana je različitim izlaznim brojevima za svaki pojas podataka. Kod slika kvantiziranih sa 8 bita, digitalni brojevi (engl. *DN digital number*) mogu biti u rasponu od 0-255 za svaki piksel, što čini 256 razina inteziteta sive boje koju senzorski sustav može detektirati [6].

2.2. Vrste senzora

Podjela senzora u daljinskom istraživanju općenito se vrši prema principu rada i to na aktivne i pasivne senzore (Slika 2.3). Aktivni senzori mogu osigurati izvor energije, odnosno generirati energetski impuls u smjeru cilja koji se ispituje i detektirati refleksiju promatranog cilja. Za razliku od aktivnih senzora, pasivni senzori mogu mjeriti elektromagnetsko zračenje dobiveno iz vanjskog izvora, energiju reflektiranu od sunčevog zračenja ili emitiranu s Zemljine površine [9]. Postoje različite vrste slikovnih podataka daljinskog istraživanja koje ovise o tipu senzora, primjerice pankromatske, multispektralne, hiperspektralne i SAR slike [10]. U ovom poglavlju opisane su karakteristike nekoliko najčešće korištenih instrumenata kod aktivnih i pasivnih senzora.



Slika 2.3: Vrste senzora: (a) Aktivni senzor (b) Pasivni senzor

2.2.1. Aktivni senzori

Aktivni senzori većinom rade u mikrovalnom dijelu elektromagnetskog spektra, što im omogućava mjerenje refleksije promatranog područja bez utjecaja atmosfere i sunčevog osvjetljenja.

Radar

Radar (engl. *Radio Detection And Ranging*) je najpoznatiji aktivni senzor, koji odašilje signal u rasponu valnih duljina od 0.1 cm do 1m i prima refleksiju povratnog raspršenja promatranog područja. Koeficijent piksela predstavlja povratno raspršenje i raste primanjem intezivnijih signala. Ako povećamo visinu promatranja nekog objekta, za dobivanje adekvatne prostorne rezolucije podrazumijevalo bi se korištenje antene ogromnih proporcija, što je upravo mana ovakvog pristupa. Problem se može riješiti korištenjem virtualne antene koja sintetizira "dužu" antenu [7].

SAR

SAR (engl. *Synthetic Aperture Radar*) je radarski sustav koji ima sintetički otvor blende i sintetizira "dužu" antenu koristeći relativno kretanje prema naprijed kratke antene u smjeru ciljnog područja i Dopplerov efekt [1]. Ovakav sustav može biti instaliran na zrakoplovu ili svemirskoj letjelici. Antena emitira više puta impulse radio valova na različitim valnim duljinama i na taj način formira snop do promatranog područja. Signali koji se vraćaju raspršeni tijekom snimanja nekog područja u određenom vremenskom intervalu, pohranjuju se i naknadno obrađuju kako bi se mogli razlučiti snimljeni elementi i rekonstruirati slika promatranog područja [11].

LiDAR

LiDAR (engl. *Light Detection And Ranging*) senzor dizajniran je za prijenos energije u uskom rasponu frekvencija, gdje koristi primljenu energiju povratno raspršenu za formiranje slike Zemljine površine. Jedna od važnijih funkcija ovog senzora je sposobnost usporedbe karakteristika odaslanih i vraćenih energija. Ovo implicira da LiDAR senzor osim procjene svjetline povratnog raspršenja može mjeriti kutni položaj, promjenu frekvencije i vrijeme reflektiranih impulsa [2].

2.2.2. Pasivni senzori

Pasivni senzori koji se koriste u daljinskom otkrivanju većinom rade u vidljivom, infracrvenom, toplinskom infracrvenom i mikrovalnom dijelu elektromagnetskog spektra [7].

Radiometar

Radiometar (engl. *radiometer*) je senzor koji mjeri elektromagnetsko zračenje s visokom radiometrijskom rezolucijom i to u vidljivom, infracrvenom ili mikrovalnom području elektromagnetskog spektra [6]. Kvantitativno mjeri intezitet elektromagnetskog zračenja u jednom širokom spektralnom pojasu (*single-band radiometer*) ili u samo nekoliko pojasa (*multiband radiometer*) [12].

Hiperspektralni radiometar

Hiperspektralni radiometar (engl. *hyperspectral radiometer*) detektira reflektiranu energiju u stotinama do tisućama kontinuiranih uskih spektralnih pojaseva u vidljivom, bliskom infracrvenom i srednjem infracrvenom dijelu elektromagnetskog spektra [13]. Visoka spektralna rezolucija senzora omogućava razlikovanje detalja proučavanih objekata nekog područja. To se postiže na temelju spektralnog odgovora promatranih objekata u svakom od uskih pojasa elektromagnetskog spektra [14].

Spektrometar

Spektrometar (engl. *spectrometer*) je senzor koji služi za otkrivanje, mjerenje i analizu spektralnog sadržaja upadnog elektromagnetskog zračenja [14]. Mjeri radijancu u mnogim uskim spektralnim pojasevima u vidljivom dijelu elektromagnetskog spektra pa sve do kratkovalnog infracrvenog (engl. *SWIR - Short-wave infrared*) dijela elektromagnetskog spektra. Ovaj senzor karakterizira visoka spektralna, ali niska radiometrijska rezolucija u usporedbi s radiometrom [12].

2.3. Satelitske misije

Satelitske misije sastavljene su od jednog ili više satelita koji se lansiraju u svemir raketama i mogu kružiti oko Zemlje od 5 do 12 godina u unaprijed definiranoj orbiti [12]. Uobičajeni kritični zahtjevi koje bi svaka satelitska misija trebala ispuniti su: pokrivenost ili vrijeme odgovora, rezolucija, osjetljivost i životni vijek u orbiti. Pokrivenost satelitske misije odnosi se primjerice na broj raspoređenih satelita, komunikacijsku arhitekturu, vidno polje korisnog terena i nadmorsku visinu. Rezolucija ovisi o veličini instrumenta, nadmorskoj visini i kontroli položaja. Osjetljivost se odnosi na veličinu nosivosti, kompleksnost, obradu i termičku kontrolu. Životni vijek satelitske misije u orbiti ovisi o težini, odabiru komponenti, proračunu snage i pogona [15].

Trenutno postoji više od 2500 aktivnih satelita u Zemljinoj orbiti prema podacima iz listopada 2020. godine s različitim primjenama kao što su promatranje, daljinsko istraživanje, telekomunikacija i navigacija [16]. S obzirom na navedeni broj aktivnih satelita u Zemljinoj orbiti u ovome radu dan je pregled samo onih satelita koji su od interesa za budući istraživački rad i čiji su podaci javno dosupni. ESA (engl. *European Space Agency*) je u okviru programa ESA Copernicus razvila "obitelj" satelita pod nazivom Sentinel, a sastoji od ukupno sedam satelitskih misija koje nose radarske i multispektralne instrumente za snimanje i praćenje kopna, oceana i atmosfere [17]. U ovome poglavlju biti će opisani teorijski aspekti radarske satelitske misije Sentinel-1 i dvije multispektralne satelitske misije Sentinel-2 i Sentinel-3.

Sentinel-1 nosi radar sa sintetičkim otvorom (SAR) koji pripada skupini aktivnih senzora. Ovaj senzor osjetljiv je na valjne duljine u C-pojasu (engl. *C-band*) elektromagnetskog spektra. Prednost radara je sposobnost daljinskog istraživanja i promatranja bez obzira na atmosferske uvjete, jer mikrovalovi prolaze kroz maglu, kišu i oblake [18].

Sentinel-2 misija za snimanje Zemljine površine koristi instrument MSI (engl. *Multispec-tral Imager*) koji je postavljen na dva identična satelita Sentinel-2A i Sentinel-2B. Navedeni sateliti nalaze se u istoj Sunčevoj sinkronoj orbiti, ali na dijametralno suprotnim stranama, što osigurava vrijeme ponovnog posjeta od pet dana na području ekvatora. Satelitski podaci Sentinel-2 misije mogu se iskoristiti u svrhu praćenja šuma i vegetacije, upravljanje vodama, upravljanje rizicima (poplave i šumski požari), urbano kartiranje i slično [19, 20].

Sentinel-3 misija koristi više instrumenata za globalno praćenje okoliša, od kojih su istaknuti OLCI (engl. *Ocean and Land Colour Imager*) i SLSTR (engl. *Sea and Land Surface Temperature Radiometer*). OLCI je osjetljivi optički uređaj koji se sastoji od velikog broja spektralnih kanala i dizajniran je za snimanje boja oceana i kopnene površine. SLSTR instrument mjeri površinsku temperaturu oceana, kopna i leda. Misija predviđa niz satelita, gdje su trenutno aktivna dva identična satelita Sentinel-3A i Sentinel-3B koji se nalaze u istoj orbiti s faznim kašnjenjem od 180° [21].

Envisat misija razvijena je od strane ESA-e i bila je operativna od ožujka 2002. godine pa sve do travnja 2012 godine. Sastojala se od devet instrumenata za promatranje i prikupljanje informacija o Zemlji (kopno, voda, led i atmosfera) [22]. U ovome radu istaknut je instrument MERIS (engl. *Medium Reslution Imaging Spectrometer*) na platformi Envisata koji je služio za promatranje oceanske biologije i kvalitete morske vode na temelju boje vode. MERIS instrument mjeri reflektirano sunčevo zračenje u 15 spektralnih pojaseva u vidljivom (engl. *VIS - visible*) i bliskom infracrvenom dijelu spektra (engl. *NIR - near-infrared*) [23].

PROBA-V autonomni satelit pripada seriji minisatelita PROBA implementirane od strane ESA-e. Misija je bila aktivna od svibnja 2013. godine pa sve do kraja lipnja 2020. godine, kada ju je ESA zbog dostupnosti podataka Sentinel-3 satelita odlučila završiti [24]. Zada-tak PROBA-V satelita bilo je globalno promatranje rasta vegetacije, razlikovanje različitih tipova zemljišta i biljnih vrsti. Dostupnost podataka bila je skoro svakodnevno (osima na ekvatoru gdje je pokrivenost bila zajamčena svako dva dana). Podaci su mjereni u četiri pojasa umjerene spektralne i visoke radiometrijske rezolucije [25].

SPOT 6 i 7 komercijalni su sateliti za snimanje Zemlje u vlasništvu tvrtke Airbus Defense and Space koja ima ugovor sa ESA-om za distribuciju podatkovnih proizvoda dobivenih iz misija [26, 27]. Sateliti su identični i svaki od njih na sebi ima dva identična NAOMI (engl. *New Astrosat Optical Modular Instrument*) instrumenta gdje multispektralne snimke sadrže spektralne pojaseve u plavom, zelenom, crvenom i bliskom infracrvenom rasponu elektromagnetskog spektra [28]. SPOT satelitske snimke nalaze svoju primjenu u poljoprivredi, šumarstvu, geologiji, kartografiji i regionalnom planiranju.

Landsat-8 satelit razvijen je u suradnji NASA-e i američkog geološkog zavoda (engl. *USGS - U.S. Geological Survey*). Na njemu se nalaze dva instrumenta: OLI (engl. *Operational Land Imager*) i TIRS (engl. *Thermal Infrared Sensor*). OLI senzor snima u devet spektralnih pojaseva koji se nalaze u vidljivom (VIS) i kratkovalnom infracrvenom (SWIR) spektralnom području. Ovaj senzor ima višestruku primjenu, primjerice u otkrivanju cirusnih oblaka, praćenje obalnih aerosola, aktivnih požara i mjerenje čistoće vode. TIRS senzor koristi dva toplinska pojasa u termalnom infracrvenom (engl. *Thermal infrared*) području koji omogućuju prikupljanje temperature Zemljine površine [29].

MODIS (engl. *Moderate Resolution Imaging Spectroradiometer*) glavni je instrument na satelitskim misijama Aqua i Terra mmeđunarodnog programa NASA-e imena EOS - *Earth Observing System*. Osim MODISA, misija Aqua sadrži još pet instrumenata: AIRS (engl.

Atmospheric Infrared Sounder), AMSU-A (engl. Advanced Microwave Sounding Unit), HSB (engl. Humidity Sounder for Brazil), CERES (engl. Clouds and the Earth's Radiant Energy System) i AMSR-E (engl. Advanced Microwave Scanning Radiometer for EOS), dok misija Terra uz MODIS nosi još četiri instrumenta: ASTER (engl. Advanced Spaceborne Thermal Emission and Reflection Radiometer), CERES, MISR (engl. Multi-angle Imaging SpectroRadiometer) i MOPITT (engl. Measurements of Pollution in the Troposphere). Instrument MODIS dizajniran je za praćenje brojnih aspekata Zemljine atmosfere, kopna i oceana. Ukupno ima 36 spektralnih pojaseva u vidljivom, bliskom infracrvenom, srednje infracrvenom (engl. MIR - middle-infrared) i termalnom dijelu elektromagnetskog spektra. Razlika između Aqua MODIS i Terra MODIS podataka je vrijeme prikupljanja, gdje Aqua kruži popodnevnom orbitom, a Terra kruži jutarnjom orbitom, što omogućuje prikupljanje podataka sa poludnevnom vremenskom rezolucijom koristeći obe misije [30–32].

U Tablici 2.1 izdvojene su glavne karakteristike prethodno opisanih satelita.

Satelitska misija	Organizacija	Senzor/ Instrument	Prostorna rezolucija	Vremenska rezolucija (dan)	Spektralni pojasevi
Sentinel-1	ESA	SAR	10-40m	<= 6	C-Band
Sentinel-2	ESA	MSI	10-60m	<= 5	13 (VIS. NIR, SWIR)
Sentinel-3	ESA	OLCI, SLSTR	300m, 500m i 1km	< 2, < 4	21 (VIS, NIR), 11 (VIS, SWIR, MWIR, TIR)
Envisat	ESA	MERIS	300m	<= 3	15 (VIS, NIR)
PROBA-V	ESA	VGT-P	100m, 333m, i 1km	<= 2	4 (SWIR, Blue, Red, NIR)
SPOT 6/7	Airbus	NAOMI	1.5m i 8m	dvaput dnevno	5 (PAN, RGB, NIR)
Landsat-8	NASA/ USGS	OLI, TIRS	15m, 30m, 100m	16	11 (VIS, NIR, SWIR, PAN,TIR)
Aqua MODIS	NASA	AIRS, AMSU-A, CERES, MODIS, HSB i AMSR-E	250m, 500m, i 1km	dnevno	36 (VIS, NIR, SWIR, MWIR, LWIR)
Terra MODIS	NASA	ASTER, CERES, MISR, MODIS, i MOPITT	250m, 500m, i 1km	dnevno	36 (VIS, NIR, SWIR, MWIR, LWIR)

Tablica 2.1: Pregled satelita za daljinska istraživanja i njihovih osnovnih parametara

2.4. Predobrada satelitskih snimki

Većina podataka koja se detektira daljinskim ispitivanjem Zemlje treba proći kroz osnovnu obradu, koja se vrši na slikama od trenutka kada su primljene na Zemlju do trenutka kada ih korisnik učita u svoje računalo i postanu upotrebljivi. U kontekstu digitalne analize podataka daljinskog istraživanja uglavnom se provode dvije operacije predobrade slike koje uključuju 1) radiometrijsku i 2) geometrijsku obradu slike. Radiometrijska obrada je proces koji pre-tvara snimljene napone senzora ili digitalne brojeve (engl. *DN - digital numbers*) u apsolutnu ljestvicu radijance ili refleksije. Navedena obrada prilagođava vrijednosti radijance slike na koje utječu kvarovi senzora ili atmosferska degradacija. Primjerice, ako promatramo vrijednost digitalne radijance koja iznosi "62", tada ona može biti dijelom rezultat površinske refleksije koja iznosi "50", a dijelom rezultat atmosferskog raspršenja koji iznosi "12". Kako bi se postigla dosljedna i točna mjerenja koja se mogu koristiti u otkrivanju klimatskih i okolišnih promjena, potrebno je DN-ove transformirati u ispravne površinske radijance.

Geometrijska obrada podrazumijeva pripremu planimetrijski ispravnih verzija slika dobivenih daljinskim ispitivanjem. Nijedna slika dobivena senzorom ne može u potpunosti predstaviti prava svojstva krajolika. Također, mnogi čimbenici kao što su varijacije u visini platforme, položaj, brzina, rotacija i zakrivljenost Zemlje mogu iskriviti geometrijska svojstva podataka. Neka od navedenih iskrivljenja su sustavna i mogu se ispraviti analizom karakteristika senzora ili platforme, dok su druga nasumična i moraju se ispraviti korištenjem zemaljskih kontrolnih točaka (engl. *GCP - ground control point*). Cilj geometrijske obrade je da se slike dobivene daljinskim ispitivanjem podudaraju sa drugim slikama i kartama kako bi postale adekvatne za mjerenje udaljenosti i površine [2,6].

Većina podataka daljinskog ispitivanja zahtijeva barem minimalnu obradu prije nego što postanu upotrebljivi. Razni pružatelji podataka usvojili su zajednički skup razina (engl. *le-vel*) obrade kako bi opisali vrstu obrade slika i omogućili korisnicima lakši odabir prikladne razine za njihov projekt. Razine obrade su hijerarhijske, što znači da podaci više razine započinju s obradom uključenom u slike prethodne razine i dodaju im druge značajke. Prema autoru [33] postoji sedam razina, odnosno *levela* obrade slikovnih podataka, a to su:

- Level 0 predstavlja neobrađene podatke instrumenta, baš onako kako su prikupljeni na senzoru. S obzirom da je potrebno primijeniti neke osnovne obrade na podatke prije nego što budu upotrebljivi, ovakvi se podaci uglavnom neće distribuirati korisnicima, osim ako korisnik proučava senzorski uređaj, a ne nužno značajke Zemlje.
- Level 1A predstavlja podatke nad kojima je primijenjena radiometrijska korekcija i uklonjene varijacije detektora unutar senzora. Podaci su neobrađeni i prikazani u punoj razlučivosti, vremenski referencirani i označeni pomoćnim informacijama koje sadržavaju radiometrijske i geometrijske koeficijente kalibracije. Dodatne informacije se mogu koristiti za pretvaranje vrijednosti piksela u stvarna mjerenja zračenja (engl.

irradiance) koja predstavljaju količinu svjetlosti što dolazi do određene točke iz svih mogućih smjerova.

- Level 1B predstavlja slike nad kojima su primijenjene korekcije nad varijacijama kao što su izobličenja u geometriji slike koja su nastala pogrešnim poravnanjem linije skeniranja ili neujednačenim veličinama piksela. Primjenjene korekcije poboljšavaju geometrijsku kvalitetu slike koja je vrlo poželjna za njihovu daljnju upotrebu i obradu.
- Level 2A predstavlja poboljšane verzije slika razine 1B koje su sustavno mapirane u standardnu kartografsku projekciju karte na temelju predviđanja gdje se nalazio satelit kad je slika snimljena. Kod nekih satelitskih podataka kao što su primjerice slike Sentinel-2 satelita, ova razina obrade uključuje još klasifikaciju scene i atmosfersku korekciju slike.
- Level 2B predstavlja precizno georeferencirane slike, koje prolaze kroz proces geometrijske korekcije ili ispravljanja slike, analitičar slike pozicionira sliku na postojeću osnovnu kartu odabirom parova dobro definiranih GCP točaka sa promatrane slike i osnovne karte. Točnost položaja slike razine 2B općenito odgovara prostornoj razlučivosti izvornih podataka (npr. 30 m za Landsat slike).
- Level 3A korisno u slučaju slika koje predstavljaju visoki reljef, pa je osim ručnog lociranja GCP točaka potrebno dostaviti digitalni model visine reljefa (engl. *DEM Digital Elevation Model*) kako bi se mogao uzeti u obzir pomak reljefa na različitim visinama. Ovaj proces se općenito naziva ortorektifikacija.
- Level 3B predstavlja slike istih atributa kao scene razine 3A, ali pokrivaju veće područje, odnosno scene koje su spojene u mozaik.

2.4.1. Atmosferska korekcija

Svaki senzor koji promatra Zemljinu površinu u području vidljivog ili blisko vidljivog dijela elektromagnetskog spektra zabilježit će dvije vrste radijance. Radijanca koja predstavlja Zemljinu površinu i koja je od interesa u sklopu daljinskog ispitivanja često je pomiješana sa radijancom same atmosfere. Stoga je potrebno razdvojiti ove dvije komponente prilikom analize slike, kako atmosfersko raspršenje ne bi imalo utjecaj na ispitivanje promatrane površine. U fokusu su nam slike snimljene u vidljivom i bliskom infracrvenom području spektra, s obzirom da slike prikupljene radarom nisu podložne značajnom utjecaju oblaka, oborina i drugih atmosferskih uvjeta. Oblaci u atmosferi blokiraju informacije o Zemljinoj površini, pa se koriste razne metode za njihovu detekciju i pripadnih im sjena. Uglavnom se koriste metoda praga, model atmosferskog zračenja i razne statističke metode tvoreći masku oblaka promatranog područja. Osim oblaka, na kvalitetu optičkih slika utječu aerosol i vođena para koji se raspršuju i apsorbiraju zračenje reflektirano od površine. Raspodjela aerosola uglavnom utječe na kratkovalne signale, dok vodena para utječe na bliske infracrvene signale. Prema autorima [34] atmosferska korekcija se uglavnom sastoji od dva dijela, a to je 1) procjena atmosferskih parametara i 2) pronalaženje površinske refleksije. Na Slici 2.4 prikazana je atmosferska korekcija GF-1 WFV satelitske slike.



Slika 2.4: Atmosferska korekcija GF-1 WFV satelitske slike, lijevo je prikazana slika prije, a desno poslije atmosferske korekcije [34]

Mnogi algoritmi atmosferske korekcije napravljeni su za točno određeni satelit, pa se tako primjerice procesor Sen2Cor ravijen od strane ESA-e koristi za atmosfersku korekciju Sentinel-2 satelitskih slika. Cilj Sen2Cor procesora je ispraviti Sentinel-2 Level-1C Topof-Atmosphere (TOA) proizvode od učinaka atmosfere kako bi se dobio Level-2A Bottomof-Atmosphere (BOA) proizvod. U svrhu detektiranja oblaka Sen2Cor koristi SCL (engl. Scene Classification) modul koji za svaki piksel koristi niz pragova spektralne refleksije, omjera i indeksa kao što je NDSI (engl. Normalized Difference Snow Index) i NDVI (engl. Normalized Difference Vegetation Index), kao i sve spektralne pojaseve osim B06, B07 i B09. Sen2Cor atmosfersku korekciju izvodi pomoću skupa tzv. Look-up tablica (LUT) generiranih putem libRadtran biblioteke za proračun sunčevog i toplinskog zračenja u Zemljinoj atmosferi [35]. Postoje procesori atmosferske korekcije koji su namijenjeni za korekciju slika različitih satelita, pa tako primjerice MAJA procesor (engl. MACCS-ATCOR Joint Algorithm) služi za atmosfersku korekciju slika satelita Formosat-2, Landsat, VENµS i Sentinel-2. MAJA je spektralno-vremenska metoda koja se sastoji od dvije komponente, a to je algoritam MACCS (engl. Multi-sensor Atmospheric Correction and Cloud Screening algorithm) i moduli iz ATCOR programa (engl. Atmospheric and Topographic Correction software). U svrhu otkrivanja niskih oblaka, MAJA procesor provjerava u odnosu na referentnu kompozitnu sliku koja sadrži piksele bez oblaka, jesu li plavi i crveni spektralni pojasevi promatrane slike prešli vrijednost definiranog praga i postoji li niska korelacija refleksija susjednih piksela [36]. Jedan od najpoznatijih procesora u svrhu atmosferske korekcije slika vode u kopnenim i obalnim područjima je C2RCC procesor (engl. *Case 2 Regional CoastColour*). C2RCC algoritam temelji se na nizu neuralnih mreža koje su obučene na simuliranom setu podataka koji sadrži TOA refleksije. Navedeni algoritam generira Case-2 proizvode koji sadrže inherentna optička svojstva, apsorpcije i raspršenja različitih čestica, kao i relevantne optičke koncentracije (pigment fitoplanktona, ukupna suspendirana tvar i žuta tvar). Najčešće se koristi kod slika prikupljenih senzorima Sentinel-3 OLCI, Sentinel-2 MSI, Landsat-8 OLI i MERIS [37].

Osim algoritama koji su napravljeni za ciljani satelit, postoje oni koji su napravljeni ciljano za atmosfersku korekciju satelita koji snimaju u određenom rasponu elektromagnetskog spektra, kao što su MODTRAN, 6S model [38] i FLAASH [39]. MODTRAN (engl. *MODerate resolution atmospheric TRANsmission*) je jedan od poznatijih i široko korištenih algoritama atmosferske korekcije, a dizajniran je za modeliranje atmosferskog širenja u području od ultraljubičastog do infracrvenog dijela elektromagnetskog spektra. MODTRAN rješava jednadžbu prijenosa zračenja (engl. *radiative transfer equation*), odnosno fenomen prijenosa energije u obliku elektromagnetskog zračenja, koji uključuje učinke apsorpcije, emisije i raspršenja molekula i čestica, površinske refleksije i emisije, sunčevo ili mjesečevo osvjetljenje i sfernu refrakciju [40].

Atmosferska korekcija je zasigurno jedna od najvažnijih koraka u predobradi slika dobivenih daljinskim istraživanjem. U ovome poglavlju dan je kratak pregled često korištenih algoritama u svrhu atmosferske korekcije. Važno je naglasiti da još uvijek ne postoji jednoznačan algoritam za sve slike daljinskih istraživanja. Stoga je ovo područje i dalje zanimljiva tema mnogim istraživačima, s obzirom da i najmanji propust u algoritmu može dati pogrešne rezultate, što dovodi do loših performansi algoritama strojnog i dubokog učenja prilikom klasifikacije i detekcije određenih uzoraka u slikama.

3. Temeljne tehnike prepoznavanja uzoraka u satelitskim podacima

Neprestano povećavanje količine podataka dobivenih daljinskim istraživanjima raznolikim skupom senzora zahtijeva brz i efikasan način izvlačenja korisnih informacija iz satelitskih slika, korištenjem adekvatnih tehnika za prepoznavanje uzoraka. Uzorak satelitske slike u kontekstu daljinskog istraživanja predstavljen je kao vektor značajki (engl. *features*) koje opisuju objekt. Objekt može imati jedan piksel ili skup susjednih piksela koji tvore zemljopisnu cjelinu. Značajke mogu predstavljati vrijednosti spektralne refleksije iz optičkih ili infracrvenih slika, vrijednosti radarskog raspršenja (engl. *radar backscatter*), sekundarna mjerenja izvedena iz slika kao što je tekstura ili geografske značajke kao što su nadmorska visina terena, nagib i orijentacija [1]. Svrha prepoznavanja uzoraka je pronaći odnos između uzorka i oznake klase, koje mogu biti poznate ili nepoznate. U slučaju poznatog skupa podataka, odnosno poznate pripadnosti pojedinoj klasi, moguće je navesti sve kategorije prisutne u području proučavanja, dok se u slučaju nepoznatog skupa podataka nazivi i oznake klase dodjeljuju i određuju na temelju znanja istraživača i zemljopisnih karakteristika proučavanog područja. Metode strojnog učenja koje se koriste u svrhu prepoznavanja uzoraka su:

- nadzirano učenje (engl. *supervised learning*) koristi označeni skup podataka. Kod klasifikacije koristi piksele koji su već dodijeljeni klasama u svrhu klasifikacije piksela nepoznatog identiteta, a kod regresije pomoću skupa podataka za treniranje predviđa vrijednost ciljne varijable,
- **nenadzirano učenje** (engl. *unsupervised learning*) koristi neoznačeni skup podataka s ciljem identifikacije i klasifikacije inherentnih skupina piksela unutar satelitskih podataka,
- **polunadzirano učenje** (engl. *semi-supervised learning*) kombinacija je nadziranog i nenadziranog učenja, a u svrhu klasifikacije koristi manji dio označenih podataka i veći dio neoznačenih podataka.

U ovome poglavlju biti će opisane glavne karakteristike i primjene različitih metoda nadziranog, nenadziranog i polunadziranog učenja u svrhu analize satelitskih podataka.

3.1. Nadzirano učenje

Tehnike nadziranog učenja uključuju klasifikaciju i regresiju. Nadzirana klasifikacija odrađuje se pod nadzorom analitičara i može se koristiti prilikom rješavanja problema kod multispektralne i hiperspektralne klasifikacije satelitskih podataka. Obično sve nadzirane klasifikacije slijede isti niz postupaka [41]:

- Definiranje područja za treniranje (engl. *training areas*) na kojemu se mogu definirati spektralne karakteristike poznatog identiteta (piksela) koji je homogen u odnosu na informacijsku klasu.
- Kreiranje statističke karakterizacije piksela, tzv. potpisa (engl. *signatures*) koji se nalaze unutar područja za treniranje. Njihova je vrijednost digitalizirana i čine uzorke za treniranje (engl. *training samples*).
- Primjena odgovarajućih klasifikacijskih algoritama u svrhu dodjele informacijskih klasa spektralnim vrijednostima satelitskih slika.

Regresijska analiza ima za cilj modelirati odnos u matematičkom obliku između određenog broja nezavisnih značajki/varijabli i kontinuirane ciljne zavisne varijable. Regresija omogućuje da se kvantitativno izrazi zavisnost (korelacija) između promatranih varijabli. U nastavku je ukratko opisano nekoliko algoritama klasifikacije i regresije, kao i njihova primjena u području daljinskog istraživanja.

Paralelepipedni klasifikator

Paralelepipedni klasifikator (engl. *Parallelepiped Classifier*) implementira se definiranjem podprostora sličnog paralelepipedu za svaku klasu piksela. Za svaku značajku koja opisuje izabrano područje za treniranje definiraju se granice paralelepipeda, koje mogu biti minimalna i maksimalna vrijednost piksela u danoj klasi ili standardne devijacije s obje strane srednje vrijednosti podataka za treniranje za promatranu klasu. Klasifikacija se vrši provjerom pripadnosti piksela u prostoru značajki jednog od paralelepipeda. Mana opisane metode je što se u ponekim situacijama vektor piksela može nalaziti u dva ili više paralelepipeda istovremeno, a je odluku o pripadnosti piksela potrebno donijeti nekom drugom metodom [1,42]. Primjer upotrebe paralelepipednog klasifikatora opisan je u [43] gdje je metoda iskorištena u svrhu mapiranja područja sadnje zimske pšenice na temelju Sentinel-1 SAR satelitskih podataka. Koristeći ovaj klasifikator autori su uspjeli izdvojiti usjeve zimske pšenice za područje ispitavanja gdje je ukupna točnost klasifikacije iznosila 84%. Također, zanimljiv doprinos prikazan je u radu [44] gdje su autori upotrijebili paralelepipedni algoritam i klasifikator Mahalanobisove udaljenosti u svrhu klasifikacije šuma koristeći slike SPOT-5 satelita. Rezultati su pokazali da je paralelepipedna klasifikacija bolja za daljinsko ispitivanje s ukupnom točnošću od 95.4%, dok je klasifikator Mahalanobisove udaljenosti imao ukupnu točnost od 85.97%.

Klasifikator minimalne udaljenosti

Klasifikator minimalne udaljenosti (engl. *Minimum Distance Classifier*) koristi udaljenosti između ulaznih podataka i skupa središnjih vektora u prostoru značajki. Novi ulazni podatak klasificira se pronalaženjem klase koja minimalnu (Euklidsku) udaljenost od ulaznog podatka do središta klastera [45]. Primjerice, u radu [46] autori su koristeći navedeni klasifikator došli do zaključka da primijenjen na ASTER i Landsat-8 slike daje dobre rezultate u svrhu litološkog mapiranja, dok su autori u [47] upotrijebili navedeni klasifikator nad multispektralnim slikama (SPOT-5, SPOT-6, Landsat-7, Landsat-8 i Sentinel-2) u svrhu procjene zemljišnog i vegetacijskog pokrova napuštenih požarno opasnih i ponovno navlaženih trese-tišta.

Klasifikacija maksimalne vjerojatnosti

Klasifikacija maksimalne vjerojatnosti (engl. *Maximum Likelihood Classification*) piksel dodjeljuje klasi uzimajući u obzir njegovu vjerojatnost pripadanja određenoj klasi. Srednja vrijednost i kovarijanca pojedine klase modeliraju se formiranjem normalne distribucije u prostoru značajki koja se poslije koristi za procjenu vjerojatnosti [48]. Navedena klasifikacija zahtijeva intenzivne izračune što je čini snažnom tehnikom klasifikacije u usporedbi s prethodno dvije opisane. Upotreba klasifikacije maksimalne vjerojatnosti može se pronaći primjerice u mapiranju tropskih kopnenih dijelova [49] i urbanih dijelova [50, 51], kao i u praćenju i mapiranju plutajućih vođenih korova na otvorenim vodnim tijelima [52].

Metoda k-najbližih susjeda

Metoda k-najbližih susjeda ili KNN algoritam (engl. *K-Nearest-Neighbor*) jedan je od napoznatijih metoda klasifikacije u prepoznavanju uzoraka na slici. KNN ispituje svaki piksel koji treba klasificirati i njegova se pripadnost klasi identificira pronalaskom k-najbližih susjeda malih udaljenosti između uzoraka u skupu podataka za treniranje algoritma [53]. Ova metoda popularna je u predviđanju šumskih atributa kombiniranjem *in situ* i satelitskih podataka [54, 55]. Osim vegetacije, pokazala se kao efektivna metoda u detektiranju vodnih tijela koristeći podatke senzora različite spektralne i prostorne razlučivosti [56], kao i kod analize podataka u svrhu otkrivanja kvalitete vode za kupanje [57].

Linearna regresija

Linearna regresija (engl. *Linear Regression*) predstavlja najjednostavniju metodu regresije i koristi se za proučavanje linearnog odnosa između ovisne varijable (Y) i jedne nezavisne varijable (X). Model linearne regresije opisuje stvarno mjerenje (zavisna varijabla Y) ravnom linijom koja je definirana jednadžbom:

$$Y_i = a + b * X_i + e_i \tag{3.1}$$

gdje je Y_i ovisna varijabla i X_i nezavisna varijabla. Parametar *a* predstavlja koeficijent konstantne vrijednosti, a na grafu predstavlja odsječak na y-osi. Parametar *b* predstavlja regresijski koeficijent nezavisne varijable, a na grafu označava nagib regresijske linije i daje mjeru doprinosa nezavisne varijable X u objašnjavanju ovisne varijable Y. Varijabla e_i predstavlja pogrešku kao slučajnu varijablu s očekivanom vrijednošću nula.

U radu [58] autori su iskoristili model linearne regresije u svrhu predviđanja nadmorske visine korištenjem Cartosat-1 satelitskih podataka. Koristili su mjerenja nadmorske visine tla kao ovisnu varijablu, a obrađene satelitske podatke Cartosat-1 kao nezavisnu varijablu. Vrijednost koeficijenta determinacije R^2 bila je približno 80% za sva četiri promatrana područja istog tipa terena. Zanimljiva primjena linearne regresije opisana je i u radu [59], gdje je iskorištena u svrhu procjene i identifikacije saliniteta površinske vode korištenjem Sentinel-2 satelitskih podataka i postigla točnost (koeficijent determinacije) od 0,8797.

Multivarijatna linearna regresija

Multivarijatna linearna regresija (engl. *Multivariate Linear Regression*) slična je jednostavnom linearnom modelu linearne regresije, ali ima više neovisnih varijabli ($X_1, X_2, ..., X_n$) koje doprinose ovisnoj varijabli (Y) i za koje je potrebno izračunati vrijednost koeficijenata što čini model složenijim. Primjer korištenja multivarijatne linearne regresije opisan je u [60], gdje su autori koristili navedenu regresiju u svrhu mapiranja organskog ugljika u tlu korištenjem Landsat4-5 Thematic Mapper satelitskih podataka i prikupljenih uzoraka tla. Utvrđeno je da implementirani model multivarijatne linearne regresije postiže 81% točnosti (R^2) u previđanju organskog ugljika na temelju pogodnog ili optimalnog stanja tla.

Polinomijalna regresija

Polinomijalna regresija (engl. *Polynomial Regression*) omogućuje pronalazak nelinearne veze između nezavisnih (X) i ovisnih varijabli (Y), pa je veza prikazana krivuljom višeg reda. Model polinomijalne regresije opisan polinomom n-tog stupnja može se zapisati kao:

$$Y_{i} = \beta_{0} + \beta_{1} * X_{i} + \beta_{2} * X_{i}^{2} + \dots + \beta_{n} * X_{i}^{n} + e_{i}$$
(3.2)

gdje Y_i predstavlja vrijednost ovisne varijable za *i*-ti podatak, X_i vrijednost nezavisne varijable za i-ti podatak, e_i vrijednost greške za *i*-ti podatak i $\beta_0, \beta_1, ..., \beta_n$ regresijski koeficijenti nezavisnih varijabli. Primjer navedene regresije opisan je u radu [61], gdje su autori iskoristili polinomijalnu regresiju trećeg stupnja za određivanje koncentracije klorofila u jezeru na temelju *in situ* podataka kloforila i podataka hiperspektralnog senzora Hyperion. Omjer površinskih refleksija SR467/SR555 (engl. *SR - surface reflectance*) koje predstavljaju plavi i zeleni spektralni pojas pokazao se kao najbolji omjer kod algoritma polinomijalne regresije u svrhu modeliranja koncentracije klorofila s vrijednošću koeficijenta determinacije od 70%.

Ridge regresija

Ridge regresija (RR) je statistička metoda predložena 1970. godine od strane Hoerla i Kennarda [62]. Koncept ove metode temelji se na estimatoru najmanjih kvadrata (engl. *Least Squares Estimator*), koji smanjuje srednju kvadratnu pogrešku i dohvaća stabilnije koeficijente regresije koji nisu ovisni o podskupu trening podataka. Također, navedena metoda izbjegava multikolinearnost, odnosno postojanje gotovo linearnog odnosa između regresijskih, prediktorskih ili ulaznih varijabli, jer može dovesti do netočnih procjena regresijskih koeficijenata. Model ridge regresije može se zapisati kao [63]:

$$\widehat{\gamma}_n^{RR}(k) = (C + kI_p)^{-1} X^T Y, C = X^T X$$
(3.3)

gdje $\hat{\gamma}_n^{RR}$ predstavlja regresijski koeficijent, X predstavlja nezavisnu varijablu u obliku matrice, Y predstavlja vektor rješenja, *k* parametar podešavanja (*k*>0) i *I_p* matricu identiteta. U radu [64] autori su primijenili ridge regresiju u svrhu procjene koncentracije klorofila u listovima kurkume korištenjem slika bespilotne letjelice visoke vremenske i prostorne rezolucije s četiri multispektralna ulazna pojasa. Rezultati su pokazali da navedena regresija postiže srednju kvadratnu pogrešku (engl. *RMSE - Root Mean Squared Error*) od 0,10 mg/g i koeficijent determinacije *R*²=0,7452.

3.2. Nenadzirano učenje

Nenadzirana klasifikacija koristi mehanizme grupiranja u svrhu identificiranja piksela sličnih karakteristika u neoznačene klase, odnosno klastere. Analitičar u praksi na temelju rezultata klasifikacije dodjeljuje smislene oznake klasterima, gdje se kao rezultat dobije dobro klasificirana satelitska slika [65]. Ovakav pristup klasifikacije sam identificira prirodne skupine ili strukture unutar multispektralnih ili hiperspektralnih podataka. Ponekad postojanje prirodnih klasa unutar scene nije intuitivno očigledan, ali se ovim pristupom može pokazati da se satelitske slike obično sastoje od spektralnih klasa koje su ujednačene u različitim spektralnih nim kanalima [2].

Algoritmi nenadziranog učenja općenito su iterativne prirode koji slijede niz postupaka u svrhu klasteriranja podataka [66]:

- Odabir proizvoljne početne vrijednosti koja pokazuje svojstvo klastera i učinak rezultata klasifikacije,
- Klasifikacija svakog piksela u obližnji klaster,
- Izračunavanje srednje vrijednosti svih piksela u jednom klasteru.

Drugi i treći korak ponavlja se dok promjena između iteracija ne postane dovoljno mala. Promjena se može razmatrati postotkom promjene piksela od jedne iteracije do druge ili izračunom udaljenosti između srednjih vrijednosti vektora klastera tijekom iteracija.

Algoritam k-srednjih vrijednosti

Algoritam k-srednjih vrijednosti (engl. *K-means algorithm*) optimalno grupira piksele minimiziranjem varijance piksela unutar definiranog broja klastera. Algoritam je posebno prilagođen za postizanje optimalnog grupiranja sličnih piksela tako da dodijeljene varijance svakog klastera na najbolji način objašnjavaju ukupnu varijancu svih piksela smanjujući varijabilnost unutar klastera [67]. Najraširenija upotreba ovog algoritma je u metodama zasnovanim na modelu BoVW (engl. *Bag of Visual Words*), gdje se tzv. vizualni rječnici generiraju izvođenjem grupiranja k-srednjih vrijednosti na skupu lokalnih značajki u svrhu klasifikacije scena za korištenje zemljišta [68,69]. Primjenu algoritma k-srednjih vrijednosti možemo pronaći i u morskom okolišu, primjerice kod otkrivanja izlijevanja nafte koristeći radarske [70] ili optičke [71] satelitske slike, kao i kod klasifikacije boje morskog dna u plitkim oligotrofnim vodama [67].

Algoritam ISODATA

Algoritam ISODATA (engl. *Iterative Self Organizing Data*) je proširenje K-means algoritma gdje automatski odabire broj klastera uz zadane parametere sa pretpostavkom da svaka klasa poštuje multivarijantnu normalnu distribuciju. Koristeći iterativne procese, dok promjena između iteracija ne postane dovoljno malena, dodjeljuje proizvoljna središta klasterima i računa njihove srednje vrijednosti i kovarijance. Piksel je predstavljen vektorom spektralnih vrijednosti i uspoređen sa srednjom vrijednosti pojedinog klastera. Dodjela piksela klasteru vrši se na temelju računanja Euklidske udaljenosti, koja treba biti što manja do izračunate srednje vrijednosti klastera [41,72]. Autori u [73] primijenili su ISODATA algoritam u svrhu detekcije promjene obalne linije, dok su autori u [74] navedeni algoritam primijenili u svrhu otkrivanja područja oštećenih šumskim požarom.

Fuzzy klasifikator

Fuzzy klasifikator za razliku od prethodno opisanih algoritama dopušta djelomično, odnosno neizrazito članstvo (engl. *fuzzy membership*) piksela pojedinom klasteru kada u prostoru značajki nema oštrih granica među klasterima [75]. Piksel može poprimiti ocjenu članstva u vrijednosti od 0 do 1, gdje vrijednost 0 označava da piksel nije član klastera, vrijednost 1 da je piksel punopravni član klastera, a vrijednosti između 0 i 1 označavaju nejasnu particiju u jednom ili više drugih klastera [76]. Primjer korištenja fuzzy klasifikatora prikazan je u [77] gdje su autori koristeći SAR satelitske slike klasificirali plutajuće splave na moru koje služe za uzgoj školjaka, a mogu vršiti pritisak na okoliš i rezultirati njegovim onečišćenjima. U radu [78] opisan je Fuzzy C-Means (FCM) algoritam i njegova primjena nad satelitskim podacima. Pokazao se kao koristan algoritam za praćenje utjecaja oceanskih čimbenika kao što su morski vjetrovi, valovi, struje i temperatura prilikom vojnih akcija.

3.3. Polunadzirano učenje

Polunadzirano učenje u svrhu izgradnje boljih klasifikatora koristi velike količine neoznačenih podataka zajedno s označenim podacima. Cilj polunadziranog učenja je iskoristiti strukturne informacije neoznačenih uzoraka u prostoru značajki kako bi se implementirao bolji model distribucije klasa. U svrhu klasifikacije polunadzirano učenje pokušava pronaći što točnije pravilo klasifikacije, a ne samo koristeći informacije iz označenih uzorka. Metode polunadziranog učenja mogu se grupirati u sljedeće kategorije [79, 80]:

- self-training metoda klasifikator koristi metodu nadziranog učenja više puta tijekom osposobljavanja i prvo se trenira s malom količinom označenih podataka. Svakom sljedećom iteracijom, dio neoznačenih podataka zajedno s njihovim predviđenim oznakama dodaje se skupu za obuku. Klasifikator se ponovno osposobljava koristeći dodatne označene uzorke i postupak se ponavlja. Self-training metode mogu koristiti bilo koji nadzirani klasifikator.
- co-training metoda temelji se na pretpostavkama da značajke mogu biti podijeljene u dva skupa koja su uvjetno neovisna s obzirom na klasu, a svaki skup podznačajki je dovoljan za treniranje dobrog klasifikatora. Prvo se dva odvojena klasifikatora treniraju na označenim podacima na dva skupa podznačajki. Zatim svaki klasifikator klasificira neoznačene uzorke i 'podučava' drugi klasifikator na način da mu daje najpouzdanije neobilježene uzorke s njihovim predviđenim oznakama. Svaki se klasifikator ponovno obučava s dodatnim uzorcima za obuku koje daje drugi klasifikator, a proces se ponavlja.
- generativni modeli (engl. *Generative models*) temelje se na procjeni zajedničke vjerojatnosti $P(x, y|\delta)$ uz pretpostavku modela za podatke kao što je primjerice *Gaussian*

mixture model. Varijable *x*, *y* predstavljaju promatrane točke slike, gdje je svaka točka predstavljena latitudom i longitudom u tzv. prostoru uzoraka (engl. *sample space*). U vektoru δ sadržani su parametri modela, kojeg je potrebno procijeniti promatranjem, a može imati koristi od zajedničkog korištenja označenih i neoznačenih uzoraka. Popularna metoda za procjenu δ vektora je EM algoritam (engl. *Expectation-maximization algorithm*). Konačna klasifikacija provodi se na temelju Bayesovog pravila.

- polunadzirani Support Vector Machine (SVM) modeli tehnike polunadziranog učenja posebno razvijene za SVM. Postoje razne inačice SVM modela, ovisno o njihovoj primjeni. Primjerice, transduktivni SVM (TSVM) služi za klasifikaciju teksta, gdje uzima u obzir određeni skup testova i pokušava ih svesti na najmanju moguću mjeru pogreške klasifikacije. Ovo se postiže korištenjem označenih uzoraka za obuku i neoznačenih testnih uzoraka. Granica odluke treba proći u područjima niske gustoće podataka što se postiže dodavanjem dodatnog termina regularizacije na neoznačenim podacima.
- metode temeljene na grafu definiraju graf gdje su čvorovi označeni, a neoznačeni uzorci i veze (koje mogu biti ponderirane) označavaju njihovu sličnost. Ova metoda obično pretpostavlja "glatkoću" oznake preko grafa. Metode temeljene na grafu su neparametarske, diskriminativne i transduktivne prirode.

Navedene metode uspješno su usvojene u studijama koje koriste slike dobivene daljinskim ispitivanjem u svrhu klasifikacije. Primjerice u radu [81] autori su iskoristili polunadziranu *self-training* metodu sastavljenu od dva probabilističla klasifikatora MLR (engl. *Multinomial logistic regression*) i SVM nad hiperspektralnim slikama za klasifikaciju pokrova zemljišta. Također, zanimljiv doprinos je prikazan u radu [82], gdje su autori iskoristili multispketralne slike i polunadziranu metodu temeljenu na grafovima u svrhu klasifikacije urbanih područja i oblaka. Metode polunadziranog učenja mogu poboljšati generalizaciju i stabilnost izgrađenog modela, bez potrebe za kompromisima pri odabiru nadziranog ili nenadziranog učenja. Koristeći oba skupa podataka (označeni i neoznačeni), polunadzirano učenje će zahtijevati manje ljudskog rada i ponekad rezultirati razvojem boljih klasifikatora [83].

4. Duboko učenje

Duboko učenje (engl. *Deep Learning*) je dio umjetne inteligencije i usmjereno je na stvaranje modela dubokih neuronskih mreža koje mogu donositi točne odluke na temelju podataka (engl. *data-driven decisions*). Odluke temeljene na podacima donose se identificiranjem i izdvajanjem uzoraka iz velikih skupova podataka (engl. *Big Data*), koji jednoznačno preslikavaju skupove složenih ulaznih podataka u izlazne podatke koji predstavljaju rezultate dobivene na temelju dobrih odluka. Neuronska mreža dubokog učenja je matematički model koji je inspiriran strukturom ljudskog mozga koji se sastoji od velikog broja živčanih stanica zvanih neuroni. Biološki neuron (Slika 4.1) sastoji se od tijela stanice, skupine vlakana zvanih dendriti i jednog dužeg vlakna zvanog akson. Većinu vremena neuron miruje, gdje prima signale od drugih neurona, a ponekad ih i sam šalje drugim neuronima. Dendriti omogućuju da neuron primi signal, dok akson omogućuje prijenos izlaznog signala. Komunikaciju između dvaju neurona omogućuje spoj koji se zove sinapsa, a povezuje akson kao izvor slanja signala i dendrite (jednog ili više njih) kao mjesto koje prepoznaje signale.

Prvi model jednostavnog umjetnog neurona koji oponaša biološki predložen je od strane McCulloch-a i Pitts-a 1943. godine. Prema navedenim autorima, umjetni neuron može sadržavati jedan ili više binarnih ulaza (binarne on(1)/off(0) vrijednosti) i jedan binarni izlaz, a u svome radu su pokazali da je moguće izgraditi neuronsku mrežu sa opisanim jednostavnim umjetnim neuronima koja može izračunati bilo koju logičku operaciju. S obzirom na ograničenja ovakvog modela, 1958. godine Frank Rosenblatt predložio je novi generaliziraniji model umjetnog neurona koji se zove perceptron. Temelji se na malo drugačijem umjetnom neuronu koji se naziva logička jedinica praga (engl. TLU - threshold logic unit), ili ponekad linearna jedinica praga (engl. LTU - linear threshold unit) [84]. Perceptron je predstavljen matematičkim funkcijama koje koristi za mapiranje ulaza u izlaz kroz dvije faze. Prvo se računaju ponderirane sume ulaznih podataka, a potom se rezultati preslikavaju u aktivacijske vrijednosti neurona, dobivene primjenom aktivacijske funkcije. Postoje razne aktivacijske funkcije, od jednostavnih do složenih, a najčešće su funkcija identiteta (engl. *identity*), praga (engl. threshold), ispravljačka (engl. ReLU - Rectified Linear Unit) i sigmoidna (engl. sigmoid) funkcija [85]. Na Slici 4.2 prikazan je model umjetnog neurona - perceptron, gdje $x_1, x_2, x_3, ..., x_n$ predstavljaju ulazne varijable, $w_{1j}, w_{2j}, w_{3j}, ..., w_{nj}$ predstavljaju sinaptičke pondere (težine ulaznih vrijednosti), \sum označava rezultat sume *n* ulaznih vrijednosti pomnoženih s njihovim odgovarajućim težinama i φ označava aktivacijsku funkciju koja preslikava

vrijednost ulaza, obično u ograničeni raspon od 0 do 1 ili od -1 do 1. Uz aktivacijsku funkciju općenito je prikazan odgovarajući parametar θ_j koji se naziva pristranost (engl. *bias*), a predstavlja slobodan koeficijent koji služi za prilagodbu izlaza aktivacijske vrijednosti neurona o_j . Strelice u neuronskoj mreži predstavljaju veze čiju snagu između dva neurona karakteriziraju vrijednosti težina [86].

U ovome poglavlju biti će opisani osnovni koncepti i arhitekture neuronskih mreža i konvolucijskih neuronskih mreža. Posebna pozornost bit će dana na primjeni dubokog učenja u području daljinskog ispitivanja Zemlje, gdje su algoritmi dubokog učenja u zadnjih desetak godina postigli značajan uspjeh u mnogim zadacima analize slika, uključujući klasifikaciju korištenja zemljišta i zemljišnog pokrivača (engl. *LULC - Land Use and Land Cover*), klasifikaciju scene i detekciju objekata [87].



Slika 4.1: Biološki neuron [88]



Slika 4.2: Umjetni neuron [89]

4.1. Neuronske mreže

Umjetna neuronska mreža (engl. *Artificial Neural Network*) sastoji se od slojeva u kojima su raspodijeljeni neuroni koji predstavljaju jednostavne jedinice ili čvorove koji obrađuju informacije. Slojevi mogu biti ulazni, skriveni i izlazni. Neuroni ulaznog sloja mogu se smatrati kao spremnici vrijednosti ulaznih podataka, jer u njima nema obrade informacija. Broj skrivenih slojeva, zajedno sa izlaznim slojem određuje dubinu mreže. Minimalni broj skrivenih slojeva koji je potreban da se neuronska mreža smatra dubokom je dva.

Postoje dvije glavne arhitekture umjetnih neuronskih mreža koje ovise o vrsti veze između neurona, a to je *feed-forward* i *recurrent* neuralna mreža. Ako ne postoji povratna informacija od izlaza neurona prema ulazima kroz cijelu mrežu, tada kažemo da je to *feed-forward*, odnosna unaprijedna neuralna mreža. U slučaju kada postoji povratna informacija, odnosno sinaptička veza od izlaza prema ulazima, tada se mreža smatra ponavljajućom ili povratnom neuronskom mrežom (engl. *RNN - Recurrent Neural Network ili FNN - Feedback Neural Network*). *Feed-forward* neuralne mreže obično se dijele u dvije kategorije ovisno o broju slojeva, a to su jednoslojne unaprijedne mreže (engl. *single-layer feed-forward networks*) i višeslojne unaprijedne mreže (engl. *multilayer feed-forward networks*) [90].

Jednoslojne unaprijedne mreže (Slika 4.3) s *m* izlaznih neurona u izlaznom sloju (engl. *output layer*) ekvivalentne su *m* neovisnih ulaznih perceptrona u ulaznom sloju (engl. *input layer*), gdje informacija uvijek ide u jednom smjeru, odnosno veza je aciklička. Zbog činjenice da se u ulaznom sloju ne izvodi računanje, taj se sloj ne uzima u obzir i stoga se mreža naziva jednoslojnom [91].



Slika 4.3: Jednoslojna unaprijedna mreža [91]

Za razliku od jednoslojnih unaprijednih mreža, kod višeslojnih unaprijednih mreža, između ulaznog i izlaznog sloja nalazi se jedan ili više skrivenih slojeva (engl. *hidden layers*). Na Slici 4.4 nalazi se primjer linearnog višeslojnog perceptrona (engl. *MLP - multilayer perceptron*) koja ima samo jedan skriveni sloj i može se opisati kao 5-3-2 mreža, s obzirom da ima 5 ulaznih neurona, 3 skrivena neurona i dva izlazna neurona. Svaki sloj sastoji se od čvorova koji su potpuno povezani sa čvorovima u sljedećim slojevima, pa tako čine potpuno povezane mreže (engl. *fully connected networks*). U slučaju da između nekih čvorova nedostaju sinaptičke veze, mreža bi se smatrala djelomično povezanom (engl. *partially connected networks*) [92].



Slika 4.4: Višeslojna unaprijedna mreža 5-3-2 [90]

Feed-forward višeslojne mreže mogu se implementirati zajedno s *backpropagation* algoritmom, koji se sastoji od dvije faze. Prva faza uključuje *feed-forward* prolaz u kojem se signali ulaznog sloja i težine šire prema naprijed gdje se generiraju signali izlaznog sloja. Druga faza predstavlja povratno širenje, gdje se izlazna vrijednost generirana *feed-forward* prolazom i prava vrijednost prosljeđuju u funkciju gubitka i uspoređuju, pri čemu se težine slojeva mreže ažuriraju. U svrhu minimiziranja funkcije gubitka koristi se metoda gradijentnog spusta (engl. *gradient descent*) za svaki izlaz neurona. *Backpropagation* algoritam izvodi se u više epoha, gdje se očekuje da će se signali pogreške smanjiti pri svakoj iteraciji. Procesi *feed-forward* i *backpropagation* ponavljaju se sve dok se ne dostigne maksimalni broj epoha [93]. U arhitekturu *feed-forward* višeslojnih mreža spada i RBF mreža (engl. *Radial Basis Function*), koja ima slične karakteristike kao mreža koja koristi *backpropagation* algoritam, ali obično može trenirati mnogo brže. RBF mreže implementiraju ulazno-izlazno mapiranje koristeći linearnu kombinaciju radijalno simetričnih funkcija [94] i koriste se uglavnom za klasifikaciju. Povratne neuronske mreže ili skraćeno RNN (Slika 4.5) predstavljaju dinamičke sustave i koriste se za izvođenje procesa analize sekvence proizvoljne duljine. RNN je dizajnirana za izdvajanje kontekstualnih podataka definiranjem ovisnosti između različitih vremenskih oznaka, a sastoji se od brojnih uzastopnih ponavljajućih slojeva, gdje se izlazi iz neurona koriste kao povratna informacija neuronima prethodnog sloja. Sposobnost RNN da upravlja vremenskim nizovima omogućuje ponavljajuće skriveno stanje čije aktiviranje u svakom trenutku ovisi o onom iz prethodnog vremena. Funkcija gubitka kod RNN izračunava se za svaki parametar neurona. Glavni algoritmi obuke koji se koriste za RNN je generalizirano delta pravilo (engl. generalized delta rule) i funkcija minimizacije energije (engl. energy *minimization function*) [95]. Problem na koji nailaze povratne neuronske mreže je računanje pogreške, kao i njene propagacije unazad kroz sve slojeve i sva stanja neurona u određenim vremenskim trenucima. Također, kroz sva ponavljanja računaju se i podešavaju težine, što izaziva veliki broj prijelaza i otežava mreži njihovo postavljanje. Zbog navedenog problema, gradijent može postati jako malen što rezultira pojavom nestajanja gradijenta (engl. vanishing gradient) ili prevelik pa se ta pojava zove eksplodirajućim gradijentom (engl. ex*ploding gradient*). Jedno od riješenja navedenih pojava je korištenje jedinica sa dugoročnom memorijom (engl. LSTM - Long short term memory units) ili zatvorene ponavljajuće jedinice (engl. GRU - Gated Reccurent Unit) [96]. Primjeri povratnih neuronskih mreža su Hopfield mreža, LSTM mreža, ART mreža (engl. Adaptive Resonance Theory) i RSOM (engl. Recurrent Self-Organizing Map) [97].



Slika 4.5: Povratna neuronska mreža [95]

4.2. Konvolucijske neuronske mreže

Konvolucijska neuronska mreža (engl. *CNN ili ConvNet - Convolutional Neural Network*) je duboka *feed-forward* neuronska mreža nastala proučavanjem vizualnog korteksa mozga s ciljem obrađivanja i prepoznavanja slika. CNN tehnika razvijena je 1980-ih i 1990-ih godina, ali aktivno je zaživjela u posljednih nekoliko godina zbog povećanja računalne snage i količine dostupnih podataka za obuku. CNN mreže imaju topologiju nalik mreži i specijalizirane su za prepoznavanje slika, koje se mogu smatrati 2-D mrežom piksela. Osim kod vizualne percepcije, uspješno se primjenjuju i u drugim zadacima, kao što je prepoznavanje glasa ili obrada prirodnog jezika (engl. *NLP - Natural Language Processing*), kao i kod vremenski ovisnih podataka koji se mogu smatrati 1-D mrežom koja uzima uzorke u pravilnim vremenskim intervalima. Sam naziv "konvolucijska neuronska mreža" sugerira da ova vrsta mreže koristi matematičku operaciju imena konvolucija, koja je specijalizirana vrsta linearne operacije i koristi se umjesto općeg množenja matrica u barem jednom sloju CNN mreže [98].

4.2.1. Arhitektura konvolucijske neuronske mreže

Konvolucijska neuronska mreža daje bolje rezultate u prepoznavanju slike kada njezina neuronska mreža za izdvajanje značajki slike (engl. *Feature extraction network*) ima više slojeva, odnosno kada je neuronska mreža "dublja", što uvelike utječe na sam proces obuke. Neuronska mreža za izdvajanje značajki sastoji se od velikog broja parova konvolucijskih slojeva (engl. *convolutional layer*) i slojeva sažimanja (engl. *pooling layer*). Osim mreže za izdvajanje značajki ulazne slike, svaka CNN mreža ima neuronsku mrežu koja klasificira sliku (engl. *Classifier network*) na temelju značajki slike i generira izlaz [99]. Na Slici 4.6 nalazi se osnovna arhitektura konvolucijske neuronske mreže. U nastavku će ukratko biti opisani najčešće korišteni slojevi u CNN arhitekturi i standardne arhitekture CNN.



Slika 4.6: Osnovna arhitektura konvolucijske neuronske mreže [99]

Konvolucijski sloj

Konvolucijski sloj generira nove slike koristeći matematičku operaciju konvolucije koje se zovu mape značajki (engl. *feature maps*), a naglašavaju jedinstvene značajke izvorne slike. Ovaj sloj ne koristi težine veza i ponderirani zbroj, kao što je to slučaj kod neuronskih mreža, već koristi konvolucijske filtre ili kernele u svrhu pretvaranja slike u mapu značajki. Filtar u konvolucijskom sloju predstavlja mrežu diskretnih brojeva. Na početku treniranja konvolucijske neuronske mreže težine svakog filtra se uče tijekom treninga, a postupak učenja uključuje nasumičnu inicijalizaciju težine filtara i njihovo podešavanje kroz niz različitih iteracija. Matematičku operaciju konvolucije najlakše je objasniti kroz njenu primjenu. Na Slici 4.7 možemo vidjeti ulaznu mapu značajki, predstavljenu kao matricu od 4x4 piksela i konvolucijski filtar dimenzije 2x2, koji pomnoženi generiraju vrijednosti za izlaznu mapu značajki dimenzije 3x3. Filtar "klizi" po širini i visini ulazne mape značajki i taj se proces ponavlja sve dok filtar ne bude mogao "kliziti" dalje, odnosno sve dok ne dođe do kraja matrice. Primjer izračuna prve vrijednosti izlazne mape značajki na Slici 4.7 pod a) je:

$$(1*2) + (3*0) + (-2*(-1)) + (0*3) = 2 + 2 = 4$$

Može se primijetiti da je konvolucijski filtar manje dimenzije u odnosu na ulaz, koji općenito bude velikih dimenzija i potrebno ga je učinkovito obraditi kroz velike CNN modele [100].



Slika 4.7: Primjena matematičke operacije konvolucije u konvolucijskom sloju mreže [100]

Nelinearni sloj

Nelinarni sloj (engl. *nonlinearity layer*) slijedi odmah nakon sloja konvolucije. U nelinearnom sloju primjenjuje se nelinearna aktivacijska funkcija u svrhu podešavanja i propuštanja određenih izlaznih vrijednosti u sljedeći sloj konvolucijske neuronske mreže. Nelinearna funkcija se može shvatiti kao slekecijski mehanizam koji odlučuje hoće li se neuron aktivirati ili ne s obzirom na sve svoje ulaze. Također, omogućuje neuronskoj mreži da nauči nelinearna preslikavanja nakon težinskih slojeva. Primjeri aktivacijskih funkcija su sigmoidna i tanges koje su dugi niz godina bile najpopularnije nelinearne aktivacijske funkcije, dok je trenutno najpoznatija ispravljačka tzv. ReLU funkcija [101]. Razlozi zbog kojih se ReLU funkcija trenutno najčešće koristi su:

1. ima jednostavniju definiciju funkcije i gradijenta:

$$ReLU(x) = max(0,x)$$

$$\frac{d}{dx}(x) = \{1 \text{ if } x > 0; 0 \text{ otherwise}\}$$
(4.1)

- izbjegava pojavu nestajanja gradijenta prilikom primjene *backpropagation* algoritma, što se događa kod sigmoidne i tanges aktivacijske funkcije, s obzirom da je njihov gradijent vrlo blizu nuli osim u središtu funkcije.
- 3. stvara tzv. rijetku reprezentaciju (engl. *sparse representation*) što znači da je ReLU funkcija sposobna dati potpune nulte vrijednosti za negativne ulaze dok sigmoidne i tangens aktivacijske funkcije uče kako aproksimirati nulti izlaz.

Sloj sažimanja

Sloj sažimanja važan je korak u cilju kontinuiranog smanjivanja dimenzionalnosti mape aktivacijskih značajki, što rezultira manjim brojem parametara i računanjima u mreži. Zadržavanjem samo važnih značajki pomaže kontrolirati problem zvan *overfitting* i skratiti vrijeme potrebno za treniranje mreže. Ovaj sloj omogućava konvolucijskim neuronskim mrežama da u svrhu prepoznavanja uključe različite dimenzije slike, zato jer uspješno prepoznaje zadani objekt čak i kada je njegov oblik iskrivljen ili prisutan pod drugim kutom. Postoje različite vrste slojeva za sažimanje kao što je sažimanje maksimalnom vrijednošću (engl. *max pooling*), prosječno sažimanje (engl. *average pooling*), stohastičko sažimanje (engl. *stohastic pooling*) i prostorno piramidalno sažimanje (engl. *spatial pyramid pooling*).

Operacija sažimanja maksimalnom vrijednošću najpopularnija je od navedenih, a radi na način da iz odabranoga bloka matrice ulaznih vrijednosti bira maksimalnu vrijednost bloka. Slično kao kod sloja konvolucije potrebno je definirati veličinu filtra za sažimanje i njegov korak koji "klizi" preko ulazne mape značajki [102]. Na Slici 4.8 prikazana je operacija



sažimanja maksimalnom vrijednošću ulazne mape značajki dimenzije 4x4 pomoću filtra dimenzije 2x2 s pomakom jedan, koji kao rezultat daju izlaznu mapu značajki dimenzija 3x3.

Slika 4.8: Primjena operacije sažimanja maksimalnom vrijednošću u sloju sažimanja CNN [100]

Potpuno povezani sloj

Često se posljednji dio svake CNN arhitekture sastoji od potpuno povezanih slojeva (engl. *fully connected layers*) koji predstavljaju *feedforward* umjetnu neuronsku mrežu i slijede principe MLP neuronske mreže (Slika 4.4). Neuroni unutar povezanog sloja raspoređeni su na sličan način kao u tradicionalnoj neuronskoj mreži, gdje je svaki neuron unutar sloja povezan sa svakim neuronom iz prethodnog i sljedećeg sloja. Potpuno povezani slojevi kao ulaz koriste mapu značajki dobivenu od završnog konvolucijskog sloja ili od sloja sažimanja. Posljednji sloj potpuno povezanih slojeva služi kao klasifikator CNN arhitekture i generira njezin konačan izlaz. Mana potpuno povezanog sloja je ta što uključuje puno parametara koji zahtijevaju kompleksno računanje u procesu treniranja.

Standardne CNN arhitekture

Proučavanjem i razumijevanjem značajki pojedinih arhitektura kao što je veličina ulaza, dubina i robusnost omogućuje odabir prikladne arhitekture u svrhu rješavanja ciljnog zadatka. U nastavku će biti dani primjeri najčešće korištenih CNN arhitektura poredanih kronološkim redom.

AlexNet (2012) je duboka CNN mreža koja se temelji na najjednostavnijoj CNN arhitekturi LeNet-5. Sastoji se 60 milijuna parametara, 650 tisuća neurona i osam slojeva, od kojih je pet konvolucijskih slojeva, a tri su potpuno povezana sloja. Smatra se prvom arhitekturom koja je iskoristila ispravljačku ReLU funkciju kao aktivacijsku funkciju, kao i koncept *dropout-a* u svrhu bolje generalizacije modela. Na Slici 4.9 prikazana je AlexNet arhitektura, gdje se može vidjeti kako navedena CNN kombinira snagu GPU-a, tako što jedan GPU pokreće dijelove sloja na vrhu slike, dok drugi pokreće dijelove sloja na dnu [103].



Slika 4.9: AlexNet arhitektura [103]

VGG-16 (2014) ili *Visual Geometry Group* arhitektura je predložena od strane Simonyana i Zissermana. VGG-16 mreža sadrži 13 konvolucijskih slojeva i tri potpuno povezana sloja. Prednost ove arhitekture je što koristi filtere manjih dimenzija (2x2 i 3x3) koji su se pokazali slično učinkoviti kao filteri većih dimenzija (5x5 i 7x7), a pritom smanjuju računsku kompleksnost. S druge strane, veliki broj parametara, otprilike 140 milijuna, glavni je nedostatak ove arhitekture [104]. Osim navedene VGG-16 (Slika 4.10) arhitekture postoji njena još dublja varijanta, a to je VGG-19.



Slika 4.10: VGG-16 arhitektura [105]

Inception-v3 (2015) arhitektura sadrži 42 sloja, što je u usporedbi sa VGG-16 puno robusnije, ali i mnogo učinkovitije. Inception-v3 mreža naslijedila je koncept prethodne Inceptionv1 mreže i poboljšala ga korištenjem skupne normalizacije, faktorizacijom konvolucije nxn u asimetrične konvolucije (1×n i n×1) i faktorizacijom konvolucije 5x5 na dvije operacije konvolucije od 3x3. Karakteristika Inception mreža (Slika 4.11) je da su izgrađene pomoću modula/blokova u kojima se nalaze konvolucijski slojevi (otuda i naziv *inception*) [106].



Slika 4.11: Inception-v3 arhitektura [107]

ResNet-50 (2015) mreža napravljena je da riješi problem povećavanja dubine mreže koja utječe na samu njenu izvedbu i performanse modela, a točnost postaje zasićena ili smanjena. Navedeni problem ResNet-50 je riješio korištenjem rezidualnih veza ili "preskakajućih veza" te dviju vrsta mapiranja, gdje je jedno mapiranje identiteta, a drugo rezidualno mapiranje. Na Slici 4.12 prikazana je ResNet-50 arhitektura koja na ulazu izvrši operaciju konvolucije, nakon čega slijede četiri rezidualna bloka i na kraju se izvršava operacija potpuno povezanog sloja u svrhu klasifikacije [108].



Slika 4.12: ResNet-50 arhitektura [108]

Xception (**2016**) je skraćeno od *Extreme Inception* i temelji se na dubinsko odvojivim konvolucijama. Model Xception arhitekture prilagodio je originalni *inception* blok na način da je postao širi i da razmjenjiva samo jednu dimenziju 3x3 bloka, nakon čega slijedi konvolucija 1x1 kako bi se smanjila složenost računalnog procesa. Navedena arhitektura postiže dodatnu učinkovitost učenja i bolju izvedbu korištenjem kanala za razdvajanje i prostornu korespondenciju [109].

4.2.2. Proces obuke konvolucijske neuronske mreže

Proces obuke ili učenja CNN modela sastoji se od sljedećih koraka:

Predobrada i povećanje skupa podataka

Predobrada podataka (engl. *Data Pre-processing*) odnosi se na transformaciju neobrađenog skupa podataka koji uključuje skup za obuku, validaciju i testiranje kako bi skup podataka postao čišći, detaljniji, lakši za učenje i u jednolikom formatu. Transformacija se odvija prije unosa podataka u CNN model čija je izvedba ovisna o dobroj prethodnoj obradi podataka koja može povećati točnost modela. Tehnike koje se najčešće koriste prilikom predobrade podataka su: oduzimanje srednje vrijednosti (engl. *Mean-Subtraction*) i normalizacija podataka (engl. *Normalization*). Metoda oduzimanja srednje vrijednosti svakoj pojedinačnoj podatkovnoj točki ili značajki radi se u svrhu pomicanja podatka u nulto središte, odnosno vrši se nulto centriranje podatka. Matematički se navedena operacija može opisati kao:

$$X' = X - x^* \tag{4.2}$$

$$x^* = \frac{1}{N} \sum_{i=1}^{N} x_i \tag{4.3}$$

gdje N predstavlja veličinu skupa podataka za treniranje, a x^* srednju vrijednost podatka. Metoda normalizacije dijeli svaku dimenziju podatka s njegovom standardnom devijacijom. Operacija se matematički može implementirati kao:

$$X'' = \frac{X'}{\sqrt{\frac{\sum_{i=1}^{N} (x_i - x^*)^2}{N - 1}}}$$
(4.4)

gdje parametri N, X' i x^* imaju isto značenje kao i u jednadžbama 4.2 i 4.3.

Povećanje skupa podataka (engl. *Data Augmentation*) je tehnika koja različitim operacijama i transformacijama nad uzorcima podataka stvara novu verziju ili više novih uzoraka podataka i na taj način proširuje veličinu skupa za obuku CNN modela. Ova tehnika je iznimno korisna kada postoji vrlo ograničena količina podataka za obuku, ali i kada je potrebno provesti regularizaciju CNN modela izbjegavajući problem *overfitting-a*. Neke od operacije koje se koriste prilikom povećanja skupa podataka su: izrezivanje, rotiranje, okretanje, translacija, skaliranje, itd [110].

Inicijalizacija parametara

Inicijalizacija parametara (engl. *Parameter Initialization*) odnosno njihovih težina odvija se na početku procesa obuke CNN, a određuje koliko će brzo CNN konvergirati i s koli-

kom točnošću. Najlakši način inicijalizacije parametara je postavljanje težina svih slojeva na nulu, međutim ova metoda se pokazala neučinkovita jer će izlaz i gradijenti prilikom povratnog širenja kroz mrežu uvijek biti isti, stoga bi ažuriranje svih težina također bilo isto i mreža ne bi naučila nikakve korisne značajke. Kako bi se izbjegao navedeni problem ne inicijaliziraju se težine s istom vrijednošću, već se koriste različite tehnike za nasumično inicijaliziranje težina kao što su: nasumična inicijalizacija (engl. *random initialization*), Xavier inicijalizacija i nenadzirana inicijalizacija prije obuke (engl. *unsupervised pre-training initialization*) [110].

Regularizacija

Overfitting predstavlja glavni problem za CNN modele u svrhu dobivanja generalizacije dobrog ponašanja modela. Generalizacija modela može se postići tako da se algoritam dubokog učenja pravilno prilagodi novom ili prethodno neviđenom ulazu izvučenom iz iste distribucije podataka kao i podaci za obuku modela. Model se smatra *overfitted* kada pokazuje iznimno dobre rezultate na podacima za obuku, ali ne uspijeva postići dobre rezultate na testnim podacima, odnosno neviđenim podacima. Suprotnost navedenom modelu je *underfitted* model koji nije dovoljno dobro istreniran na podacima za obuku. Model koji daje dobre rezultate na podacima za obuku i testnim podacima može se smatrati uravnoteženim modelom (engl. *balanced*) i naziva se *justfitted* model. Navedene tri vrste modela prikazane su na Slici 4.13. Regularizacija pomaže u izbjegavanju *overfitting-a* korištenjem intuitivnih koncepata kao što su isključivanje neurona (engl. *dropout*), isključivanje težina ili veza između neurona (engl. *drop weights*), povećavanje podataka (engl. *data augmentation*) i skupnom normalizacijom (engl. *batch normalization*) [111].



Slika 4.13: Overfitting i underfitting podataka [111]

Optimizacija

CNN model trenira se iterativnim ažuriranjem parametara svih slojeva u mreži, stoga je vrlo važno odabrati dobar algoritam učenja (optimizator) i njegovih poboljšanja (kao što su

AdaDelta, AdaGrad i Momentum) u svrhu poboljšanja samog izlaza modela. Algoritam gradijentnog spusta (engl. *Gradient descent algorithm*) uobičajen je izbor za izvođenje optimizacije u neuronskoj mreži. Kako bi se smanjila pogreška u mreži, parametri modela ažuriraju se u obrnutom smjeru od gradijenta ciljne funkcije u odnosu na parametre i model iterativno traži lokalno optimalno rješenje u svakoj epohi odluke. Prilikom svake iteracije u procesu obuke uspoređuju se željeni i predviđeni izlaz s namjerom minimizacije ciljne funkcije, a pogreška se širi unatrag. Veličina koraka ažuriranja parametara naziva se "brzina učenja" (engl. *learning rate*), a potpuna iteracija ažuriranja parametara cijelog skupa podataka za obuku naziva se "epoha obuke" (engl. *training epoch*). Jedna od najpopularnijih metrika za mjerenje performansi je unakrsna entropija koja postiže vrijednost nula kada su željeni i predviđeni učinak potpuno isti što je i glavni cilj svake optimizacijske tehnike. Ostali algoritmi koji se koriste u svrhu optimizacije CNN modela su *Batch Gradient Descent*, *Stochastic Gradient Descent, Mini-batch Gradient Descent, Momentum* i *Adaptive Moment Estimation (Adam)* [112].

4.3. Duboko učenje i daljinska istraživanja

Podaci daljinskog istraživanja predstavljaju nove izazove za duboko učenje. Proučavanjem Zemlje kao sustava koji se neprestano izmjenjuje moguće je koristeći moderne tehnologije stvarati trajne zapise koji bi mogli pomoći trenutnim, ali i budućim znanstvenim istraživanjima. Primjena algoritama dubokog učenja postala je uvelike raširena u svijetu geoznanosti, a eksperimentalni rezultati potvrđuju izvrsne performanse njihove primjene u analizi velikih podataka daljinskog istraživanja. Unatoč velikom potencijalu, duboko učenje se ne može izravno koristiti u svim zadacima daljinskog istraživanja. Primjerice, hiperspektralne slike sadrže veliki broj spektralnih pojaseva što bi značilo da je potrebno osigurati veliki broj neurona u unaprijed obučenoj mreži kako bi se takve slike mogle analizirati. Osim velikog broja podataka, problem s kojim se znanstvenici susreću kod primjene dubokog učenja u daljinskim istraživanjima jest mali broj označenih uzoraka, kao i primjena unaprijed uvježbane mreže na podatke prikupljene različitim senzorima. U radu [113] autori predlažu opći okvir koji opisuje primjenu svih metoda temeljenih na dubokom učenju za analizu podataka dobivenih daljinskim istraživanjem unatoč njihovim složenim hijerarhijskim strukturama. Opći okvir prikazan je na Slici 4.14, a podijeljen je u tri glavne komponente: pripremljene ulazne podatke, temeljne duboke mreže i očekivane izlazne podatke, gdje je analiza slika daljinskog ispitivanja promatrana iz četiri perspektive: pretprocesiranje slika, klasifikacija na temelju piksela, prepoznavanje cilja i razumijevanje scene. Kvaliteta snimljenih slika nije uvijek zadovoljavajuća zbog utjecaja raznih čimbenika, kao što je ograničenje senzora i utjecaj atmosfere. Kako bi se povećala kvaliteta slike prije naknadnih zadataka klasifikacije i prepoznavanja, koriste se metode temeljene na dubokom učenju u svrhu pretprocesiranja slike. U zadacima prepoznavanja cilja i razumijevanja scene koriste se značajke izvučene iz objekata, kao i sirovi digitalni brojevi piksela (engl. *DN - digital numbers*) izvučeni iz baze podataka koja sadrži slike visokih i niskih rezolucija. Kod klasifikacije temeljene na pikselima tehnike dubokog učenja mogu izdvojiti robusne i apstraktnije prikaze značajki i tako poboljšati točnost klasifikacije.



Slika 4.14: Opći okvir - primjena dubokog učenja nad podacima daljinskog istraživanja [113]

4.3.1. Semantička segmentacija

Duboko učenje kao vrsta strojnog učenja koja je puno kompleksnija i računalno zahtjevnija proučava iste fenomene kao i metode strojnog učenja koje su opisane u Poglavlju 3, ali to radi na puno većoj razini s obzirom da pokušava simulirati rad čovjekova mozga. Zanimljiva primjena dubokog učenja nad slikama visoke rezolucije opisana je u radu [114], gdje su autori dizajnirali novu CNN arhitekturu naziva SAPCNN (engl. Self-Adaptive Pooling CNN) koja može izdvojiti korisne značajke vodenih tijela u složenom urbanom ekosustavu. SAP-CNN arhitektura sastoji se od ulazne slike, dva konvolucijska sloja, dva samoprilagodljiva sloja za sažimanje i dva potpuno povezana sloja. Rezultati su pokazali kako je predložena metoda postigla veću točnost (99,14%) od nekih tradicionalnih pristupa (SVM, NDWI indeks), a kao rezultat generirane su slike visoke razlučivosti izdvojenih vodnih tijela. Osim navedene, mnoge studije su pokazale kako se izdvajanje vodnih tijela može uspješno napraviti korištenjem dubokog učenja. Kombinacijom prostornih i spektralnih informacija na temelju kojih se izdvajaju značajke promatranog područja, duboko učenje može uspješno izbjeći zabunu vodnih tijela sa sjenama, oblacima i različitim obilježjima tla kao što je snijeg i led [115]. Tako su u radu [116] autori predložili metodu dubokog učenja koja se zasniva na modificiranoj strukturi modela Mask R-CNN koja se temelji na podacima i ne zahtijeva prethodno znanje, a korištena je u svrhu prepoznavanja vodnih tijela. Navedena studija koristi slike visoke prostorne rezolucije (HSRRSI), kao i slike satelita Worldview-3 i GaoFen-2 koje uključuju pankromatske i multispektralne slike. Rezultati su pokazali da predložena metoda daje točne rezultate u prepoznavanju vodnih tijela s više izvora i iz različitih vremena, te može učinkovito izbjeći zabunu sa sjenama i drugim obilježjima tla.

Jedna od najčešćih tema istraživanja u području daljinskog ispitivanja je zasigurno klasifikacija scene, kojoj je cilj automatski dodijeliti semantičku oznaku svakom objektu scene. Klasifikacija scene je izazovan zadatak s obzirom da različite vrste scene mogu sadržavati iste vrste objekata ili imati sličan prostorni raspored, primjerice stambena i poslovna područja, što uvelike otežava interpretaciju satelitskih slika. Bitan aspekt prilikom klasifikacije scene je učinkovito odabrati značajke, što može značajno utjecati na krajnju izvedbu odabrane metode. Primjer klasifikacije scene opisan je u radu [117] gdje su autori koristili popularnu metodu dubokog učenja DBF (engl. *Deep Belief Network*), koja formulira problem odabira obilježja kao problem rekonstrukcije značajke, odnosno koliko dobro rekonstruirana značajka može predstaviti izvorni podatak. Svaka scena predstavljena je kao vektor značajki, s obzirom da klasifikacija na razini piksela nije dovoljno informativna za interpretaciju scene visoke rezolucije (Slika 4.15).



Slika 4.15: Razlika između klasifikacija slika: (a) satelitska slika scene, (b) klasifikacija na razini piksela i (c) klasifikacije scene slike na temelju vektora značajki [117]

U navedenom radu, autori su klasificirali ukupno sedam značajki (travnjak, poljoprivredno zemljište, industrijsko područje, rijeke i jezera, šume, stambeno područje i parking) i postigli prosječnu točnost od 77%. Prema rezultatima autora, scena *šume* bila je najviše prepoznatljiva sa točnošću 93.5%, dok je najnižu točnost od 65% postigla klasa koja predstavlja *industrijsko područje* jer nailazi na miješanje sa klasama *parking* i *stambeno područje*, što predstavlja veliki izazov u dubokom učenju jer je potrebno uočiti specifične značajke sličnih klasa. Slično istraživanje proveli su autori u [118], gdje su implementirali model diskriminirajuće DBN mreže za klasifikaciju scena SAR slika visoke rezolucije u četiri klase: vodeno područje, poljoprivredno zemljište, građevinsko područje i šume. Osim navedenih primjera

klasifikacije slika, gdje se jedna slika iz seta slika klasificira u jednu kategoriju scene, velik broj istraživanja je usmjeren na otkrivanje i klasificiranje različitih objekata na jednoj sceni slike. Tako su u radu [119] autori uspjeli detektirati zrakoplove koji predstavljaju veliki izazov u klasifikaciji zbog složenosti pozadine promatrane scene. Set podataka obuhvaćao je slike prikupljene sa Google Earth-a, gdje su u svrhu povećanja obujma i raznolikosti uzoraka primijenili dodatno operaciju rotacije. Zanimljivo je da su u radu autori koristili metodu transfer learning, gdje su iskoristili arhitekturu VGG16 kao osnovnu mrežu za unaprijedno obučavanje modela. Okvir za otkrivanje zrakoplova temeljio se na metodi SSD (engl. Single Shot MultiBox Detector) koja kombinira brzu R-CNN (engl. Faster Region-Based CNN) s konvolucijskom neuronskom mrežom YOLO (engl. You Only Look Once). Predložena metoda za detekciju zrakoplova postigla je prosječnu preciznost od 96,23% na testnom skupu podataka. Problem detekcije zrakoplova na optičkim satelitskim slikama prikazan je i u radu [120], gdje su autori dodatno napravili i detekciju automobila koristeći poboljšanu verziju bazne VGG16 mreže. Zanimljiv pristup u detekciji objekata na slikama opisan je i u radu [121], gdje su autori iznijeli nekoliko izazova s kojima se susreće neuronska mreža FCRNN (engl. Faster region based CNN) u otkrivanju višeklasnih objekata na slikama daljinskog ispitivanja. Autori navode kako se objekti često pojavljuju u vrlo različitim razmjerima na slikama, pa tako na slikama velikih dimenzija objekti budu male veličine, a gustog rasporeda. Također, kao problem navode ručno označavanje slika, kao skupu metodu i malu dostupnost takvih oznaka. Kao rješenje navedenih izazova predlažu metodu koja objedinjuje istovremeno otkrivanje višeklasnih objekata koristeći dvije podmreže za otkrivanje objekata: MS-OPN (engl. Multi-scale object proposal network) za generiranje područja nalik objektu iz nekoliko međuslojeva, čija se receptivna polja podudaraju s različitim razmjerima objekta i AODN (engl. Accurate object detection network) za otkrivanje objekata korištenjem spojenih mapi značajki koje omogućuju malim i gusto zbijenim objektima jači odziv prilikom detekcije.

4.3.2. Predviđanje točkastih parametara

Osim izdvajanja vodnih tijela kao prirodnih cjelina, duboko učenje je naišlo na veliku primjenu u predviđanju koncentracije parametara koja karakteriziraju vodna tijela, koristeći slike daljinskih ispitivanja. Parametri kvalitete vode u praksi se mjere metodom uzorkovanja koja je skupa, ovisna o vremenskim uvjetima, ali i vremenski zahtjevna. Također, takva metoda daje informaciju samo o mjestu uzorkovanja, koje je točkasto i ne može dati odgovor o kvaliteti vode za veće područje proučavanja. Stoga se duboko učenje koristi primjerice u analizi klorofila (Chl-a), koji je jedan od indikatora eutrofikacije vode. U radu [122] autori su koristeći kombinaciju daljinskog istraživanja (Sentinel-2, Landsat i GaoFen-2) i tradicionalnog terenskoga uzorkovanja dizajnirali model na temelju prostorno-vremenske fuzije slika i CNN za računanje koncentracije Chl-a. Rezultati su pokazali da koeficijent determinacije R^2 iznosi 0.803, a nakon dodatne primjene algoritma za korekciju piksela rezultat je poboljšan, pa je koeficijent R^2 postigao iznos 0.879, što prema autorima daje znanstvenu osnovu za brzu dijagnozu eutrofikacije u kopnenim jezerima. Osim u kopnenim vodama, duboko učenje se pokazalo uspješnom metodom kod procjene Chl-a koncentracije u obalnim područjima [123], koja su posebno osjetljiva na eutrofikaciju zbog ljudske aktivnosti. Jedan takav primjer opisan je u radu [124], gdje su autori koristili slike satelita Sentinel-2 u svrhu procjene koncentracije Chl-a za obalno područje Menor u Španjolskoj. Uz parametar Chl-a postoje i drugi pokazatelji kvalitete vode koji također mogu biti procijenjeni korištenjem metoda dubokog učenja, pa se često u znanstvenim člancima mogu pronaći usporedbe sa nekoliko optičkih parametara, kao i njihova korelacija sa neoptičkim parametrima koji utječu na kvalitetu vode. U radu [125] opisana je primjena nove metode dubokog učenja naziva pDNN (engl. Progressively decreasing deep neural network) za procjenu koncentracije plavo-zelenih algi (engl. BGA - blue-green algae), klorofila, fluoroscentne otopljene organske tvari (engl. fDOM - fluorescent dissolved organic matter), otopljenog kisika (engl. DO - dissolved oxygen), specifične vodljivosti (engl. SC - specific conductance) i zamućenosti (engl. turbidity). pDNN je potpuno povezana feedforward neuralna mreža čija se arhitektura sastoji od jednog ulaznog sloja, šest skrivenih slojeva s progresivno opadajućom širinom (broj čvorova obrade) i jednim izlaznim regresijskim slojem. Rezultati su pokazali da model pDNN nadmašuje sljedeće metode strojnog učenja: višestruka linearna regresija, regresija potpornih vektora i regresija za ekstremno učenje. Podaci korišteni u studiji su Sentinel-2 i Landast-8 prostorne razlučivosti 30m, čijom je fuzijom postignuto vrijeme frekvencije učestalosti satelitskih podataka promatranog područja od oko tri dana. Pri analizi satelitskih podataka u obalnim vodama potrebno je uzeti u obzir refleksiju dna i transspektralne procese kao što je fluorescencija zbog visoke koncentracije pigmenta fitoplanktona. Optika obalne vode je izrazito složena, a razni i nepovezani spojevi u vodenom stupcu mogu vlastitim apsorpcijama i raspršenjima utjecati na svjetlosno polje. Zanimljiva primjena DL-a opisana je u [126], gdje autori predlažu višeslojnu perceptronsku neuronsku mrežu (MLP) za pronalaženje optički aktivnih komponenti morske vode kao što su Chl-a, obojena otopljena organska tvar (engl. CDOM - Colored Dissolved Organic Matter) i tvari bez algi (engl. NLP - nonalgal particulate matter). Osim promatranja samo jednog optičkog parametra često se koristi pristup u kojem se pokušavaju dobiti koncentracije parametara koji nisu vidljivi, ali su optički aktivni. Primjerice razina parametra otopljenog kisika u vodi (engl. DO - Dissolved Oxygen) mjeri se na temelju međusobno povezanih optičkih svojstava koji diktiraju potrošnju i oslobađanje kisika u vodi. U radu [127] autori su razvili tri modela dubokog učenja: LSTM, CNN i hibridni CNN-LSTM model u svrhu predviđanja dviju varijabli kvalitete vode: otopljeni kisik (DO) i klorofil-a (Chl-a). Također, razvili su i dva tradicionalna modela strojnog učenja za usporedbu s navedenim DL modelima, a to su regresija vektora podrške (engl. SVR - Support Vector Regression) i stablo odlučivanja (engl. DT - Decision Tree). Za razvoj modela, kao ulazne podatke koristili su vremenske serije fizikalno-kemijskih varijabli

kvalitete vode, a to su: pH vrijednost, oksidacijsko-redukcijski potencijal (eng. *ODR - Oxidation reduction potential*), temperatura vode, električna vodljivost (engl. *EC - Electrical conductivity*), DO i Chl-a. Rezultati su pokazali da je hibridni CNN-LSTM model nadmašio samostalne modele (LSTM, CNN, SVR i DT) u predviđtanju DO i Chl-a, a posebice u koncentracijama DO gdje je uspješno uhvatio i niske i visoke razine koncentracije. Doprinosi sličnih istraživanja koja su koristila duboko učenje i podatke daljinskog ispitivanja u svrhu procjene koncentracije različitih optičkih i neoptičkih parametara kvalitete vode opisana su u radovima [128–130].

4.3.3. Poboljšanje kvalitete slike

Osim kod klasifikacije, detektiranja različitih objekata i izdvajanja karakterističnih parametara na slikama daljinskog istraživanja, duboko učenje naišlo je na primjenu u poboljšavanju same kvalitete slike, kao što je atmosferska korekcija. Pouzdano otkrivanje oblaka smatra se jedinim od kritičnih koraka prethodne obrade slika daljinskog ispitivanja posebice kod optičkih satelita. Većina se metoda temelji na klasificiranju pojedinačnih piksela koje ne uključujući prostorne uzorke često dovode do pogrešne klasifikacije jako reflektirajućih površina, kao što su strukture koje je napravio čovjek ili snijeg/led. U svrhu ublažavanja ovakvog problema mogu se koristiti multi-temporalne metode, koje uvode novi problem a to je potreba za slikom scene bez oblaka kako bi se slike mogle usporediti. Primjer koji opisuje detektiranje oblaka na slici opisan je u radu [131], gdje su autori predložili okvir duboke mreže CDnet (engl. Cloud detection network). CDnet je sastavljen od predtrenirane ResNet-50 mreže za izdvajanje značajki, potom slijedi FPM modul (engl. Feature pyramid module) za izdvajanje globalnih kontekstualnih informacija za prepoznavanje kategorija regija slike i na kraju BP modul (engl. Boundary Refinement) za hvatanje oštrih i detaljnih granica oblaka. Predloženi model je ostvario ukupnu točnost od približno 97% za slike satelita GF-1, Landsat-8 i ZY-3. Još jedna zanimljiva primjena dubokog učenja opisana je u radu [132]. Autori su predstavili model naziva RS-Net (engl. Remote Sensing Network) koji je obučen i evaluiran nad optičkim satelitskim slikama (Landsat-8 BIOME i SPARCS), a baziran je na U-net arhitekturi. RS-Net je pokazao vrhunske performanse, posebice nad područjima s teško prepoznatljivim krajolikom, kao što su oblaci nad snježnim i ledenim područjima.

Zanimljiva primjena dubokog učenja u svrhu atmosferske korekcije obalnih voda opisana je u radu [133]. Autori su koristili višeslojnu unaprijednu neuralnu mrežu u svrhu dobivanja optičke dubine aerosola i refleksije daljinskog senzora (R_{rs}) iz TOA zračenja (L_{rc}). Predložena korekcija pokazuje poboljšanje u odvajanju atmosferskih i morskih uzoraka u usporedbi s drugim algoritmima temeljenim na neuronskim mrežama, kao što je algoritam C2RCC. Također, navedeni algoritam prilagodljiv je postojećim, ali i budućim senzorima za određivanje boje oceana, raspoređenih na raznim platformama.

4.4. Izazovi dubokog učenja u daljinskim istraživanjima

Istraživanja koja povezuju duboko učenje i daljinska ispitivanja smatraju se relativno novim područjem proučavanja, gdje su mnoga pitanja još uvijek ostala neodgovorena. Podaci daljinskog istraživanja predstavljaju izazov, budući da su satelitske slike često multimodalne. Stoga se u raznim aplikacijama i primjenama često koriste zajedno različite vrste slika, kao što su optičke (multispektralne i hiperspektralne) i radarske slike kojima je geometrija i sadržaj potpuno različit. Fuzijom (engl. *fusion*) navedenih slika pokušava se dobiti veći i pouzdaniji skup podataka koji može dovesti do točnih i stabilnih predviđanja i poboljšati konačni rezultat. Fuzija usklađuje komplementarne izvore podataka dobivene asinkrono, gdje su slike u većini slučajeva snimljene iz različitih perspektiva. Primjerice, visoka spektralna rezolucija neophodna je za točnu klasnu diskriminaciju većeg promatranog područja, dok s druge strane za točan opis tekstura i oblika potrebna je visoka prostorna razlučivost. Također, fuzijom podataka postiže se bolja vremenska rezolucija, čime se jamči kontinuirano prikupljanje podataka i pomak s analize pojedinačnih slika na analizu vremenskih serija.

Osim fuzije podataka kojom se povećava skup podataka za treniranje neuralnih mreža, s ciljem što boljeg treniranja istih, pokušava se istražiti i prenosivost (engl. *transfer learning*) već unaprijed istreniranih neuralnih mreža, gdje se značajke iz jedne domene prenose u drugu domenu. Ovaj pristup predstavlja izazov, s obzirom da je većina predtreniranih arhitektura (VGG, ResNet, Inception i sl.) istrenirana na uvriježenim skupovima podataka (ImageNet, CIFAR-10 i sl.) koji uglavnom predstavljaju RGB slike, pa se teško može primijeniti na satelitske slike, koje često pokrivaju veći spektralni pojas. Piksel na slici predstavlja mjeru u prostoru i ovisi o tipu senzora kojom je slika snimljena. Tako se primjerice neke satelitske slike mogu poklapati u spektralnoj rezoluciji, ali im prostorna rezolucija može biti različita. Primjerice, jedan piksel satelita A predstavlja 10x10m u stvarnosti, dok satelita B predstavlja 500x500m, pa se postavlja pitanje kako interpolirati različitosti i stvoriti unificirani set podataka.

U daljinskim istraživanjima moglo bi se reći da je još uvijek najveći problem sama kvaliteta podataka, kao i njihova pouzdanost i dobra interpretacija. Algoritmi dubokog učenja bez pouzdanih podataka neće imati reprezentativnu izvedbu bez primjerenog seta podataka za obuku. Jedan od glavnih utjecaja na kvalitetu podataka je zasigurno atmosferska korekcija, koja je prilično i složena i zahtijeva informacije o atmosferskim uvjetima i svojstvima u trenutku snimanja slike koje obično nisu dostupne, kao i o samom tipu senzora kojim je slika snimljena. Prema trenutnim saznanjima još uvijek nije implementirana univerzalna metoda koja bi otklonila utjecaj atmosfere za različite tipove optičkih satelitskih slika. Konvolucijske neuralne mreže imaju veliki potencijal u daljinskim istraživanjima, iako su zamišljene za 2D ili 3D slike, zbog njihove složene arhitekture moguće ih je prilagoditi za slike složene distribucije s više kanala kao što su satelitske. Pronaći odgovarajuću dubinu neuralnih mreža za podatke daljinskog ispitivanja još uvijek je otvorena tema i predmet istraživanja, gdje korištenje veća dubina mreže može rezultirati većim brojem parametara prilikom učenja što uvelike utječe na vrijeme izvedbe.

Duboko učenje samo po sebi ima problem objašnjivosti algoritama, a to je posebice izraženo u daljinskim istraživanjima gdje se koriste podaci koji su sami po sebi teško objašnjivi čovjeku (spektri izvan raspona vidljivog čovjeku). Zbog toga će razvoj objašnjivih dubokih neuralnih mreža koje rade sa satelitskim snimkama sigurno biti tema mnogih budućih istraživanja.

5. Zaključak

Podaci daljinskog istraživanja nastaju kada instrument na kojemu se nalazi senzor promatra i bilježi elektromagnetsko zračenje koje se emitira ili odbija od promatranog područja. Ponekad se takvi podaci čine apstraktnim zbog njihovih neobičnih rezolucija, a i često predstavljaju spektralne pojaseve koji se nalaze izvan čovjeku vidljivog spektra. Kako bi se učinkovito upotrijebili navedeni podaci, potrebno ih je analizirati, transformirati i interpretirati kako bi podaci postali informacije koje mogu riješiti praktične probleme. Slike daljinskog istraživanja postale su otvoren resurs koji dopire do javnosti, pa tako mnoge zajednice različitih interesa pridonose razvoju modela, obradi podataka i širenju znanja koje je potrebno za korištenje podataka daljinskog istraživanja u praksi. U ovome radu opisane su glavne karakteristike najčešće korištenih aktivnih i pasivnih senzora koje satelitske misije nose na sebi. Na temelju prostorne, spektralne, vremenske i radiometrijske rezolucije koje su jedinstvene za svaki instrument može se donijeti odluka o prikladnosti njegovih podataka za praktičnu primjenu. Prije upotrebe podataka potrebno ih je obraditi, primijeniti atmosfersku korekciju i na taj način povećati pouzdanost podataka prije nego što se nad njima primjeni algoritam strojnog učenja. Kroz ovaj rad opisani su razni algoritmi strojnog učenja koji koriste nadzirano, nenadzirano ili polunadzirano učenja u svrhu prepoznavanja uzoraka u podacima daljinskog istraživanja i njihove klasifikacije. Važno je naglasiti da ne postoji najbolja metoda, već ovisno o području istraživanja i karakteristikama dostupnih podataka potrebno je pronaći prikladnu metodu. Osim standardnih algoritama klasifikacije, kao prirodan slijed nameće se primjena dubokog učenja nad slikama daljinskog ispitivanja koje je postalo popularno u zadnjih nekoliko desetljaća zbog povećanja računalne snage. Duboko učenje pokazalo se kao prikladna metoda u razumijevanju i digitalnoj obradi slika, jer omogućuje veću razinu apstrakcije značajki slike. U ovome radu su opisane najčešće arhitekture i sam princip rada neuronskih mreža i konvolucijskih neuronskih mreža, kao i dosadašnja istraživanja i njihova primjena u području daljinskog istraživanja. Neuronske mreže su osim u pronalasku značajki, segmentaciji slika i detektiranju objekata na slici, pronašle primjenu i u samoj korekciji slika, kao što je atmosferska korekcija koja predstavlja veliki i još uvijek otvoren izazov u području daljinskog istraživanja. Na kraju rada su opisani izazovi i razmatranja koja bi se mogla koristiti kao smjernice za budući rad koji bi mogli biti od iznimne važnosti i ubrzati sam proces u detektiranju različitih promjena Zemlje.

LITERATURA

- [1] P. Mather i B. Tso, *Classification Methods for Remotely Sensed Data (2nd ed.)*, CRC Press, 2016.
- J. B. Campbell i R. H. Wynne, *Introduction to remote sensing, Chapter 2, 10 and 12*, pp. 31–55, 285–286, 339–356, Guilford Press, 2011.
- [3] Casimiro, Maria and Ferreira, Luís and Leal, João and Pereira, and Monteiro, Bernardo, Ionizing Radiation for Preparation and Functionalization of Membranes and Their Biomedical and Environmental Applications, *Membranes*, 9, 163, 12 2019.
- [4] S. Aggarwal, Principles of remote sensing, *Satellite remote sensing and GIS applications in agricultural meteorology*, 23, 2, 23–28, 2004.
- [5] J. E. Estes i D. S. Simonett., Fundamentals of Image Interpretation. Chapter 14 in Manual of Remote Sensing (R. G. Reeves, ed.). Bethesda, pp. 869–1076, American Society of Photogrammetry American Society of Photogrammetry, Falls Church, Virginia, Falls Church, Virginia, 1975.
- [6] S. Liang i J. Wang, Chapter 1 A systematic view of remote sensing, Advanced Remote Sensing (Second Edition), 1–57, Academic, 2020.
- [7] E. Chuvieco i A. Huete, *Fundamentals of Satellite Remote Sensing*, pp. 63–79, Taylor and Francis, 2009.
- [8] K. Ose, T. Corpetti i L. Demagistri, 2 multispectral satellite image processing, N. Baghdadi i M. Zribi, editori, *Optical Remote Sensing of Land Surface*, 57–124, Elsevier, 2016.
- [9] N. Horning, Remote sensing, S. E. Jorgensen, editor, *Encyclopedia of ecology*, 2986–2993, Elsevier, 2008.
- [10] L. Zhu, J. Suomalainen, J. Liu, J. Hyyppä, H. Kaartinen, H. Haggren et al., A review: Remote sensing sensors, *Multi-purposeful application of geospatial data*, 19– 42, 2018.
- [11] F. Li, *Automated Remote Sensing Image Interpretation with Limited Labeled Training Data*, doktorska disertacija, University of Waterloo, 2015.
- [12] K. Tempfli, G. Huurneman, W. Bakker, L. L. Janssen, W. Feringa, A. Gieske, K. Grabmaier, C. Hecker, J. Horn, N. Kerle et al., *Principles of remote sensing: an introductory textbook*, International Institute for Geo-Information Science and Earth Observation, 2009.

- [13] M. J. Badzmierowski, D. S. McCall i G. Evanylo, Using Hyperspectral and Multispectral Indices to Detect Water Stress for an Urban Turfgrass System, *Agronomy*, 9, 8, 2019.
- [14] NASA Official, Passive Sensors, Online Available: https://earthdata.nasa.gov/ learn/remote-sensors/passive-sensors, [Accessed on 14. February 2022.].
- [15] W. J. Larson i J. R. Wertz, Space Mission Analysis and Design: Vol. 8, Space Technology Library (3rd ed.). New York: Springer, 47–72, 1999.
- [16] D. O'Reilly, G. Herdrich i D. F. Kavanagh, Electric propulsion methods for small satellites: A review, *Aerospace*, 8, 1, 2021.
- [17] European Space Agency ESA, The Sentinel missions, Online Available: https://www.esa.int/Applications/Observing_the_Earth/Copernicus/ The_Sentinel_missions, [Accessed on 25. February 2022.].
- [18] D. Radočaj, J. Obhođaš, M. Jurišić i M. Gašparović, Global Open Data Remote Sensing Satellite Missions for Land Monitoring and Conservation: A Review, *Land*, 9, 11, 2020.
- [19] M. Drusch, U. Del Bello, S. Carlier, O. Colin, V. Fernandez, F. Gascon, B. Hoersch, C. Isola, P. Laberinti, P. Martimort et al., Sentinel-2: ESA's optical high-resolution mission for GMES operational services, *Remote sensing of Environment*, 120, 25–36, 2012.
- [20] D. Phiri, M. Simwanda, S. Salekin, V. R. Nyirenda, Y. Murayama i M. Ranagalage, Sentinel-2 data for land cover/use mapping: A review, *Remote Sensing*, 12, 14, 2020.
- [21] C. Donlon, B. Berruti, A. Buongiorno, M.-H. Ferreira, P. Féménias, J. Frerick, P. Goryl, U. Klein, H. Laur, C. Mavrocordatos et al., The global monitoring for environment and security (GMES) sentinel-3 mission, *Remote Sensing of Environment*, 120, 37–57, 2012.
- [22] European Space Agency ESA, About Envisat, Online Available: https://earth.esa.int/eogateway/missions/envisat, [Accessed on 25. February 2022.].
- [23] L. Guanter, M. D. C. González-Sanpedro i J. Moreno, A method for the atmospheric correction of envisat/meris data over land targets, *International Journal of Remote Sensing*, 28, 3-4, 709–728, 2007.
- [24] European Space Agency ESA, About PROBA-V, Online Available: https: //earth.esa.int/eogateway/missions/proba-v, [Accessed on 25. February 2022.].
- [25] W. Dierckx, S. Sterckx, I. Benhadj, S. Livens, G. Duhoux, T. V. Achteren, M. Francois, K. Mellab i G. Saint, PROBA-V mission for global vegetation monitoring: standard products and image quality, *International Journal of Remote Sensing*, 35, 7, 2589–2614, 2014.
- [26] European Space Agency ESA, SPOT-6, Online Available: https://earth.esa. int/eogateway/missions/spot-6, [Accessed on 22. February 2022.].

- [27] European Space Agency ESA, SPOT-7, Online Available: https://earth.esa. int/eogateway/missions/spot-7, [Accessed on 22. February 2022.].
- [28] P. Mhangara, W. Mapurisa i N. Mudau, Comparison of image fusion techniques using satellite pour l'observation de la terre (spot) 6 satellite imagery, *Applied Sciences*, 10, 5, 2020.
- [29] T. R. Loveland i J. R. Irons, Landsat 8: The plans, the reality, and the legacy, *Remote Sensing of Environment*, 185, 1–6, 2016.
- [30] C. Parkinson, Aqua: an Earth-Observing Satellite mission to examine water and other climate variables, *IEEE Transactions on Geoscience and Remote Sensing*, 41, 2, 173– 183, 2003.
- [31] M. Wu, W. Zhang, X. Wang i D. Luo, Application of modis satellite data in monitoring water quality parameters of chaohu lake in china, *Environmental monitoring and assessment*, 148, 1, 255–264, 2009.
- [32] NASA Official: Kurtis Thome, Terra Instruments, Online Available: https://terra.nasa.gov/about/terra-instruments, [Accessed on 24. February 2022.].
- [33] J. M. Piwowar, Getting your imagery at the right level, *Cartouche*, 41, 2001.
- [34] Chapter 4 Atmospheric correction of optical imagery, S. Liang i J. Wang, editori, Advanced Remote Sensing (Second Edition), 131–156, Academic Press, second edition edn., 2020.
- [35] M. Main-Knorn, B. Pflug, J. Louis, V. Debaecker, U. Müller-Wilm i F. Gascon, Sen2Cor for Sentinel-2, 3, 10 2017.
- [36] K. Tarrio, X. Tang, J. G. Masek, M. Claverie, J. Ju, S. Qiu, Z. Zhu i C. E. Woodcock, Comparison of cloud detection algorithms for Sentinel-2 imagery, *Science of Remote Sensing*, 2, 100010, 2020.
- [37] C. Brockmann, R. Doerffer, M. Peters, S. Kerstin, S. Embacher i A. Ruescas, Evolution of the C2RCC neural network for Sentinel 2 and 3 for the retrieval of ocean colour products in normal and extreme optically complex waters, *Living Planet Symposium*, 740, 54, 2016.
- [38] R. T. Wilson, Py6S: A Python interface to the 6S radiative transfer model., *Comput. Geosci.*, 51, 2, 166–171, 2013.
- [39] T. Cooley, G. P. Anderson, G. W. Felde, M. L. Hoke, A. J. Ratkowski, J. H. Chetwynd, J. A. Gardner, S. M. Adler-Golden, M. W. Matthew, A. Berk et al., FLAASH, a MODTRAN4-based atmospheric correction algorithm, its application and validation, *IEEE international geoscience and remote sensing symposium*, 3, 1414–1418, IEEE, 2002.
- [40] A. Berk, P. Conforti, R. Kennett, T. Perkins, F. Hawes i J. van den Bosch, MOD-TRAN® 6: A major upgrade of the MODTRAN® radiative transfer code, 2014 6th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), 1–4, 2014.

- [41] S. A. Kar i V. V. Kelkar, Classification of multispectral satellite images, 2013 International Conference on Advances in Technology and Engineering (ICATE), 1–6, IEEE, 2013.
- [42] R. A. Schowengerdt, *Remote sensing: models and methods for image processing*, Elsevier, 2006.
- [43] Y. Song i J. Wang, Mapping Winter Wheat Planting Area and Monitoring Its Phenology Using Sentinel-1 Backscatter Time Series, *Remote Sensing*, 11, 4, 2019.
- [44] U. Khan, N. Minallah, A. Junaid, K. Gul i N. Ahmad, Parallelepiped and mahalanobis distance based classification for forestry identification in pakistan, 2015 International Conference on Emerging Technologies (ICET), 1–6, 2015.
- [45] Y. Wang i Y. Jiang, A Weighted Minimum Distance Classifier Based on Relative Offset, 2019 IEEE 4th International Conference on Cloud Computing and Big Data Analysis (ICCCBDA), 343–347, 2019.
- [46] M. Pal, T. Rasmussen i A. Porwal, Optimized Lithological Mapping from Multispectral and Hyperspectral Remote Sensing Images Using Fused Multi-Classifiers, *Remote Sensing*, 12, 1, 2020.
- [47] A. Sirin, M. Medvedeva, A. Maslov i A. Vozbrannaya, Assessing the land and vegetation cover of abandoned fire hazardous and rewetted peatlands: Comparing different multispectral satellite data, *Land*, 7, 2, 71, 2018.
- [48] P. S. Sisodia, V. Tiwari i A. Kumar, Analysis of Supervised Maximum Likelihood Classification for remote sensing image, *International Conference on Recent Advances and Innovations in Engineering (ICRAIE-2014)*, 1–4, 2014.
- [49] A. Ahmad i S. Quegan, Analysis of maximum likelihood classification on multispectral data, *Applied Mathematical Sciences*, 6, 129, 6425–6436, 2012.
- [50] V. Mesev, B. Gorte i P. A. Longley, Modified maximum-likelihood classification algorithms and their application to urban remote sensing, *Remote Sensing and Urban Analysis: GISDATA 9*, 62, 2003.
- [51] M. S. Majd, E. Simonetto i L. Polidori, Maximum likelihood classification of highresolution SAR images in urban area, *Trees (trees, small shrubs)*, 4281, 3719, 3719, 1990.
- [52] T. Dube, W. Gumindoga i M. Chawira, Detection of land cover changes around Lake Mutirikwi, Zimbabwe, based on traditional remote sensing image classification techniques, *African Journal of Aquatic Science*, 39, 1, 89–95, 2014.
- [53] C. Bo, H. Lu i D. Wang, Spectral-spatial K-Nearest Neighbor approach for hyperspectral image classification, *Multimedia Tools and Applications*, 77, 9, 10419–10436, 2018.
- [54] S. Thessler, S. Sesnie, Z. S. R. Bendaña, K. Ruokolainen, E. Tomppo i B. Finegan, Using k-nn and discriminant analyses to classify rain forest types in a Landsat TM image over northern Costa Rica, *Remote sensing of environment*, 112, 5, 2485–2494, 2008.

- [55] G. Chirici, M. Mura, D. McInerney, N. Py, E. O. Tomppo, L. T. Waser, D. Travaglini i R. E. McRoberts, A meta-analysis and review of the literature on the k-Nearest Neighbors technique for forestry applications that use remotely sensed data, *Remote Sensing of Environment*, 176, 282–294, 2016.
- [56] A. Paul, D. Tripathi i D. Dutta, Application and comparison of advanced supervised classifiers in extraction of water bodies from remote sensing images, *Sustainable Water Resources Management*, 4, 4, 905–919, 2018.
- [57] A. Senta i L. Šerić, Remote sensing data driven bathing water quality assessment using sentinel-3, *Indonesian journal of electrical engineering and computer science*, 21, 3, 1634–1647, 2021.
- [58] K. Sudalaimuthu i K. Sudalayandi, Development of linear regression model to predict ground elevation from satellite elevation–statistical approach, *AIP Conference Proceedings*, 2112, 020031, AIP Publishing LLC, 2019.
- [59] R. Borovskaya, D. Krivoguz, S. Chernyi, E. Kozhurin, V. Khorosheltseva i E. Zinchenko, Surface Water Salinity Evaluation and Identification for Using Remote Sensing Data and Machine Learning Approach, *Journal of Marine Science and Engineering*, 10, 2, 2022.
- [60] G. S. Bhunia, P. Kumar Shit i H. R. Pourghasemi, Soil organic carbon mapping using remote sensing techniques and multivariate regression model, *Geocarto International*, 34, 2, 215–226, 2019.
- [61] A. I. Flores-Anderson, R. Griffin, M. Dix, C. S. Romero-Oliva, G. Ochaeta, J. Skinner-Alvarado, M. V. Ramirez Moran, B. Hernandez, E. Cherrington, B. Page i F. Barreno, Hyperspectral Satellite Remote Sensing of Water Quality in Lake Atitlán, Guatemala, *Frontiers in Environmental Science*, 8, 2020.
- [62] A. E. Hoerl i R. W. Kennard, Ridge regression: Biased estimation for nonorthogonal problems, *Technometrics*, 12, 1, 55–67, 1970.
- [63] A. Ivanda, L. Šerić, M. Bugarić i M. Braović, Mapping Chlorophyll-a Concentrations in the Kaštela Bay and Brač Channel Using Ridge Regression and Sentinel-2 Satellite Images, *Electronics*, 10, 23, 2021.
- [64] G. Singhal, B. Bansod, L. Mathew, J. Goswami, B. Choudhury i P. Raju, Estimation of leaf chlorophyll concentration in turmeric (Curcuma longa) using high-resolution unmanned aerial vehicle imagery based on kernel ridge regression, *Journal of the Indian Society of Remote Sensing*, 47, 7, 1111–1122, 2019.
- [65] S. Abburu i S. B. Golla, Satellite image classification methods and techniques: A review, *International journal of computer applications*, 119, 8, 2015.
- [66] A. W. Abbas, N. Minallh, N. Ahmad, S. A. R. Abid i M. A. A. Khan, K-Means and ISODATA clustering algorithms for landcover classification using remote sensing, *Sindh University Research Journal-SURJ (Science Series)*, 48, 2, 2016.
- [67] G. Wattelez, C. Dupouy i F. Juillot, Unsupervised Optical Classification of the Seabed Color in Shallow Oligotrophic Waters from Sentinel-2 Images: A Case Study in the Voh-Koné-Pouembout Lagoon (New Caledonia), *Remote Sensing*, 14, 4, 2022.

- [68] G. Cheng, J. Han i X. Lu, Remote sensing image scene classification: Benchmark and state of the art, *Proceedings of the IEEE*, 105, 10, 1865–1883, 2017.
- [69] K. Qi, H. Wu, C. Shen i J. Gong, Land-use scene classification in high-resolution remote sensing images using improved correlatons, *IEEE Geoscience and Remote Sensing Letters*, 12, 12, 2403–2407, 2015.
- [70] J. Xu, X. Pan, B. Jia, X. Wu, P. Liu i B. Li, Oil Spill Detection Using LBP Feature and K-Means Clustering in Shipborne Radar Image, *Journal of Marine Science and Engineering*, 9, 1, 2021.
- [71] P. Ganesan et al., Detection and segmentation of oil slick environment hazards in ocean using modified K-means clustering, *Journal of Chemical and Pharmaceutical Research*, 7, 1, 56–61, 2015.
- [72] S. A. E. Rahman, Hyperspectral Imaging Classification Using ISODATA Algorithm: Big Data Challenge, 2015 Fifth International Conference on e-Learning (econf), 247– 250, 2015.
- [73] N. Shenbagaraj, N. Mani i M. Muthukumar, Isodata classification technique to assess the shoreline changes of Kolachel to Kayalpattanam coast, *Int. J. Eng. Res. Technol*, 3, 4, 2014.
- [74] S.-J. Lee i Y.-W. Lee, Detection of wildfire-damaged areas using Kompsat-3 image: A case of the 2019 Unbong Mountain fire in Busan, South Korea, *Korean Journal of Remote Sensing*, 36, 1, 29–39, 2020.
- [75] G. Bilgin, S. Erturk i T. Yildirim, Unsupervised classification of hyperspectral-image data using fuzzy approaches that spatially exploit membership relations, *IEEE Geoscience and Remote Sensing Letters*, 5, 4, 673–677, 2008.
- [76] P. Kersten, J.-S. Lee i T. Ainsworth, Unsupervised classification of polarimetric synthetic aperture Radar images using fuzzy clustering and EM clustering, *IEEE Transactions on Geoscience and Remote Sensing*, 43, 3, 519–527, 2005.
- [77] J. Fan, J. Zhao, W. An i Y. Hu, Marine Floating Raft Aquaculture Detection of GF-3 PolSAR Images Based on Collective Multikernel Fuzzy Clustering, *IEEE Journal* of Selected Topics in Applied Earth Observations and Remote Sensing, 12, 8, 2741– 2754, 2019.
- [78] J. F. Yang, Y. Z. Liu, B. J. Liu i W. L. Chen, Fuzzy Clustering for Military Decision Analysis with Remote Sensing Information, *Instruments, Measurement, Electronics* and Information Engineering, 347 of Applied Mechanics and Materials, 3085–3088, Trans Tech Publications Ltd, 10 2013.
- [79] C. Persello i L. Bruzzone, Active and Semisupervised Learning for the Classification of Remote Sensing Images, *IEEE Transactions on Geoscience and Remote Sensing*, 52, 11, 6937–6956, 2014.
- [80] Z. Xiaojin, Semi-supervised learning literature survey, *Computer Sciences TR*, 1530, 2008.

- [81] I. Dópido, J. Li, P. R. Marpu, A. Plaza, J. M. Bioucas Dias i J. A. Benediktsson, Semisupervised Self-Learning for Hyperspectral Image Classification, *IEEE Transactions* on Geoscience and Remote Sensing, 51, 7, 4032–4044, 2013.
- [82] L. Gomez-Chova, G. Camps-Valls, J. Munoz-Mari i J. Calpe, Semisupervised Image Classification With Laplacian Support Vector Machines, *IEEE Geoscience and Remote Sensing Letters*, 5, 3, 336–340, 2008.
- [83] V. J. Prakash i D. L. Nithya, A survey on semi-supervised learning techniques, arXiv preprint arXiv:1402.4645, 2014.
- [84] A. Géron, Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems, "O'Reilly Media, Inc.", 2019.
- [85] J. D. Kelleher, *Deep learning*, MIT press, 2019.
- [86] W. S. Sarle, Neural networks and statistical models, 1994.
- [87] L. Ma, Y. Liu, X. Zhang, Y. Ye, G. Yin i B. A. Johnson, Deep learning in remote sensing applications: A meta-analysis and review, *ISPRS Journal of Photogrammetry* and Remote Sensing, 152, 166–177, 2019.
- [88] A. Aboukarima, H. Elsoury i M. Menyawi, Artificial Neural Network Model for the Prediction of the Cotton Crop Leaf Area, *International Journal of Plant Soil Science*, 8, 1–13, 01 2015.
- [89] L. Camuñas-Mesa, B. Linares-Barranco i T. Serrano-Gotarredona, Neuromorphic Spiking Neural Networks and Their Memristor-CMOS Hardware Implementations, *Materials*, 12, 2745, 08 2019.
- [90] M. H. Sazli, A brief review of feed-forward neural networks, *Communications Faculty* of Sciences University of Ankara Series A2-A3 Physical Sciences and Engineering, 50, 01, 2006.
- [91] J. F. Mas i J. J. Flores, The application of artificial neural networks to the analysis of remotely sensed data, *International Journal of Remote Sensing*, 29, 3, 617–663, 2008.
- [92] W. H. Delashmit, M. T. Manry et al., Recent developments in multilayer perceptron neural networks, *Proceedings of the seventh Annual Memphis Area Engineering and Science Conference, MAESC*, 2005.
- [93] Y. Liu, S. Liu, Y. Wang, F. Lombardi i J. Han, A Stochastic Computational Multi-Layer Perceptron with Backward Propagation, *IEEE Transactions on Computers*, 67, 9, 1273–1286, 2018.
- [94] D. Galar i U. Kumar, Chapter 5 Diagnosis, D. Galar i U. Kumar, editori, *eMaintenance*, 235–310, Academic Press, 2017.
- [95] T. K. Gupta i K. Raza, Chapter 7 Optimization of ANN Architecture: A Review on Nature-Inspired Techniques, N. Dey, S. Borra, A. S. Ashour i F. Shi, editori, *Machine Learning in Bio-Signal Analysis and Diagnostic Imaging*, 159–182, Academic Press, 2019.

- [96] R. Zhu, X. Tu i J. Xiangji Huang, Chapter seven Deep learning on information retrieval and its applications, H. Das, C. Pradhan i N. Dey, editori, *Deep Learning for Data Analytics*, 125–153, Academic Press, 2020.
- [97] B. Kumaraswamy, 6 Neural networks for data classification, D. Binu i B. Rajakumar, editori, *Artificial Intelligence in Data Mining*, 109–131, Academic Press, 2021.
- [98] I. Goodfellow, Y. Bengio i A. Courville, *Deep Learning: Convolutional Networks Chapter 9*, MIT Press, 2016, http://www.deeplearningbook.org.
- [99] K. Phil, Matlab deep learning with machine learning, neural networks and artificial intelligence, Chapter 6: Convolutional Neural Network, *Apress, New York*, 2017.
- [100] S. Khan, H. Rahmani, S. A. A. Shah i M. Bennamoun, A guide to convolutional neural networks for computer vision, Chapter 4: Convolutional Neural Network, *Synthesis Lectures on Computer Vision*, 8, 1, 43–68, 2018.
- [101] S. Albawi, T. A. Mohammed i S. Al-Zawi, Understanding of a convolutional neural network, 2017 International Conference on Engineering and Technology (ICET), 1–6, 2017.
- [102] A. Ajit, K. Acharya i A. Samanta, A Review of Convolutional Neural Networks, 2020 International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE), 1–5, 2020.
- [103] A. Krizhevsky, I. Sutskever i G. E. Hinton, ImageNet Classification with Deep Convolutional Neural Networks, F. Pereira, C. Burges, L. Bottou i K. Weinberger, editori, *Advances in Neural Information Processing Systems*, 25, Curran Associates, Inc., 2012.
- [104] K. Simonyan i A. Zisserman, Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*, 2014.
- [105] B. Shi, R. Hou, M. Mazurowski, L. Grimm, Y. Ren, J. Marks, L. King, C. Maley, E. Hwang i J. Lo, Learning better deep features for the prediction of occult invasive disease in ductal carcinoma in situ through transfer learning, 98, 02 2018.
- [106] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens i Z. Wojna, Rethinking the Inception Architecture for Computer Vision, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2016.
- [107] G. Mujtaba i E.-S. Ryu, Client-Driven Personalized Trailer Framework Using Thumbnail Containers, *IEEE Access*, PP, 1–1, 03 2020.
- [108] B. Li i D. Lima, Facial expression recognition via ResNet-50, *International Journal* of Cognitive Computing in Engineering, 2, 57–64, 2021.
- [109] F. Chollet, Xception: Deep learning with depthwise separable convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1251–1258, 2017.
- [110] A. Ghosh, A. Sufian, F. Sultana, A. Chakrabarti i D. De, *Fundamental Concepts of Convolutional Neural Network*, 519–567, Springer International Publishing, Cham, 2020.

- [111] L. Alzubaidi, J. Zhang, A. J. Humaidi, A. Al-Dujaili, Y. Duan, O. Al-Shamma, J. Santamaría, M. A. Fadhel, M. Al-Amidie i L. Farhan, Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions, *Journal of big Data*, 8, 1, 1–74, 2021.
- [112] S. Bera i V. K. Shrivastava, Analysis of various optimizers on deep convolutional neural network model in the application of hyperspectral remote sensing image classification, *International Journal of Remote Sensing*, 41, 7, 2664–2683, 2020.
- [113] L. Zhang, L. Zhang i B. Du, Deep Learning for Remote Sensing Data: A Technical Tutorial on the State of the Art, *IEEE Geoscience and Remote Sensing Magazine*, 4, 2, 22–40, 2016.
- [114] Y. Chen, R. Fan, X. Yang, J. Wang i A. Latif, Extraction of Urban Water Bodies from High-Resolution Remote-Sensing Imagery Using Deep Learning, *Water*, 10, 5, 2018.
- [115] F. Isikdogan, A. C. Bovik i P. Passalacqua, Surface Water Mapping by Deep Learning, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 10, 11, 4909–4918, 2017.
- [116] S. Song, J. Liu, Y. Liu, G. Feng, H. Han, Y. Yao i M. Du, Intelligent Object Recognition of Urban Water Bodies Based on Deep Learning for Multi-Source and Multi-Temporal High Spatial Resolution Remote Sensing Imagery, *Sensors*, 20, 2, 2020.
- [117] Q. Zou, L. Ni, T. Zhang i Q. Wang, Deep Learning Based Feature Selection for Remote Sensing Scene Classification, *IEEE Geoscience and Remote Sensing Letters*, 12, 11, 2321–2325, 2015.
- [118] Z. Zhao, L. Jiao, J. Zhao, J. Gu i J. Zhao, Discriminant deep belief network for highresolution SAR image classification, *Pattern Recognition*, 61, 686–701, 2017.
- [119] Z. Chen, T. Zhang i C. Ouyang, End-to-End Airplane Detection Using Transfer Learning in Remote Sensing Images, *Remote Sensing*, 10, 1, 2018.
- [120] P. Ding, Y. Zhang, W.-J. Deng, P. Jia i A. Kuijper, A light and faster regional convolutional neural network for object detection in optical remote sensing images, *ISPRS Journal of Photogrammetry and Remote Sensing*, 141, 208–218, 2018.
- [121] Z. Deng, H. Sun, S. Zhou, J. Zhao, L. Lei i H. Zou, Multi-scale object detection in remote sensing imagery with convolutional neural networks, *ISPRS Journal of Photo*grammetry and Remote Sensing, 145, 3–22, 2018, deep Learning RS Data.
- [122] H. Yang, Y. Du, H. Zhao i F. Chen, Water Quality Chl-a Inversion Based on Spatio-Temporal Fusion and Convolutional Neural Network, *Remote Sensing*, 14, 5, 2022.
- [123] S. Hafeez, M. S. Wong, H. C. Ho, M. Nazeer, J. Nichol, S. Abbas, D. Tang, K. H. Lee i L. Pun, Comparison of Machine Learning Algorithms for Retrieval of Water Quality Indicators in Case-II Waters: A Case Study of Hong Kong, *Remote Sensing*, 11, 6, 2019.
- [124] D. Gómez, P. Salvador, J. Sanz i J. L. Casanova, A new approach to monitor water quality in the Menor sea (Spain) using satellite data and machine learning methods, *Environmental Pollution*, 286, 117489, 2021.

- [125] K. T. Peterson, V. Sagan i J. J. Sloan, Deep learning-based water quality estimation and anomaly detection using Landsat-8/Sentinel-2 virtual constellation and cloud computing, *GIScience & Remote Sensing*, 57, 4, 510–525, 2020.
- [126] H. N i Z. G, Remote Sensing of Coastal Waters, Elsevier Ltd, Oxford (England), 2009.
- [127] R. Barzegar, M. T. Aalami i J. Adamowski, Short-term water quality variable prediction using a hybrid CNN–LSTM deep learning model, *Stochastic Environmental Research and Risk Assessment*, 34, 2, 415–433, 2020.
- [128] N. Pahlevan, B. Smith, J. Schalles, C. Binding, Z. Cao, R. Ma, K. Alikas, K. Kangro, D. Gurlin, N. Hà, B. Matsushita, W. Moses, S. Greb, M. K. Lehmann, M. Ondrusek, N. Oppelt i R. Stumpf, Seamless retrievals of chlorophyll-a from Sentinel-2 (MSI) and Sentinel-3 (OLCI) in inland and coastal waters: A machine-learning approach, *Remote Sensing of Environment*, 240, 111604, 2020.
- [129] Q. Ye, X. Yang, C. Chen i J. Wang, River Water Quality Parameters Prediction Method Based on LSTM-RNN Model, 2019 Chinese Control And Decision Conference (CCDC), 3024–3028, 2019.
- [130] J. Sha, X. Li, M. Zhang i Z.-L. Wang, Comparison of Forecasting Models for Real-Time Monitoring of Water Quality Parameters Based on Hybrid Deep Learning Neural Networks, *Water*, 13, 11, 2021.
- [131] J. Yang, J. Guo, H. Yue, Z. Liu, H. Hu i K. Li, CDnet: CNN-Based Cloud Detection for Remote Sensing Imagery, *IEEE Transactions on Geoscience and Remote Sensing*, 57, 8, 6195–6211, 2019.
- [132] J. H. Jeppesen, R. H. Jacobsen, F. Inceoglu i T. S. Toftegaard, A cloud detection algorithm for satellite imagery based on deep learning, *Remote Sensing of Environment*, 229, 247–259, 2019.
- [133] Y. Fan, W. Li, C. K. Gatebe, C. Jamet, G. Zibordi, T. Schroeder i K. Stamnes, Atmospheric correction over coastal waters using multilayer neural networks, *Remote Sensing of Environment*, 199, 218–240, 2017.

POPIS OZNAKA I KRATICA

- **BOA** Bottom of Atmosphere
- **CNN** Convolutional Neural Network
- ESA European Space Agency
- FCM Fuzzy C-Means
- KNN K-Nearest-Neighbor
- LSTM Long Short Term Memory Units
- LTU Linear Threshold Unit
- LULC Land Use and Land Cover
- LWIR Long-Wave Infrared
- MIR Middle Infrared
- MLP Multilayer perceptron
- MSI Multispectral Imager
- MWIR Mid-Wave Infrared
- NAOMI New Astrosat Optical Modular Instrument
- NDWI Normalized Difference Water Index
- NIR Near Infrared Spectrum
- **NLP** Natural Language Processing
- **OLCI** Ocean and Land Colour Imager
- **OLI** Operational Land Imager
- PAN Panchromatic
- **RBF** Radial Basis Function
- **RNN** Recurrent Neural Network
- **FNN** Feedback Neural Network
- SAR Synthetic Aperture Radar
- SLSTR Sea and Land Surface Temperature Radiometer
- SVM Support Vector Machine
- SWIR Short-Wave Infrared
- TIRS Thermal Infrared Sensor
- TLU Threshold Logic Unit
- **TOA** Top of Atmosphere
- VIS Visible Spectrum