GIS i integracija geoprostornih podataka

Ishodi učenja

Nakon završetka ove nastavne cjeline studenti će moći:

- objasniti pojam geografskih informacijskih sustava (GIS) i integracije geoprostornih podataka;
- opisati koordinatne sustave, kartografske projekcije i prostorne referentne sustave;
- koristiti prostorne baze podataka, poput Oracle Spatiala, za upravljanje georeferenciranim podacima;
- integrirati skupove podataka o okolišu primjenom prostornih spajanja i preklapanja slojeva;
- vizualizirati i analizirati podatke o okolišu na interaktivnim kartama;
- tumačiti rezultate prostornih analiza radi potpore odlučivanju o okolišu.

Uvod

Geografski informacijski sustavi (GIS) namijenjeni su prikupljanju, pohrani, upravljanju, analizi i vizualizaciji podataka povezanih s određenim položajima na Zemljinoj površini. Objedinjuju računalnu opremu, programsku podršku, podatke i analitičke metode kako bi prikazali, dohvatili i iskoristili prostorne odnose i obrasce u geografskim podacima. Kartografski prikaz i pripadajuće mogućnosti analize i vizualizacije primjenjuju se u brojnim područjima svakodnevnog života: navigaciji i prometu, dostavi, urbanističkom planiranju i pametnim gradovima, praćenju bolesti, poljoprivredi i proizvodnji hrane, prometu nekretnina i prostornom planiranju, vremenskoj prognozi i upozoravanju na nepogode, obrazovanju, gospodarenju otpadom i recikliranju, turizmu i kulturnoj baštini te zaštiti okoliša i klimatskim aktivnostima.

Iako se GIS primjenjuje u vrlo različitim područjima, u ovom ćemo se nastavnom materijalu usredotočiti na njegovu primjenu u istraživanju i zaštiti okoliša. GIS pruža snažan okvir za organiziranje i tumačenje velikih količina podataka o okolišu. Ti podaci opisuju prirodne procese i čovjekove utjecaje na okoliš, uključujući kakvoću i onečišćenje zraka i vode, promjene u korištenju zemljišta, krčenje šuma, gubitak bioraznolikosti i klimatsku promjenjivost. Navedene pojave nisu jednoliko raspoređene u prostoru, nego ovise o lokaciji, prostornom mjerilu i vremenu. Povezivanjem podataka s geografskim položajem GIS omogućuje razumijevanje ne samo onoga

što se događa u okolišu, nego i mjesta na kojem se promjene odvijaju te njihovih uzroka. Budući da većina podataka o okolišu ima prostornu sastavnicu, GIS je postao nezaobilazan alat za upravljanje složenim informacijama o okolišu i njihovo tumačenje. Znanstvenicima, planerima i donositeljima odluka omogućuje povezivanje mjerenja s geografskim lokacijama, prikaz obrazaca, prepoznavanje trendova i upravljanje okolišem utemeljeno na dokazima.

Razvoj GIS-a važan je korak od tradicionalnih tabličnih baza podataka prema informacijskim sustavima koji razumiju prostorne odnose. Uobičajeni sustavi za upravljanje podacima uglavnom se temelje na tablicama s recima i stupcima. Iako su učinkoviti za pohranu numeričkih i tekstnih podataka, sami po sebi ne prikazuju prostorne odnose. Primjerice, tablica s mjerenjima onečišćenja zraka u različitim gradovima ne pokazuje kako se koncentracije mijenjaju u prostoru ni kako su povezane s obližnjim industrijskim područjima, glavnim prometnicama ili meteorološkim uvjetima. Povećanjem računalne snage i dostupnošću digitalnih karata postalo je moguće povezati opisne (atributne) i prostorne podatke. Tako je otvoren put naprednijim analizama prostornih obrazaca, odnosa i trendova koje je teško prepoznati iz neprostornih podataka.

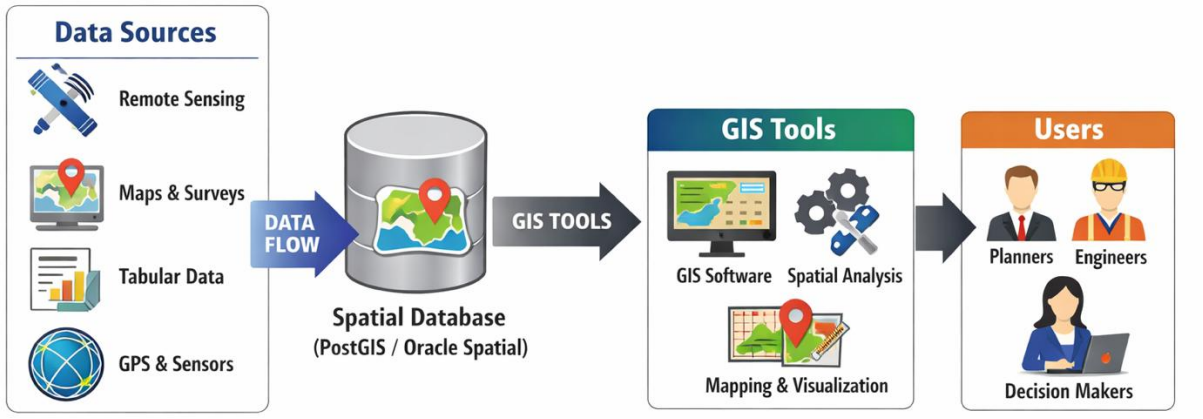

Slika 3.1. Konceptualna arhitektura suvremenog GIS-a (slika izrađena pomoću OpenAI ChatGPT-a 4. veljače 2026. prema uputi: „izvori podataka → prostorna baza podataka (PostGIS / Oracle Spatial) → GIS alati → korisnici").1

Podaci o okolišu u pravilu su prostorno određeni. Pojave kao što su onečišćenje, krčenje šuma, poplave i klimatske promjene razlikuju se u prostoru i vremenu. Tablični podaci mogu pohraniti rezultate mjerenja, ali ne omogućuju jednostavno otkrivanje njihovih prostornih obrazaca i odnosa. GIS prevladava to ograničenje tako što rezultate mjerenja, poput koncentracije onečišćujućih tvari ili udjela šumskog pokrova, povezuje s prostornim objektima (točkama, linijama i površinama) i geografskim koordinatama na kartama i satelitskim snimkama. Time omogućuje analizu blizine, preklapanja slojeva i prostorno modeliranje [1], [2].[1][2]

Slika 3.2. Usporedba tabličnog skupa podataka o indeksu kakvoće vode (WQI) i GIS karte s mjernim lokacijama i vrijednostima indeksa uz rijeku Tigris tijekom ljeta 2019. (prilagođeno prema [3]).2[3]

Table 9
The calculated WQI and WQR for two seasons in 2018 and 2019.

Season	Month	2018		2019	
		WQI	WQR	WQI	WQR
Summer	May	144.60	Poor	145.25	Poor
	June	139.02	Poor	209.19	Very Poor
	July	157.60	Poor	161.67	Poor
	August	135.86	Poor	139.10	Poor
	September	142.28	Poor	144.34	Poor
	October	141.42	Poor	142.96	Poor
Winter	November	138.88	Poor	144.43	Poor
	December	138.69	Poor	138.69	Poor
	January	139.14	Poor	139.31	Poor
	February	148.05	Poor	149.15	Poor
	March	152.79	Poor	153.95	Poor
	April	223.08	Very Poor	227.92	Very Poor

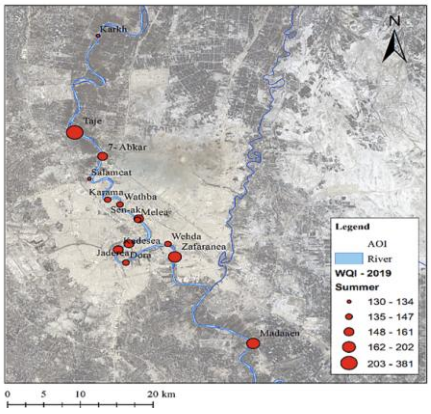

Slika 3.2. Usporedba tabličnog skupa podataka o indeksu kakvoće vode (WQI) i GIS karte s mjernim lokacijama i vrijednostima indeksa uz rijeku Tigris tijekom ljeta 2019. (prilagođeno prema [3]).2[3]

Važnost geoprostornih podataka u analizi okoliša

Geoprostorni podaci ključni su za razumijevanje procesa u okolišu i rješavanje izazova povezanih s njegovom zaštitom. Podupiru brojna istraživanja i na njima utemeljeno donošenje odluka. Prema izvorima NASA-e [4], [5] i Američkog geološkog zavoda (USGS) [13], mnoge aktivnosti praćenja stanja okoliša oslanjaju se na prostorne podatke dobivene daljinskim istraživanjima, terenskim mjerenjima i geografskim izmjerama. GIS omogućuje objedinjavanje tih raznorodnih izvora u jedinstven prostorni okvir.[4][5][13]

Pomoću GIS-a istraživači mogu analizirati raspodjelu onečišćujućih tvari i bolje razumjeti obrasce onečišćenja zraka i vode, pratiti promjene u korištenju zemljišta i vegetacijskom pokrovu, nadzirati krčenje šuma, prepoznavati područja ugrožena prirodnim opasnostima i procjenjivati učinke klimatskih promjena. Primjerice, prostorna analiza može otkriti žarišta onečišćenja uz industrijske zone, pratiti smanjenje šumskih površina na satelitskim snimkama, prikazati širenje urbanih područja ili kartirati regionalne trendove temperature i oborina. Takvi rezultati pridonose kvalitetnijem planiranju, praćenju stanja okoliša i održivom upravljanju prirodnim resursima.

U nastavku su prikazane neke od najčešćih primjena GIS-a u analizi okoliša.

Praćenje onečišćenja

GIS se široko primjenjuje u analizi onečišćenja zraka, vode i tla. Kartiranjem izmjerenih vrijednosti istraživači mogu prepoznati prostorne obrasce, primjerice žarišta onečišćenja uz industrijska područja i glavne prometnice, te istražiti povezanost razina onečišćenja s gustoćom stanovništva, korištenjem zemljišta ili meteorološkim uvjetima. Primjerice, mjerne postaje kvalitete zraka prikupljaju podatke o lebdećim česticama PM2,5, a GIS omogućuje njihov prikaz na karti grada i otkrivanje područja s trajno povišenim koncentracijama. Time se podupire donošenje ciljanih mjera za smanjenje onečišćenja.

Korištenje zemljišta i krčenje šuma

Promjene u korištenju i pokrovu zemljišta još su jedno važno područje istraživanja u kojem je GIS neizostavan. Analiza satelitskih snimaka omogućuje praćenje krčenja šuma, širenja gradova i razvoja poljoprivrednih površina tijekom vremena. Usporedbom karata pokrova zemljišta iz različitih godina moguće je kvantificirati promjene i prepoznati trendove [6]. Primjerice, podaci o pokrovu zemljišta dobiveni sa satelita mogu poslužiti za izračun ukupne šumske površine izgubljene tijekom desetljeća te za utvrđivanje područja s najvećim rizikom od budućeg krčenja šuma (slika 3.3).[6]Slika 3.3. Podaci o gubitku šumskog pokrova u Sjevernoj Makedoniji i njegov GIS prikaz na satelitskoj karti, iz izvora Global Forest Watch [7].3

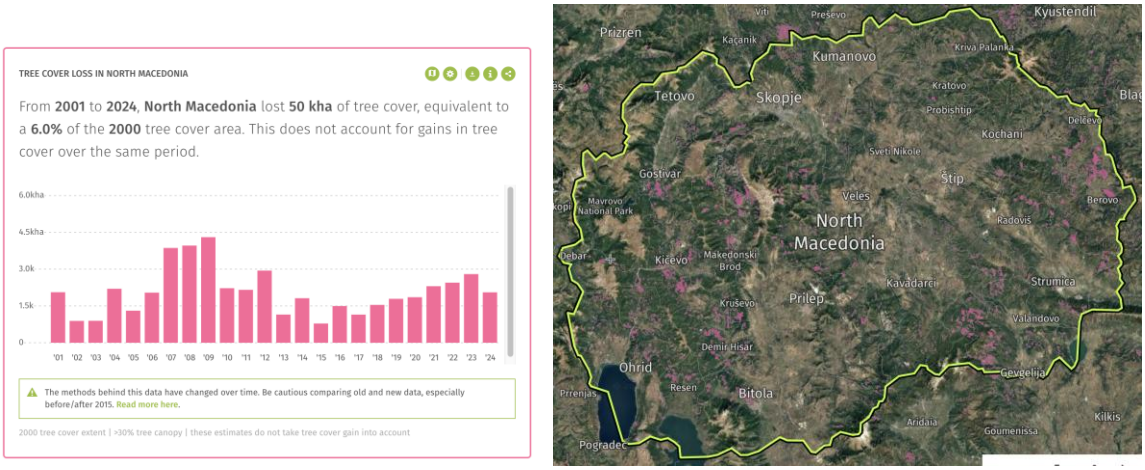

Slika 3.3. Podaci o gubitku šumskog pokrova u Sjevernoj Makedoniji i njegov GIS prikaz na satelitskoj karti, iz izvora Global Forest Watch [7].3[7]

Klimatske promjene i promjene okoliša

Klimatski podaci, kao što su temperatura, oborine i porast razine mora, imaju izraženu prostornu i kontinuiranu prirodu. GIS podupire njihovu analizu rasterskim modeliranjem i vizualizacijom. NASA Earth Observatory [4] naglašava njegovu važnost za razumijevanje prostorne promjenjivosti klimatskih obrazaca i njihovih učinaka na okoliš. Klimatski se modeli, primjerice, mogu prikazati u

GIS-u kako bi se vidjele promjene prosječne temperature na određenom području i utvrdile lokacije posebno osjetljive na toplinske valove ili sušu. GIS omogućuje i analizu povijesnih te aktualnih podataka o tornadima i uraganima kroz prostor i vrijeme, čime pruža podlogu za odlučivanje o sigurnosti stanovništva.[4]

Modeli geoprostornih podataka: rasterski i vektorski

U GIS-u se geoprostorni podaci najčešće prikazuju dvama osnovnim modelima: rasterskim i vektorskim (slika 3.4). Svaki je model prikladan za određene vrste informacija.Slika 3.4. Vektorski i rasterski podatkovni model (prilagođeno prema [8]).4

Rasterski model prikazuje geografski prostor kao mrežu ćelija, odnosno piksela, pri čemu svaka ćelija sadržava vrijednost, primjerice temperaturu, nadmorsku visinu ili kategoriju pokrova zemljišta. Rasterski su podaci osobito važni u primjenama vezanima uz okoliš jer prikladno predstavljaju kontinuirane pojave poput temperature, visine terena, oborina i pokrova zemljišta dobivenog satelitskim mjerenjima. Često se koriste u klimatskom modeliranju, daljinskim istraživanjima i ekološkim studijama. Primjerice, satelitska snimka stanja vegetacije pohranjuje se kao raster u kojem svaki piksel predstavlja gustoću vegetacije.

Vektorski model prikazuje geografske objekte pomoću točaka, linija i poligona određenih koordinatama. Pogodan je za diskretne objekte u okolišu, kao što su rijeke, prometnice, zaštićena područja, mjerne postaje, šume, jezera i administrativne granice. Primjerice, postaje za praćenje kakvoće vode prikazuju se točkama, rijeke linijama, a zaštićene močvare poligonima.

Ta dva modela zajedno omogućuju prikaz i analizu prirodnih procesa i ljudskih aktivnosti.

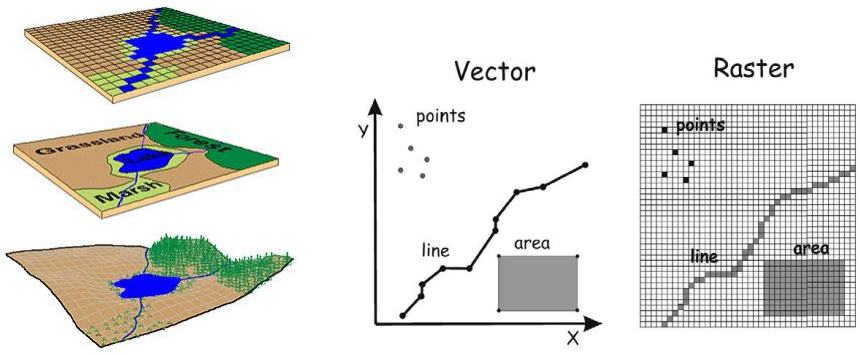

Slika 3.4. Vektorski i rasterski podatkovni model (prilagođeno prema [8]).4[8]

Standardizirani datotečni formati GIS podataka

Za pohranu i razmjenu geoprostornih podataka koriste se različiti standardizirani datotečni formati.

Među čestim vektorskim formatima jesu Shapefile, GeoJSON, KML i OSM, uz niz manje raširenih formata. Podržava ih većina GIS programa i web-aplikacija za prikaz karata, a omogućuju pohranu geografskih objekata i tematskih slojeva.

- **ESRI Shapefile:** format razvijen u okviru Esrijeva sustava ArcGIS, široko primjenjivan za pohranu točaka, linija i poligona. Podržavaju ga gotovo svi komercijalni GIS sustavi i sustavi otvorenoga koda pa je postao jedan od industrijskih standarda. Osnovni Shapefile sastoji se od najmanje triju povezanih datoteka: SHP sadržava geometriju objekata, SHX indeks položaja geometrija, a DBF atributne podatke.
- **GeoJSON (Geographic JSON):** jednostavan tekstni format za zapis geografskih struktura, kao što su točke, linije i poligoni, temeljen na zapisu JavaScript Object Notation (JSON). Riječ je o otvorenom standardu koji se sve češće primjenjuje, osobito u web-aplikacijama za kartografiju. Uobičajene su datotečne ekstenzije .geojson i .json.
- **KML (Keyhole Markup Language):** format temeljen na XML-u, ponajprije namijenjen vizualizaciji u alatima kao što je Google Earth. Koriste se ekstenzije .kml i .kmz, pri čemu je KMZ sažeti oblik KML datoteke te je često zadani format u Google Earthu. KML/KMZ je 2008. godine prihvaćen kao međunarodni standard organizacije Open Geospatial Consortium (OGC) [9].[9]
- **OSM (OpenStreetMap):** izvorni format projekta OpenStreetMap, temeljen na XML-u. OpenStreetMap jedan je od najvećih svjetskih projekata zajedničkog prikupljanja geografskih podataka.[42]

Rasterski podaci, uključujući satelitske snimke i klimatske skupove podataka, često se pohranjuju u formatu GeoTIFF, koji u istoj datoteci čuva vrijednosti slike i podatke o geografskom položaju. Ostali rasterski formati uključuju ASCII Grid (.asc) i Esri Grid.

- **GeoTIFF:** široko prihvaćen format rasterskih slika u GIS-u i satelitskim daljinskim istraživanjima. Uz GeoTIFF mogu se nalaziti dodatne datoteke: TFW (world file) s podacima za georeferenciranje rastera, XML s dodatnim metapodacima, AUX s pomoćnim informacijama, uključujući projekciju, te OVR s prikazima različitih razlučivosti radi bržeg prikazivanja.

- **ASCII Grid:** tekstni format koji podatke pohranjuje kao numeričke vrijednosti, uključujući decimalne brojeve, zajedno sa zaglavljem koje opisuje mrežu. Podaci se u tekstnoj datoteci zapisuju pomoću graničnika, primjerice zareza, razmaka ili tabulatora. Uobičajena je ekstenzija .asc.
- **Esri Grid:** vlasnički rasterski format koji je razvio Esri. Može pohranjivati i atributne podatke, no pridruživanje atributa moguće je za cjelobrojne mreže. Atributi se pohranjuju u tablici atributa vrijednosti (VAT), s jednim zapisom za svaku jedinstvenu vrijednost ćelije i brojem ćelija koje imaju tu vrijednost. Postoje cjelobrojne mreže i mreže s vrijednostima pomičnog zareza. Pokrov zemljišta primjer je diskretnog rastera u kojem kategorije imaju cjelobrojne oznake, dok model nadmorske visine prikazuje kontinuirane numeričke vrijednosti.

Uporaba standardiziranih formata osigurava interoperabilnost GIS alata te olakšava analizu i razmjenu podataka o okolišu među ustanovama i znanstvenim područjima.

Pregled tehnologija: GIS alati, modeli prostornih podataka i integracija podataka o okolišu

Pregled GIS tehnologija

Geografski informacijski sustavi obuhvaćaju širok raspon programskih tehnologija za pohranu, upravljanje, analizu i vizualizaciju prostornih podataka. S vremenom su se razvili iz samostalnih računalnih aplikacija u snažne sustave povezane s bazama podataka i računalstvom u oblaku, sposobne obrađivati velike količine geoprostornih podataka iz različitih izvora. Među najraširenijim tehnologijama danas su Esri ArcGIS, Oracle Spatial, PostGIS i QGIS. One pružaju različite mogućnosti rada s prostornim tipovima podataka i prostornom analizom. Dostupni su i brojni drugi komercijalni sustavi i sustavi otvorenoga koda, svaki sa svojim prednostima i ograničenjima.

Esri ArcGIS [10] komercijalna je GIS platforma namijenjena profesionalnom i organizacijskom radu s geografskim podacima, kartografijom, analizom i vizualizacijom. Zbog raširenosti smatra se jednim od industrijskih standarda. Objedinjuje stolne aplikacije, web-usluge i mogućnosti rada u oblaku radi upravljanja prostornim podacima, izrade interaktivnih karata i provedbe analitičkih postupaka. Podržava brojne prostorne formate, koordinatne sustave i napredne funkcije geoprostorne obrade pa je prikladan za praćenje okoliša, urbanističko planiranje i upravljanje infrastrukturom. Fleksibilnost, skalabilnost i povezivost s bazama podataka i internetskim uslugama pridonose njegovoj širokoj primjeni u javnom i privatnom sektoru.[10]

Oracle Spatial [21] komercijalno je rješenje za velike sustave integrirano u Oracle Database. Izravno podržava prostorne tipove podataka, prostorno indeksiranje, koordinatne referentne sustave i napredne funkcije prostorne analize. Često se koristi u velikim poslovnim sustavima i javnoj upravi, gdje su pouzdanost, skalabilnost i sigurnost osobito važne. Podržava složene prostorne upite, analizu mreža i integraciju s drugim informacijskim sustavima.[21]

PostGIS [16] proširenje je otvorenoga koda za bazu podataka PostgreSQL koje omogućuje rad s prostornim podacima. Vrlo je rašireno zahvaljujući fleksibilnosti, aktivnoj zajednici i usklađenosti sa standardima organizacije Open Geospatial Consortium (OGC). Korisnici mogu pohranjivati prostorne objekte, postavljati prostorne upite i izvoditi složene prostorne operacije jezikom SQL. Kao otvoreno rješenje PostGIS se široko primjenjuje u istraživanju, nastavi, praćenju okoliša i web-aplikacijama temeljenima na GIS-u.[16]

QGIS [15] besplatna je GIS platforma otvorenoga koda s profesionalnim mogućnostima za analitičare, istraživače i organizacije kojima je potrebna fleksibilnost bez troškova licencija. Služi za izradu, uređivanje, analizu i vizualizaciju geoprostornih podataka. Podržava širok raspon

vektorskih i rasterskih formata, koordinatnih referentnih sustava i alata za prostorne analize, uz pregledno grafičko sučelje. Može se izravno povezati s prostornim bazama podataka, primjerice s PostGIS-om. Zbog fleksibilnosti, mogućnosti proširenja dodatcima i snažne korisničke zajednice često se koristi u nastavi, istraživanju, praćenju okoliša i kartografskim projektima.[15]

Navedeni alati pokazuju kako suvremene GIS tehnologije povezuju upravljanje bazama podataka s prostornom analizom i omogućuju učinkovitu pohranu, pretraživanje i obradu geoprostornih podataka i podataka o okolišu.

Uvod u rad s GIS alatima

GIS alati obično omogućuju rad putem grafičkog korisničkog sučelja (GUI), ali i programski pristup prostornim podacima. Stolne aplikacije poput QGIS-a i ArcGIS-a često služe kao korisnički dio sustava, dok prostorne baze podataka, primjerice PostGIS i Oracle Spatial, imaju ulogu pozadinskih sustava za pohranu i obradu.

Uobičajeni tijek rada u GIS-u (slika 3.5) obuhvaća sljedeće korake:Slika 3.5. Osnovni tijek rada u GIS-u (slika izrađena pomoću OpenAI ChatGPT-a 4. veljače 2026. prema uputi: „uvoz → određivanje CRS-a → vizualizacija → prostorna analiza → izlaz”).5

1. uvoz prostornih skupova podataka (npr. karata, satelitskih snimaka i položaja senzora);
2. određivanje ili provjeru koordinatnih referentnih sustava;
3. vizualizaciju podatkovnih slojeva;
4. izvođenje prostornih upita i analiza;
5. izvoz rezultata za izvješćivanje ili daljnju obradu.

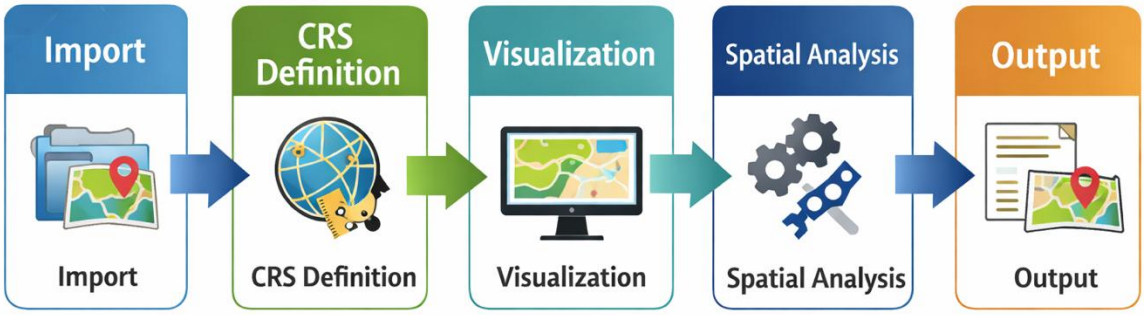

Slika 3.5. Osnovni tijek rada u GIS-u (slika izrađena pomoću OpenAI ChatGPT-a 4. veljače 2026. prema uputi: „uvoz → određivanje CRS-a → vizualizacija → prostorna analiza → izlaz”).5

Primjerice, student koji radi s Oracle Spatialom (slika 3.6) može najprije učitati vektorske skupove podataka, poput riječnih mreža ili postaja za praćenje kvalitete zraka, u prostornu bazu podataka. Zatim jednostavnim SQL upitima s prostornim funkcijama može izračunati udaljenosti, utvrditi presijecanja ili pronaći objekte unutar zadanog područja. Takav pristup, u kojem je baza podataka središnji dio sustava, pomaže studentima razumjeti kako se prostorna analiza uključuje u aplikacije temeljene na podacima i automatizirane postupke.Slika 3.6. Prikaz aktivnog projekta u Oracle Spatial Studiju (prilagođeno prema priručniku Oracle Spatial Studio Guide [23]).6

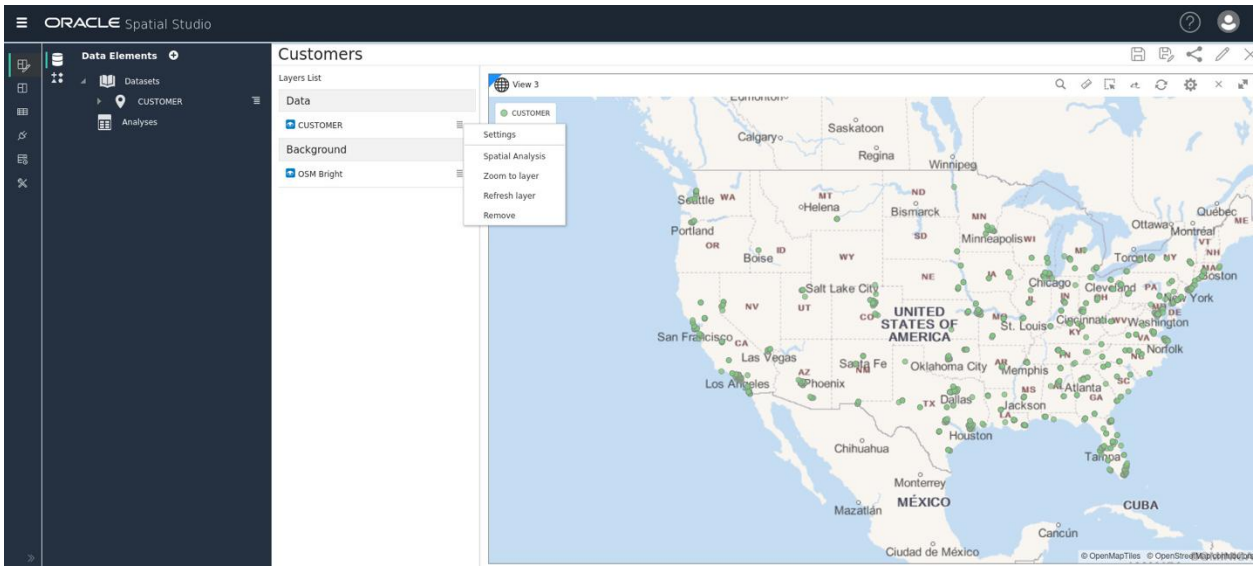

Slika 3.6. Prikaz aktivnog projekta u Oracle Spatial Studiju (prilagođeno prema priručniku Oracle Spatial Studio Guide [23]).6[23]

Uvoz prostornih skupova podataka u GIS alate

Budući da se GIS temelji na prostornim podatkovnim modelima koji opisuju digitalni prikaz objekata iz stvarnog svijeta, uvoz prostornih podataka prvi je i ključan korak svakog postupka. Prije analize, vizualizacije ili izvođenja prostornih upita geografske podatke potrebno je učitati u GIS okruženje u obliku koji program može prepoznati i obraditi. Alati QGIS, ArcGIS, PostGIS i Oracle Spatial podržavaju mnoge prostorne formate i omogućuju integraciju podataka iz različitih izvora u jedinstven projekt.

Prostorni se podaci, kao što je već opisano, uglavnom dijele na vektorske i rasterske, a svaka skupina ima posebne značajke i namjene. GIS alati omogućuju njihov uvoz putem grafičkih sučelja ili veza s bazama podataka. U stolnim aplikacijama slojevi se mogu dodati iz lokalnih datoteka, udaljenih poslužitelja ili internetskih repozitorija. Primjerice, satelitske snimke mogu se preuzeti iz NASA-inih [33] ili Copernicusovih usluga [38] i učitati kao rasterski slojevi, dok se vektorski podaci o riječnim mrežama i zaštićenim područjima mogu pribaviti iz javnih izvora poput Natural Eartha ili

OpenStreetMapa [42]. U sustavima temeljenima na bazama podataka prostorni se podaci mogu uvesti u PostGIS ili Oracle Spatial, gdje postaju dio centralizirane prostorne baze koja omogućuje učinkovito upravljanje i postavljanje upita.[33][38][42]

Pri uvozu treba provjeriti sadržava li svaki skup podataka informacije o prostornom referentnom sustavu, koje određuju položaj podataka na Zemljinoj površini. Većina GIS alata automatski prepoznaje koordinatni referentni sustav (CRS), ali korisnik prije nastavka rada treba potvrditi njegovu ispravnost. Ako CRS nedostaje ili je pogrešno definiran, sloj se možda neće ispravno poklopiti s ostalim slojevima projekta.

Važan je i prijenos atributnih podataka. Uz geometriju prostorni skupovi sadržavaju opisna obilježja, poput izmjerenih koncentracija onečišćujućih tvari, naziva lokacija, datuma opažanja ili klasifikacijskih kategorija. GIS alati čuvaju te atribute te omogućuju njihov pregled, uređivanje i primjenu u daljnjim analizama. Upravo povezanost prostornih objekata i njihovih atributa GIS čini osobito korisnim za analizu okoliša i geografskih pojava.

Suvremene primjene GIS-a u području okoliša sve se više oslanjaju na podatke iz raznorodnih izvora: terenskih senzora, primjerice postaja za praćenje zraka i vode, satelitskih platformi, državnih tijela, otvorenih repozitorija s podacima o pokrovu zemljišta i klimi te uređaja interneta stvari (IoT) koji stvaraju prostorne podatke u stvarnom vremenu. Uvoz takvih podataka u zajednički GIS projekt omogućuje njihovu integraciju i potpuniju analizu okoliša. Primjerice, satelitska se snimka može učitati kao rasterski sloj, lokacije mjernih postaja kao točke, a administrativne granice kao poligoni. Nakon uvoza svi se slojevi mogu prikazati istodobno i poslužiti kao osnova za prostornu analizu. GIS baze podataka predstavljaju središnju platformu za povezivanje prostornih i neprostornih podataka prema položaju i vremenu.

Ispravan uvoz prostornih podataka stoga je presudan za uspjeh cijelog GIS postupka. Provjerom učitavanja, ispravnim georeferenciranjem i očuvanjem atributnih informacija stvara se pouzdana osnova za vizualizaciju, analizu i odlučivanje.

Određivanje i provjera koordinatnih referentnih sustava

Koordinatni referentni sustav (CRS) određuje način na koji se položaj prostornih podataka prikazuje na Zemljinoj površini. Budući da je Zemlja trodimenzionalno i zakrivljeno tijelo, prikaz položaja na dvodimenzionalnoj karti zahtijeva matematičke transformacije koje nazivamo kartografskim projekcijama.

Različiti skupovi podataka mogu koristiti različite koordinatne sustave (slika 3.7), primjerice:Slika 3.7. Usporedba geografskih i projiciranih koordinatnih sustava (slika izrađena pomoću OpenAI ChatGPT-a 4. veljače 2026. prema uputi o usporedbi koordinatnih sustava u GIS-u).7

- geografske koordinatne sustave (geografska širina i dužina), poput Svjetskoga geodetskog sustava 1984. (WGS84);
- projicirane koordinatne sustave (npr. UTM ili nacionalne koordinatne mreže).

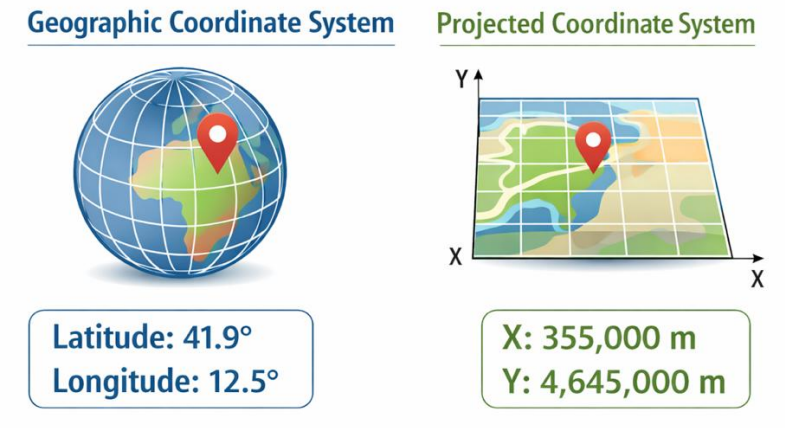

Slika 3.7. Usporedba geografskih i projiciranih koordinatnih sustava (slika izrađena pomoću OpenAI ChatGPT-a 4. veljače 2026. prema uputi o usporedbi koordinatnih sustava u GIS-u).7

Za rad u GIS-u iznimno je važno osigurati međusobnu kompatibilnost koordinatnih referentnih sustava svih skupova podataka. Ako se slojevi s različitim CRS-ovima objedine bez odgovarajuće transformacije, rezultati prostornih analiza mogu biti netočni ili zavaravajući. GIS alati zato imaju funkcije reprojekcije koje pretvaraju podatke iz jednog CRS-a u drugi i omogućuju dosljednu analizu više skupova podataka.

Pri uobičajenom radu u GIS-u preporučuje se najprije odrediti CRS projekta kako bi se slojevi mogli pravilno uskladiti. Zatim valja provjeriti CRS svakog pojedinog skupa podataka u svojstvima sloja. Informaciju o uporabljenom sustavu često prikazuje i statusna traka programa s oznakom EPSG, primjerice EPSG:4326 za geografski sustav WGS84. Neusklađeni CRS-ovi mogu uzrokovati pogreške pri preklapanju slojeva. Ako postoje razlike, slojeve je potrebno reprojicirati odgovarajućim alatom, primjerice naredbom Reproject Layer. Korisno je i vizualno provjeriti poklapaju li se slojevi jer vidljiva odstupanja mogu upozoriti na poteškoće. Ovi koraci pridonose prostornoj točnosti GIS projekta.

Izazovi integracije podataka i kvaliteta prostornih podataka

Unatoč prednostima, integracija prostornih podataka iz više izvora donosi određene izazove. Čest je problem neusklađenost koordinata zbog uporabe različitih koordinatnih referentnih sustava ili projekcija. Bez odgovarajuće reprojekcije slojevi se možda neće ispravno poklopiti na karti.

Drugi je izazov vremenska razlučivost. Podaci o okolišu mogu se prikupljati u različitim vremenskim razmacima, primjerice senzorska mjerenja svakog sata, a karte pokrova zemljišta jednom godišnje. Integracija takvih podataka zahtijeva pažljivo usklađivanje vremenskih mjerila i metoda sinkronizacije.

Probleme uzrokuju i nedosljedni metapodaci. Oni opisuju način prikupljanja, obrade i organizacije podataka. Ako su nepotpuni ili neusklađeni, teško je procijeniti kvalitetu i točnost podataka te njihovu prikladnost za određenu analizu. Zato je poznavanje metapodataka i pravilno upravljanje njima važan preduvjet pouzdanih rezultata GIS-a.

Kvaliteta prostornih podataka također je ključna sastavnica GIS analize. Obuhvaća položajnu točnost, točnost atributa, vremensku točnost, potpunost i dosljednost. Pogreške mogu dovesti do netočnih zaključaka, osobito pri donošenju odluka o okolišu. Primjerice, pogrešno evidentirani položaji senzora mogu iskriviti karte onečišćenja, dok zastarjeli podaci o korištenju zemljišta mogu dati pogrešnu sliku sadašnjeg stanja. GIS tehnologije nude alate za provjeru kvalitete podataka, valjanosti geometrije i dokumentiranje nesigurnosti. Razumijevanje ograničenja podataka nužno je za odgovornu uporabu GIS-a.

Prostorni upiti, operacije i analize

Uz geometriju, GIS upravlja i topološkim odnosima (slika 3.8), odnosno odnosima među prostornim objektima. Topologija opisuje susjedstvo, povezanost, sadržavanje i preklapanje, neovisno o točnom obliku i veličini objekata.Slika 3.8. Uobičajeni topološki odnosi (prilagođeno prema [31]).8

Uobičajeni topološki odnosi uključuju:

- **Intersects (presijecanje): dva objekta imaju barem jedan zajednički dio prostora;**
- **Contains / Within (sadržavanje / unutar): jedan se objekt nalazi unutar drugoga;**
- **Touches (dodirivanje): objekti dijele granicu, ali se njihove unutrašnjosti ne preklapaju;**
- **Overlaps (preklapanje): objekti se djelomično prostorno preklapaju.**

Topologija je osobito važna u analizi okoliša. Primjerice, određivanje izvora onečišćenja unutar slijeva, zemljišnih čestica koje se presijecaju sa zaštićenim staništima ili prometnica koje prolaze

poplavno ugroženim područjima temelji se na topološkim odnosima. Prostorne baze podataka, poput PostGIS-a i Oracle Spatiala, imaju ugrađene funkcije za njihovu učinkovitu i točnu provjeru.

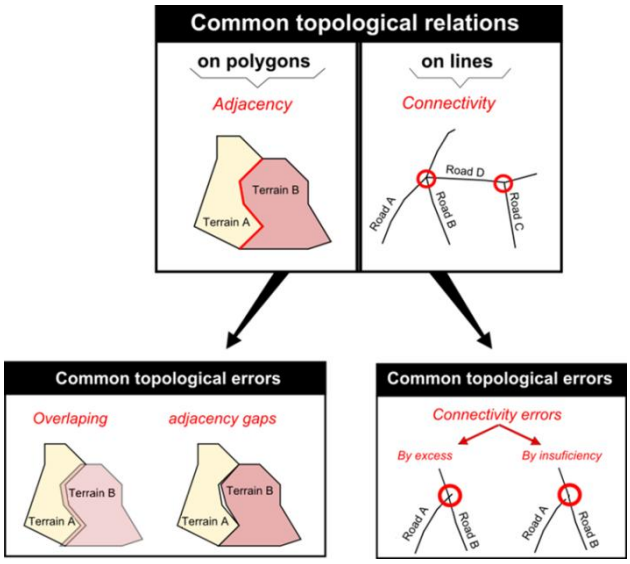

Slika 3.8. Uobičajeni topološki odnosi (prilagođeno prema [31]).8[31]

GIS tehnologije podržavaju različite prostorne operacije koje omogućuju napredne analize.

Prostorno spajanje (spatial join) omogućuje pridruživanje atributa jednog skupa podataka drugome na temelju njihovih prostornih odnosa (slika 3.9), primjerice pridruživanje mjerenja onečišćenja administrativnim područjima. Slika 3.9. Primjer prostornog spajanja (prilagođeno prema [32]).9

Operacije preklapanja (overlay) kombiniraju više prostornih slojeva i stvaraju nove skupove podataka. Primjerice, presijecanjem karata korištenja zemljišta i zona opasnosti od poplava mogu se utvrditi ugrožena područja. Takve su operacije temeljne za planiranje zaštite okoliša i procjenu rizika.

Reprojekcija pretvara skupove podataka u zajednički koordinatni referentni sustav i osigurava prostornu dosljednost. Navedene operacije čine analitičku osnovu GIS-a i podržane su u prostornim bazama kao što su PostGIS i Oracle Spatial.

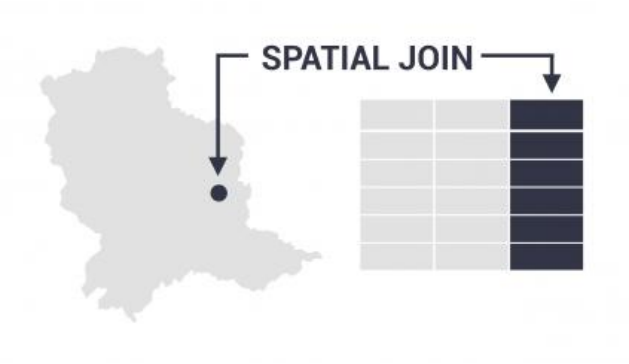

Slika 3.9. Primjer prostornog spajanja (prilagođeno prema [32]).9[32]

Suvremeni trendovi primjene umjetne inteligencije i strojnog učenja u geoprostornoj analizi

Umjetna inteligencija (UI, engl. AI) i strojno učenje (engl. machine learning, ML) sve više mijenjaju geoprostornu analizu omogućujući automatiziranu, skalabilnu i inteligentnu obradu prostornih podataka. Njihovo povezivanje s geoprostornim tehnologijama često se naziva geoprostornom umjetnom inteligencijom (GeoAI). Riječ je o području koje se brzo razvija i mijenja načine prikupljanja, tumačenja i primjene prostornih informacija.

Automatizacija i izdvajanje značajki

Modeli umjetne inteligencije i strojnog učenja, posebno metode dubokog učenja, sve se češće koriste za automatizaciju složenih geoprostornih zadataka kao što su klasifikacija slika, izdvajanje značajki i otkrivanje promjena na satelitskim i zračnim snimkama. Postupci koji su nekoć zahtijevali opsežno ručno tumačenje danas se mogu provoditi brže i točnije, čime se znatno poboljšavaju postupci praćenja okoliša, urbanističkog planiranja i kartiranja infrastrukture.

Obrada u stvarnom i gotovo stvarnom vremenu

Zahvaljujući povećanju računalne snage, rubnom računalstvu (edge computing) i optimiziranim algoritmima strojnog učenja, geoprostorni sustavi umjetne inteligencije sve se više približavaju analizi podataka u stvarnom vremenu. Time se omogućuje brže reagiranje na katastrofe, bolje upravljanje prometom i pravodobno praćenje promjena okoliša. Te su mogućnosti presudne u primjenama u kojima kašnjenje može ugroziti kvalitetu odluka.

Integracija podataka visoke prostorne razlučivosti

Sve veća uporaba senzora visoke razlučivosti, kao što su LiDAR, radar sa sintetičkom aperturom (SAR) te multispektralni i hiperspektralni satelitski senzori, pruža bogate višedimenzionalne

prostorne podatke [20]. Pristupi temeljeni na umjetnoj inteligenciji i strojnom učenju, uključujući neuronske mreže i metode fuzije podataka, važni su za njihovu obradu i objedinjavanje u usklađene prikaze za urbane, ekološke ili poljoprivredne analize.[20]

Prediktivno modeliranje i simulacije

Modeli strojnog učenja široko se primjenjuju u prediktivnom prostornom modeliranju [17], primjerice za predviđanje promjena u korištenju zemljišta, učinaka klimatskih promjena i demografskih trendova. Povezivanjem geoprostornih obilježja s okolišnim i socioekonomskim varijablama omogućuju simuliranje budućih scenarija za planiranje i oblikovanje javnih politika.[17]

Inteligentna GIS sučelja i interakcija prirodnim jezikom

Novija istraživanja proučavaju povezivanje generativne umjetne inteligencije i velikih jezičnih modela (LLM) s GIS-om radi razvoja autonomnih GIS agenata. Takvi sustavi omogućuju izvođenje prostornih analiza uputama na prirodnom jeziku, olakšavaju uporabu osobama bez specijalističkog znanja i ubrzavaju analitičke postupke.

Povezanost s održivošću i ciljevima održivog razvoja

Geoprostorna umjetna inteligencija ima sve veću ulogu u praćenju okolišnih izazova i odgovoru na njih, u skladu s ciljevima održivog razvoja Ujedinjenih naroda (SDG). UI i strojno učenje omogućuju preciznije kartiranje pokrova zemljišta, procjenu rizika od katastrofa, praćenje klime i upravljanje resursima te podupiru strategije otpornosti i održivosti utemeljene na podacima.

Etička, objašnjiva i uključiva umjetna inteligencija

Kako se uporaba umjetne inteligencije širi, raste potreba za objašnjivošću, transparentnošću i etičkom primjenom modela strojnog učenja pri prostornom odlučivanju. To uključuje pravednost, ublažavanje pristranosti u prostornim skupovima podataka i dostupnost AI alata širokom krugu korisnika, od istraživača do stručnjaka uključenih u planiranje lokalnih zajednica.

Praktični primjer u Oracle Spatialu: učitavanje i vizualizacija geoprostornih podataka

Kao što je prethodno objašnjeno, geoprostorni podaci sastavni su dio suvremenih aplikacija temeljenih na podacima, od usluga zasnovanih na lokaciji do praćenja okoliša i urbanističkog planiranja. Oracle Spatial [21] pruža pouzdane mogućnosti pohrane, upravljanja, analize i vizualizacije geoprostornih podataka unutar sustava Oracle Database. Proširenjem standardne relacijske baze prostornim funkcionalnostima programerima, GIS stručnjacima i analitičarima omogućuje rad sa složenim skupovima podataka, izvođenje prostornih upita, izradu vizualnih prikaza i uključivanje prostornih analiza u aplikacije.[21]

Oracle Spatial može se koristiti putem Oracleovih usluga u oblaku ili lokalno na osobnom računalu. Lokalna instalacija korisna je jer omogućuje potpun nadzor nad okruženjem, iskušavanje različitih skupova podataka i istraživanje prostornih funkcija baze bez oslanjanja na udaljene poslužitelje ili internetsku vezu. U ovom se poglavlju usredotočujemo na lokalno okruženje s aplikacijom Oracle Spatial Studio [22], razvijenom u Javi za vizualizaciju, upravljanje i analizu prostornih podataka pohranjenih u bazi Oracle.[22]

Prostorni podaci koji se uvoze u Oracle Spatial najčešće potječu iz javno dostupnih izvora, otvorenih skupova podataka ili vlasničkih zbirki. U ovom su primjeru odabrana dva skupa: (1) povijesne putanje tornada u SAD-u od 1950. do 2024. godine, iz izvora National Oceanic and Atmospheric Administration (NOAA) [24], i (2) podaci o gradovima u SAD-u s osnovnim demografskim i geografskim atributima, iz izvora data.gov [26]. NOAA nudi i podatke o povijesnim pojavama tuče te snažnog vjetra za slična razdoblja [25], koji se mogu upotrijebiti u alternativnim vježbama. Odabrani podaci omogućuju demonstraciju vizualizacije, analize blizine i utvrđivanja vremenskih obrazaca. Putanje tornada prikazane su polilinijama koje prate kretanje oluja, dok su gradovi predstavljeni točkama s pripadajućim metapodacima, poput broja stanovnika, savezne države i geografskih koordinata (širine i dužine). Kombinacija točkastih i linijskih podataka prikladna je za prikaz odnosa između različitih prostornih skupova podataka.[24][26][25]

Pri uvozu u Oracle Spatial Studio potrebno je izričito odabrati stupce s geografskom širinom i dužinom, koji služe za izradu točkastih geometrija i njihovo pravilno smještanje u koordinatni referentni sustav. Točno povezivanje stupaca presudno je za ispravan geografski položaj prikazanih objekata. Spatial Studio podržava više koordinatnih referentnih sustava (CRS) i identifikatora prostornih referentnih sustava (SRID), koji određuju način prostornog prikaza podataka. Za globalne skupove često se koristi sustav WGS84, koji omogućuje dosljednu vizualizaciju i usporedbu. Pogrešno zadani SRID ili neispravno pridružene koordinate mogu

uzrokovati pomaknute točke, netočne izračune udaljenosti i nevaljane analize. Zato je taj korak važan u svakom geoprostornom postupku.

Vremenski obuhvat analize određen je dostupnošću povijesnih podataka o tornadima od 1950. do 2024. godine. Dugačak vremenski niz omogućuje prepoznavanje trendova u učestalosti, pojavljivanju i geografskom rasporedu ekstremnih vremenskih događaja. Uključivanjem vremenskih atributa moguće su i analize koje nadilaze statički prikaz, primjerice ispitivanje promjena putanja oluja tijekom desetljeća, izračun učestalosti oluja koje zahvaćaju određene gradove ili povezivanje ekstremnih događaja s okolišnim i socioekonomskim čimbenicima.

Nakon uvoza podataka, izradom projekta u Spatial Studiju stvara se organizirano okruženje za vizualizaciju i analizu. Projekt je interaktivni radni prostor u kojem se skupovi podataka mogu slagati u slojeve, uređivati i pretraživati. Korisnici mogu izvoditi prostorne operacije poput stvaranja tampon-zona (buffer), presijecanja, traženja najbližih susjeda i grupiranja, uz vizualno istraživanje pomoću slojeva, boja i filtriranja atributa. Te funkcije olakšavaju razumijevanje prostornih obrazaca i odnosa te podupiru znanstveno i operativno odlučivanje.

Spatial Studio uključuje i sustav praćenja zadataka za upravljanje dugotrajnim postupcima, primjerice uvozom podataka, složenim prostornim upitima i skupnim operacijama. Taj sustav prikazuje stanje izvršavanja i napredak u stvarnom vremenu te omogućuje otkrivanje pogrešaka i poboljšavanje učinkovitosti postupaka. Posebno je koristan za velike skupove podataka koji obuhvaćaju više desetljeća ili tisuće zapisa jer omogućuje odzivno i ponovljivo provođenje analiza.

Integracija s bazom Oracle Database osigurava pohranu svih uvezenih i obrađenih podataka u relacijskom obliku koji se može pretraživati upitima. Tablice nastale uvozom čuvaju metapodatke kao što su vremenske oznake, SRID, vrste geometrije i pridruženi atributi. Takva struktura olakšava daljnju analizu SQL upitima, prostornim funkcijama i alatima strojnog učenja povezanima s bazom te predstavlja poveznicu između izvornih geoprostornih podataka i napredne analitike.

Ukratko, postupak u ovoj praktičnoj vježbi obuhvaća odabir prikladnih skupova podataka, određivanje koordinatnih stupaca, dodjeljivanje prostornih referentnih sustava, izradu projektnog radnog prostora te izvođenje vizualnih i analitičkih operacija. Time se pokazuje kako Oracle Spatial Studio objedinjuje upravljanje podacima, geoprostornu analizu i vizualizaciju na jednoj platformi te pruža osnovu za složenija istraživanja obrazaca u okolišu, urbanističko planiranje i procjenu rizika.

Prvi koraci (preduvjeti)

Za praćenje ovih uputa i izvođenje vježbi na računalu trebate lokalno instalirati sljedeće programe:

1. **Oracle Database Express Edition (XE) – besplatno, manje zahtjevno izdanje sustava Oracle Database, prikladno za lokalni razvoj. Podržava osnovne funkcije baze podataka i izradu prostornih shema potrebnih za Oracle Spatial. (Poveznica za preuzimanje)**LINK for download
2. **Oracle SQL Developer – stolni program s grafičkim sučeljem za povezivanje s bazama Oracle, izvođenje SQL naredbi, upravljanje shemama i pregled podataka. Oracle nudi i proširenje SQL Developer za Visual Studio Code, ali u ovim se uputama koristi samostalna stolna inačica. (Poveznica za preuzimanje)**LINK for download
3. **Oracle Spatial Studio – aplikacija namijenjena radu s prostornim podacima u sustavu Oracle Database. Pruža grafičko okruženje za uvoz skupova podataka, izradu projekata, izvođenje prostornih analiza te prikaz rezultata na interaktivnim kartama i grafikonima. (Poveznica za preuzimanje)**LINK for download

Zajedno te komponente čine cjelovito okruženje u kojem se geoprostorni podaci mogu učitavati, obrađivati, analizirati i vizualizirati na organiziran i interaktivan način.

Upoznavanje okruženja Spatial Studio

Tijek rada u Oracle Spatial Studiju temelji se na nekoliko ključnih pojmova koje valja razumjeti prije praktičnog rada:

- **Connections (veze): veza povezuje aplikaciju s određenom instancom baze podataka Oracle. Obuhvaća vjerodajnice, podatke o poslužitelju i prava pristupa shemama. Uspostavljanje veze prvi je korak za pristup prostornim podacima jer Spatial Studio bez nje ne može dohvaćati ni mijenjati skupove podataka.**
- **Datasets (skupovi podataka): predstavljaju izvore podataka pohranjene lokalno ili u povezanoj bazi podataka. Skup može sadržavati točke, linije, poligone ili druge prostorne objekte i služi kao glavni ulaz za analizu i vizualizaciju. Može biti statičan, sa stalnim sadržajem, ili dinamičan, s promjenama koje odražavaju ažuriranja izvorne baze.**
- **Projects (projekti): organizirani radni prostori u Spatial Studiju. U projektu korisnici mogu povlačenjem i ispuštanjem dodavati skupove podataka, prikazivati ih na kartama i konfigurirati analize. Projekti omogućuju eksperimentiranje sa složenim upitima i vizualizaciju rezultata bez mijenjanja izvornih skupova podataka.**

- **Jobs (zadaci): pozadinski procesi koji prate izvođenje postupaka, poput uvoza podataka, analiza i transformacija. Prikazuju napredak te omogućuju asinkrono izvođenje dugotrajnijih operacija kako bi korisničko sučelje ostalo odzivno.**

Razumijevanje tih sastavnica nužno je jer čine osnovu tijeka rada u Spatial Studiju i određuju način korisničke interakcije s prostornim podacima.

Praktični primjer: uvoz i vizualizacija putanja tornada

Za prikaz mogućnosti Oracle Spatiala poslužit ćemo se prethodno opisanima dvama skupovima podataka: povijesnim putanjama tornada na području SAD-a od 1950. do 2024. godine i popisom američkih gradova s osnovnim demografskim i geografskim podacima. Ti skupovi pružaju prikladnu osnovu za demonstraciju prostornih upita, vizualizacije i analize.

U novom projektu otvorite ploču Datasets u Spatial Studiju i odaberite Create Dataset, kako je prikazano na slici 3.10. Zatim odaberite odgovarajući datotečni format (CSV, GeoJSON ili Shapefile), kao na slici 3.11. Za svaki skup s geografskim koordinatama potrebno je izričito navesti stupce koji sadržavaju geografsku širinu i dužinu. Spatial Studio koristi te podatke za pravilno tumačenje koordinata i stvaranje točkastih objekata na karti. U primjeru s gradovima stupci se zovu lat i lon i potrebno ih je pravilno pridružiti koordinatama, kao na slici 3.12.Slika 3.10. Izrada novog skupa podataka iz tablice ili postojećeg skupa u Oracle Spatial Studiju.10Slika 3.11. Učitavanje lokalnog skupa podataka u projekt.11Slika 3.12. Određivanje stupaca za geografsku širinu i dužinu radi stvaranja točaka na karti svijeta.12

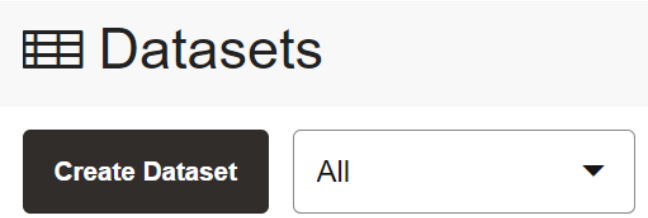

Slika 3.10. Izrada novog skupa podataka iz tablice ili postojećeg skupa u Oracle Spatial Studiju.10

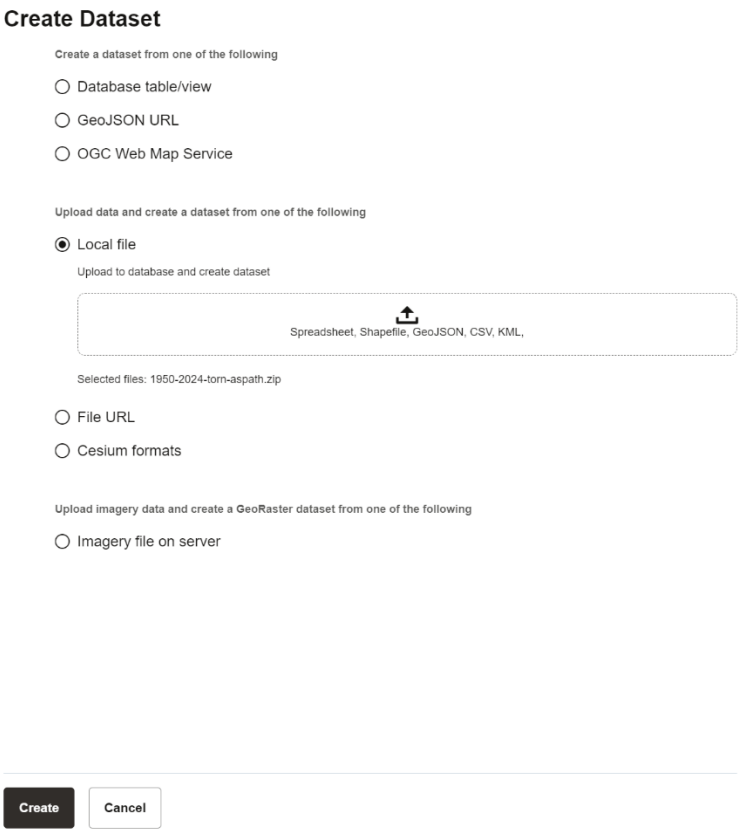

Slika 3.11. Učitavanje lokalnog skupa podataka u projekt.11

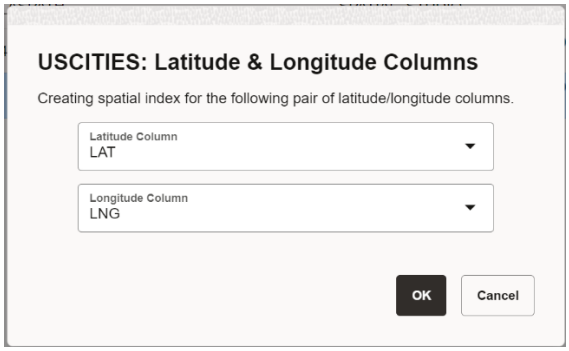

Slika 3.12. Određivanje stupaca za geografsku širinu i dužinu radi stvaranja točaka na karti svijeta.12

Nakon uvoza izradite novi projekt (Project) i dodajte oba skupa podataka. Zatim ih povucite na kartu kako bi nastali njihovi vizualni prikazi. Putanje tornada prikazivat će se linijama ili polilinijama koje prate njihovo kretanje kroz SAD, a gradovi točkama na odgovarajućim geografskim koordinatama (slika 3.13). Takav prikaz olakšava razumijevanje prostornih odnosa između

skupova podataka. Izgled slojeva može se prilagoditi promjenom boje, veličine i drugih svojstava prikaza.Slika 3.13. Prikaz podataka na karti u Oracle Spatial Studiju.13

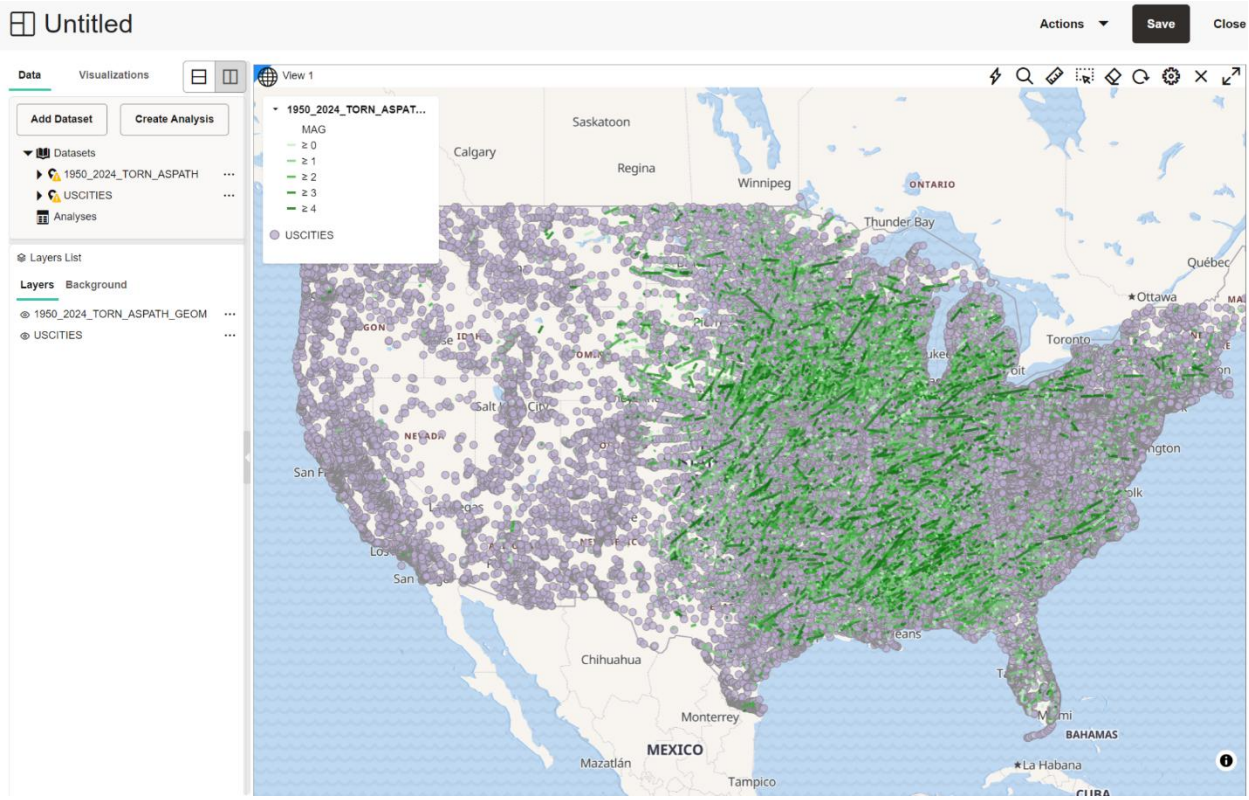

Slika 3.13. Prikaz podataka na karti u Oracle Spatial Studiju.13

Oracle Spatial Studio sadrži niz alata za prostorne analize. Primjerice, možete izračunati udaljenosti gradova od putanja tornada kako biste odredili koja su urbana područja povijesno bila izložena jakim vremenskim nepogodama. Moguće je i prepoznati skupine područja visokog rizika, pronaći presijecanja prostornih slojeva ili izračunati površine zahvaćene određenim događajima. Te operacije koriste prostorno indeksiranje i mogućnosti upita u Oracle Databaseu, što omogućuje učinkovite izračune nad velikim skupovima podataka.

Operacije prostorne analize

Oracle Spatial pruža opsežan skup ugrađenih prostornih operacija i alata koji klasične SQL upite proširuju geografskim mogućnostima. Korisnici mogu analizirati ne samo atribute nego i prostorne odnose geografskih objekata poput točaka, linija i poligona. Temelj njegovih analitičkih mogućnosti čine prostorni predikati i funkcije za uobičajene GIS operacije: izračun udaljenosti, otkrivanje presijecanja, provjeru sadržavanja, traženje objekata u blizini i izradu tampon-zona. Tim se operacijama utvrđuje preklapaju li se dvije geometrije, nalazi li se točka unutar zadanog područja

ili kolika je udaljenost između objekata. Upiti se izvršavaju izravno u sustavu baze podataka i koriste prostorne indekse za bolju učinkovitost, osobito kod velikih skupova podataka.

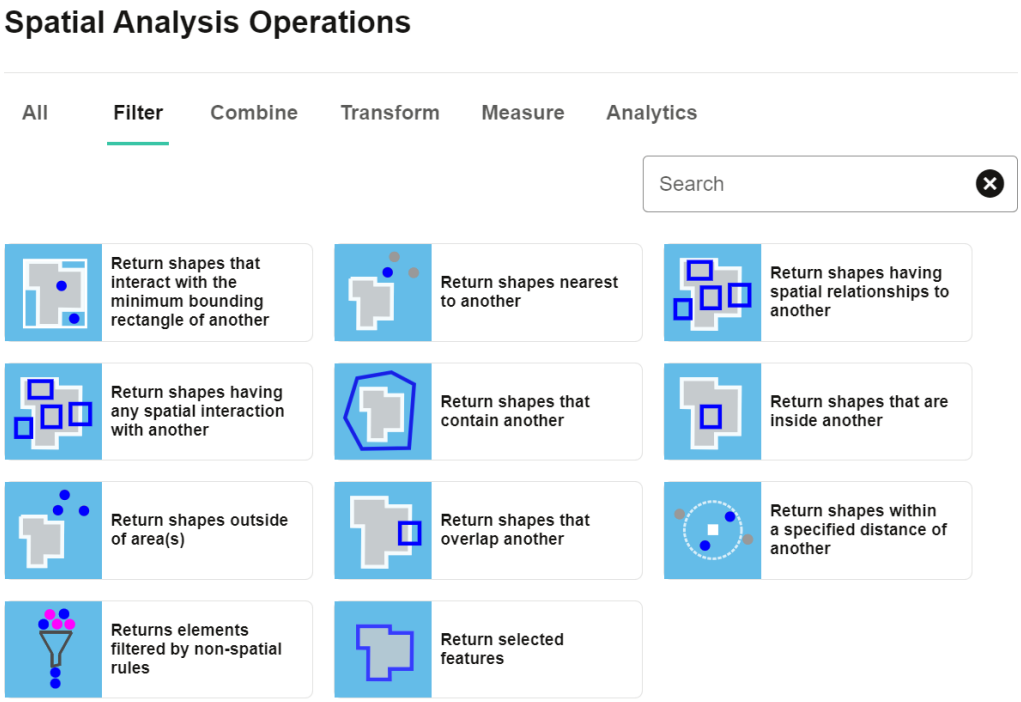

Slika 3.14. Alati za operacije prostorne analize.14

Uz osnovne prostorne predikate, Oracle Spatial podržava naprednije analitičke operacije. Izrada tampon-zona (buffer) omogućuje definiranje područja oko prostornih objekata te je korisna u analizama blizine, primjerice pri utvrđivanju gradova koji se nalaze na određenoj udaljenosti od putanja oluja ili prometnih koridora. Operacije preklapanja i presijecanja objedinjuju prostorne slojeve radi pronalaženja zajedničkih područja, što je korisno za procjenu izloženosti ekstremnim vremenskim događajima ili ugroženosti infrastrukture. Dostupne su i funkcije prostornog agregiranja i transformacije geometrija, uključujući njihovo pojednostavljivanje, reprojekciju te izračun površine i duljine. Sve te operacije čine snažan skup analitičkih alata prikazan na slici 3.14, koji omogućuje istraživanje, vizualizaciju i tumačenje prostornih obrazaca u jedinstvenom okruženju baze podataka.Slika 3.14. Alati za operacije prostorne analize.14

Nakon analize rezultati se mogu spremiti u bazu kao novi skupovi podataka, izvesti u vanjske datoteke za izvješćivanje ili prikazati neposredno u projektu. Spatial Studio podržava više izvoznih formata te tako osigurava kompatibilnost s drugim GIS programima i platformama za razmjenu podataka.

Primjer prostorne operacije jest analiza blizine kojom se procjenjuju udaljenosti među objektima. Oracle Spatial nudi predikate temeljene na udaljenosti, pa je moguće izdvojiti gradove unutar određenog radijusa od putanje oluje. To je osobito korisno pri procjeni okolišnih rizika kada se izloženost određuje geografskom blizinom, a ne izravnim presijecanjem. Sljedeći upit odabire gradove koji se nalaze unutar 50 kilometara od bilo koje putanje oluje:

```
SELECT c.city_name
FROM cities c, storm_paths s
WHERE SDO_WITHIN_DISTANCE(
        c.geom,
        s.geom,
        'distance=50 unit=km'
      ) = 'TRUE';
```

Osim blizine, topološki odnosi imaju važnu ulogu u prostornoj analizi. Oracle Spatial podržava predikate kao što su intersects (presijeca), contains (sadržava) i inside (unutar), koji opisuju međusobne odnose dviju geometrija u prostoru. Primjerice, funkcijom SDO_RELATE moguće je utvrditi presijeca li putanja oluje određenu administrativnu regiju:

```
SELECT r.region_name
FROM regions r, storm_paths s
WHERE SDO_RELATE(
        r.geom,
        s.geom,
        'mask=ANYINTERACT'
      ) = 'TRUE';
```

Važna je i izrada tampon-zona, pri kojoj nastaju nove geometrije koje predstavljaju pojaseve oko postojećih prostornih objekata. Takve se zone koriste za modeliranje područja utjecaja, primjerice područja zahvaćenoga olujom uz njezinu putanju. Nastala geometrija može se pohraniti, prikazati ili dalje analizirati. Sljedeći primjer prikazuje izradu tampon-zone oko putanja oluja:

```
SELECT SDO_GEOM.SDO_BUFFER(
         s.geom,
         25,
         0.005
       ) AS buffer_geom
FROM storm_paths s;
```

Oracle Spatial podržava i prostorna mjerenja te operacije nad geometrijama, uključujući izračun udaljenosti, površina i presijecanja. Time omogućuje kvantitativnu prostornu analizu, primjerice utvrđivanje točne udaljenosti grada od putanje oluje ili površine presjeka dvaju prostornih objekata. U nastavku je primjer izračuna udaljenosti između odabranog grada i putanje oluje:

```
SELECT SDO_GEOM.SDO_DISTANCE(
         c.geom,
         s.geom,
         0.005
       ) AS distance_in_units
FROM cities c, storm_paths s
WHERE c.city_name = 'Tucson';
```

Zajedno te prostorne operacije čine analitičku osnovu Oracle Spatiala. Kombiniranjem prostornih predikata, izračuna udaljenosti i transformacija geometrije korisnici mogu nadići jednostavan kartografski prikaz te provoditi sustavne prostorne analize izravno u bazi podataka. Integrirani pristup omogućuje ponovljive, skalabilne i razumljive GIS postupke prikladne za znanstvena istraživanja, nastavu i donošenje odluka u praksi.

Prostorna analiza: gradovi unutar 100 km od putanje oluje

Iako se prostorne analize u Oracle Spatialu mogu zapisati SQL funkcijama, u većini uobičajenih postupaka nije potrebno ručno pisati upite. Oracle Spatial Studio pruža grafičko, interaktivno sučelje u kojem se operacije poput izrade tampon-zona, presijecanja, traženja objekata u blizini i prostornog filtriranja izvode kroz izbornike i dijaloške okvire. Korisnik odabire skupove podataka, željenu prostornu operaciju i parametre poput granične udaljenosti ili geometrijskih odnosa. Spatial Studio zatim automatski stvara i izvršava odgovarajuće SQL naredbe u pozadini. Tako se složenost sintakse prostornih funkcija skriva od korisnika, a omogućuje provedba naprednih analiza i osobama s manje iskustva u SQL-u i GIS programiranju.

U sljedećem primjeru analizirat ćemo putanju oluje i gradove udaljene najviše sto kilometara od nje. Najprije u izborniku radnji sloja s putanjama oluja pokrenite novu prostornu analizu, kao što je prikazano na slici 3.15.Slika 3.15. Izbornik radnji podatkovnog sloja.15

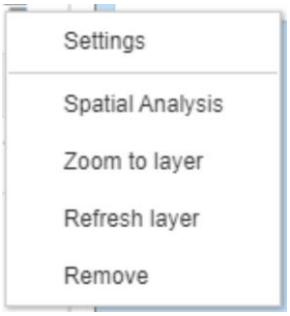

Slika 3.15. Izbornik radnji podatkovnog sloja.15

Otvorit će se prozor prostornih analiza s brojnim dostupnim operacijama. Pronađite i odaberite Return shapes within a specified distance of another, prikazanu na slici 3.16. U ovoj ćemo vježbi

filtrirati gradove koji se nalaze u blizini odabranog tornada.Slika 3.16. Odabir potrebne prostorne operacije.16

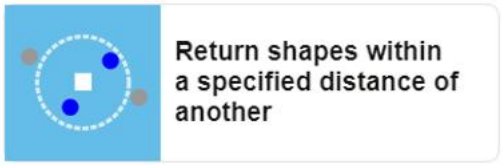

Slika 3.16. Odabir potrebne prostorne operacije.16

Prostorna operacija within distance (unutar zadane udaljenosti) često se primjenjuje u analizama blizine jer omogućuje odabir geografskih objekata prema međusobnoj udaljenosti, a ne samo prema izravnom geometrijskom preklapanju. Za razliku od upita koji zahtijevaju presijecanje dviju geometrija, analiza udaljenosti može obuhvatiti posredne utjecaje i prostornu blizinu. Zato je prikladna za analizu mogućeg djelovanja linearnih pojava, poput putanja oluja, prometnih koridora ili rijeka, na okolne točkaste objekte, primjerice gradove i infrastrukturne objekte. Određivanjem granične udaljenosti geografska se blizina pretvara u mjerljiv i ponovljiv kriterij.

Nakon odabira operacije otvara se novi prozor u kojem treba odrediti sloj za filtriranje, u našem slučaju putanju oluje, te udaljenost i mjernu jedinicu. Za ovu vježbu odaberite sto kilometara, kao na slici 3.17. Nakon izvođenja analiza se pojavljuje na lijevoj strani u odjeljku analiza, odakle je možete povući na kartu. Kao i ostale slojeve, rezultate možete prilagoditi bojom, oblikom i veličinom simbola radi preglednijeg prikaza, osobito pri preklapanju s već učitanim skupovima podataka (slika 3.18). Parametre je moguće naknadno promijeniti u izborniku radnji analize. Primjerice, povećate li udaljenost sa 100 na 200 kilometara i ponovno pokrenete postupak, prikazat će se i gradovi koji su udaljeniji od putanje tornada.Slika 3.17. Određivanje sloja, udaljenosti i mjerne jedinice za filtriranje.17Slika 3.18. Završna karta izrađena primjenom prostorne analize.18

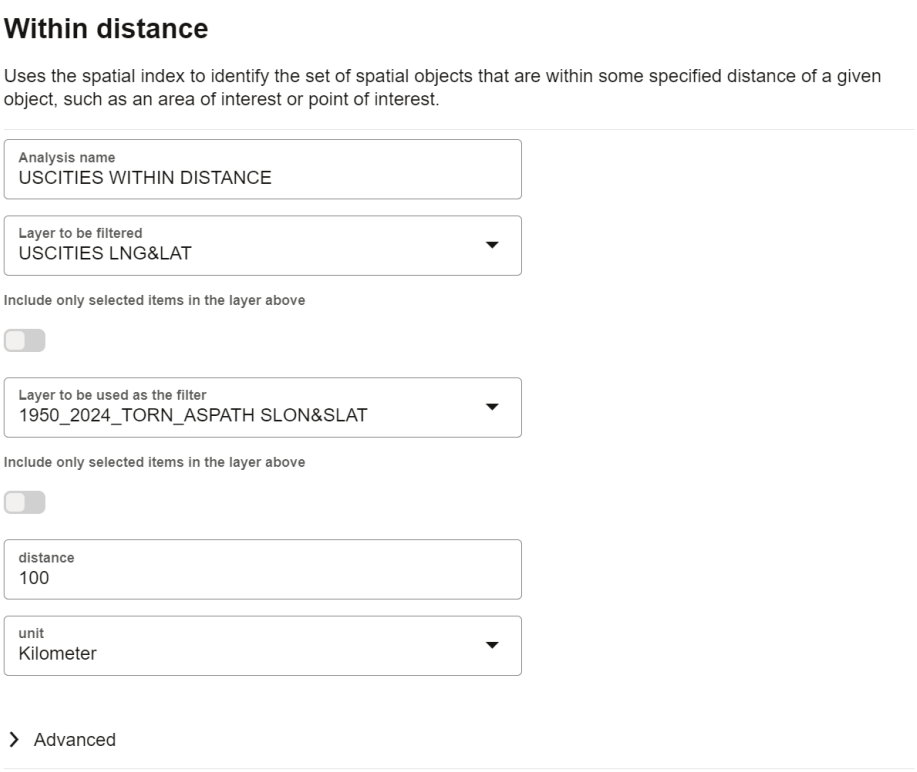

Slika 3.17. Određivanje sloja, udaljenosti i mjerne jedinice za filtriranje.17

Važna prednost ovoga pristupa njegova je interaktivnost. Promjenom granične udaljenosti i ponavljanjem analize odmah se može uočiti kako se broj obuhvaćenih gradova mijenja s povećanjem ili smanjenjem zone utjecaja. Tako se omogućuje analiza različitih scenarija, pri čemu se pretpostavke o udaljenosti utjecaja mogu iskušavati bez mijenjanja izvornih podataka. Takvo iterativno istraživanje jedna je od glavnih prednosti grafičkih GIS alata: korisnik stječe osjećaj za prostornu osjetljivost i mjerilo, a pritom zadržava analitičku dosljednost.

Iako korisnik pri ovoj analizi ne piše programski kod, u svojstvima se može pregledati SQL upit koji je Spatial Studio automatski sastavio primjenom prostornih operatora za traženje objekata na zadanoj udaljenosti.

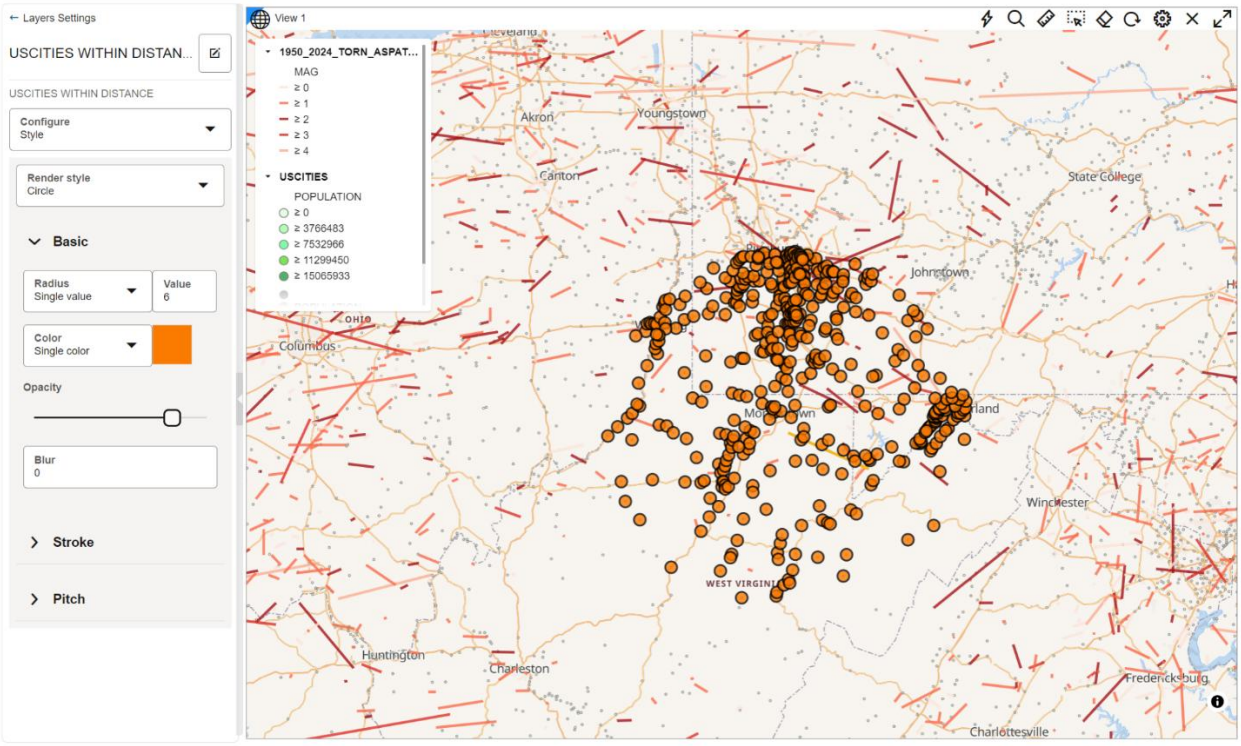

Slika 3.18. Završna karta izrađena primjenom prostorne analize.18

Premda se primjer odnosi na jednu putanju oluje i zadanu graničnu udaljenost, ista se operacija može primijeniti na brojne druge prostorne scenarije. Upiti temeljeni na blizini često se koriste u urbanističkom planiranju, procjeni okolišnih rizika, analizi infrastrukture i upravljanju hitnim situacijama kako bi se prepoznala područja mogućeg utjecaja ili izloženosti. Povezivanjem interaktivne vizualizacije s prostornim izračunima u bazi podataka Oracle Spatial Studio omogućuje pouzdane analize blizine bez ručnog pisanja SQL-a, a zadržava transparentnost zahvaljujući mogućnosti pregleda automatski generiranih upita. Operacija within distance zato je važna osnova naprednijih GIS analiza i sustava za potporu prostornom odlučivanju.

Zadaci za vježbu

- Preuzmite geoprostorne podatke o putanjama oluja i gradovima u odabranoj državi ili regiji, primjerice Europi (npr. Eurostat [40], Natural Earth [41], izvori temeljeni na OpenStreetMapu [42], putanje oluja ili ekstremnih vremenskih pojava iz EUMETSAT-a [43], reanalize ECMWF-a [44] ili europske meteorološke arhive).[40][41][42][43][44]
- Uvezite preuzete skupove podataka u Oracle Spatial Studio pomoću podržanih formata, primjerice CSV ili GeoJSON.

- Odredite prostorne atribute i koordinatne sustave: pravilno pridružite stupce geografske širine i dužine te dodijelite odgovarajući prostorni referentni sustav kako biste osigurali točan geografski prikaz.
- Vizualizirajte prostorne podatke u projektnom radnom prostoru preklapanjem više slojeva (npr. putanja oluja i položaja gradova) na interaktivnoj karti.
- Izvedite prostorne pokazatelje iz geografskih odnosa, primjerice udaljenost svakog grada do najbliže putanje oluje, broj putanja koje presijecaju određenu administrativnu regiju ili prostornu gustoću olujnih događaja tijekom vremena.
- Izvedite prostorne upite i analize, uključujući izradu tampon-zona, presijecanje i analizu blizine.
- Prikažite rezultate prostornom vizualizacijom pomoću tematskih karata, slojeva različitih boja i prikaza prilagođenog atributima.
- Protumačite prostorne obrasce i rezultate, odredite regije izloženije olujama te raspravite o mogućim geografskim i okolišnim čimbenicima.
- Usporedite prostorne obrasce u različitim razdobljima i procijenite je li se geografska raspodjela ili jačina utjecaja oluja mijenjala tijekom vremena.

Provjera znanja

Koja je osnovna svrha geografskog informacijskog sustava (GIS)?

A. Pohrana numeričkih podataka u tablicama
B. Analiza i vizualizacija podataka prema geografskom položaju
C. Zamjena relacijskih baza podataka
D. Stvaranje modela strojnog učenja

Koja tvrdnja najbolje opisuje prostorni tip podataka?

A. Tip podataka koji se koristi isključivo za analizu vremenskih nizova
B. Tip podataka koji prikazuje geografske objekte poput točaka, linija i poligona
C. Sažeti format za velike skupove podataka
D. Tip podataka koji se koristi isključivo za rasterske slike

Koja je uloga koordinatnog referentnog sustava (CRS) u GIS aplikacijama?

A. Određivanje načina šifriranja geografskih podataka
B. Određivanje načina projekcije i položaja prostornih podataka na Zemljinoj površini
C. Upravljanje pravima pristupa bazi podataka
D. Optimizacija brzine izvršavanja upita

Koja je prostorna operacija najprikladnija za pronalaženje gradova koji se nalaze unutar zadane udaljenosti od putanje oluje?

A. Filtriranje prema atributima
B. Izrada tampon-zona i analiza blizine
C. Normalizacija podataka
D. Spajanje tablica

Kako Oracle Spatial Studio korisnicima olakšava prostornu analizu?

A. Zahtijeva ručno pisanje složenih prostornih SQL upita
B. Ograničava analizu na unaprijed zadane skupove podataka
C. Omogućuje grafičko sučelje koje automatski stvara prostorne upite
D. Pohranjuje prostorne podatke izvan baze podataka

Literatura

[1] Goodchild, M. F. *Geographical Information Science.* International Journal of Geographical Information Systems *6,* no. 1 (1992): 31–45. https://doi.org/10.1080/02693799208901893

[2] Longley P. A., Goodchild M. F., Maguire D. J., and Rhind D. W.. *Geographic Information Systems and Science*. 4th ed. Hoboken, NJ: Wiley, 2015.

[3] Wael A., Suhaib M., Adel E.S., Salem M. *Tigris River water surface quality monitoring using remote sensing data and GIS techniques*. The Egyptian Journal of Remote Sensing and Space Sciences, Volume 26, Issue 3, December 2023, Pages 816-825, https://doi.org/10.1016/j.ejrs.2023.09.001

[4] NASA Earth Observatory. *Remote Sensing and GIS for Environmental Monitoring*. https://earthobservatory.nasa.gov (Accessed January 2026)

[5] NASA Earthdata. *Worldview: Interactive Visualization of Earth Science Data*. https://worldview.earthdata.nasa.gov (Accessed January 2026)

[6] Burrough, Peter A., Rachael A. McDonnell, and Christopher D. Lloyd. *Principles of Geographical Information Systems*. 3rd ed. Oxford: Oxford University Press, 2015.

[7] Global Forest Watch. *Forest Monitoring Designed for Action.* https://www.globalforestwatch.org/ (Accessed January 2026)

[8] *GIS Data Types: Vector vs. Raster.* Geospatial Innovation Facility, UC Berkeley, http://gif.berkeley.edu/documents/GIS_Data_Formats.pdf (Accessed January 2026)

[9] Open Geospatial Consortium (OGC). *OGC Standards and Geospatial Interoperability*. https://www.ogc.org/standards (Accessed January 2026).

[10] Environmental Systems Research Institute (ESRI). *What Is GIS?* Environmental Systems Research Institute. https://www.esri.com/en-us/what-is-gis (Accessed January 2026)

[11] Heywood, Ian, Sarah Cornelius, and Steve Carver. *An Introduction to Geographical Information Systems*. 4th ed. Harlow, UK: Pearson Education, 2011.

[12] ISO. *ISO 19157:2013 – Geographic Information: Data Quality*. Geneva: International Organization for Standardization, 2013.

[13] U.S. Geological Survey (USGS). *Real-time Data and Maps.* https://www.usgs.gov (Accessed January 2026)

[14] Natural Earth. *Free Vector and Raster Map Data*. (Accessed January 2026). https://www.naturalearthdata.com

[15] QGIS Project. *QGIS Documentation*. https://www.qgis.org. (Accessed January 2026).

[16] PostGIS. PostGIS *Documentation*. https://postgis.net/ (Accessed January 2026).

[17] Yenra.com. *AI Techniques in Geospatial Analysis*. https://yenra.com/ai-tech/geospatial-analysis. (Accessed January 2026).

[18] L. Tum, T. Dedring, A. Rienow. *Geospatial Intelligence for Sustainable Futures: Smart Data and AI Applications in Geographic Education*. NFDI4Earth Project. https://lps25.esa.int/lps25-presentations/poster/Geospatial%20Intelligence%20for%20Sustainable%20Futures%20S

mart%20Data%20and%20AI%20Applications%20in%20Geographic%20Education.pdf (Accessed January 2026).

[19] GeoWGS84AI. *GeoAI: Transforming GIS with AI and Deep Learning.* https://www.geowgs84.ai/post/geoai-transforming-gis-with-ai-and-deep-learning (Accessed January 2026).

[20] S. Somvanshi, D. Kumar, M. Kumari. *Trends of recent data, AI/ML approaches for geospatial AI in Earth observation towards sustainable development goals.* ITU Journal on Future and Evolving Technologies, Volume 6 (2025), Issue 1, Pages 11-28. March 2025. doi: https://doi.org/10.52953/CDIE7940

[21] Oracle. Spatial Database (OracleSpatial). https://www.oracle.com/database/spatial-database/ (Accessed January 2026).

[22] Oracle. Spatial Studio. https://docs.oracle.com/en/database/oracle/spatial-studio/25.2/index.html (Accessed January 2026).

[23] Oracle. *Oracle Spatial Studio Guide.* https://docs.oracle.com/en/database/oracle/spatial-studio/21.2/spstu/using-spatial-studio.html#GUID-6C58FFBA-7419-471C-BDDD-7554BEC049EA (Accessed January 2026).

[24] National Oceanic and Atmospheric Administration (NOAA). *Tornado Statistics Data.* https://www.ncei.noaa.gov/access/monitoring/tornadoes/ (Accessed January 2026).

[25] National Oceanic and Atmospheric Administration (NOAA). *Various Monitoring Information Data.* https://www.ncei.noaa.gov/access/monitoring/products (Accessed January 2026).

[26] DATA.GOV. *Dataset of U.S. cities (including basic demographic and geographic attributes).* https://catalog.data.gov/dataset/?tags=cities&_tags_limit=0 (Accessed January 2026).

Dodatni izvori za učenje GIS-a

[27] [REF] PostGIS Project. Introduction to PostGIS. PostGIS Introduction Workshop. PostGIS, https://postgis.net/workshops/postgis-intro/ (Accessed January 2026)

[28] [REF] GISGeography, Learn GIS and Geography, https://gisgeography.com (Accessed January 2026)

[29] [REF] GISGeography, The Ultimate List of GIS Formats and Geospatial File Extensions, https://gisgeography.com/gis-formats/ (Accessed January 2026)

[30] [REF] GISGeography, Vector vs Raster in GIS: What's the Difference? https://gisgeography.com/spatial-data-types-vector-raster/ (Accessed January 2026)

[31] *Principles of GIS and Remote Sensing*. Free Online Course. https://principles-and-applications-of-rs-and-gis.readthedocs.io/en/stable/index.html# (Accessed January 2026)

[32] GISGeography. *Learn GIS and Geography*. https://gisgeography.com/spatial-join/ (Accessed January 2026)

Izvori podataka

[33] NASA Earth Observatory. *Global Maps.* https://science.nasa.gov/earth/earth-observatory/global-maps/ (Accessed January 2026)

[34] Global Forest Watch. *Forest Monitoring Designed for Action.* (Accessed January 2026) https://www.globalforestwatch.org/map/?menu=eyJkYXRhc2V0Q2F0ZWdvcnkiOiJmb3Jlc3RDaGFuZ2UiLCJtZW51U2VjdGlvbiI6ImRhdGFzZXRzIn0%3D

[35] ESA Climate Office. *Data*. https://climate.esa.int/en/data/ (Accessed January 2026)

[36] NASA GISS (Goddard Institute for Space Studies). *Datasets and Images.* https://data.giss.nasa.gov (Accessed January 2026)

[37] NOAA Climate.gov. *Maps*. https://www.climate.gov/maps-data (Accessed January 2026)

[38] Copernicus Data Space Ecosystem. ESA. *Data Collections*. (Accessed January 2026). https://dataspace.copernicus.eu/data-collections

[39] U.S. Geological Survey (USGS) EarthExplorer. *Datasets.* (Accessed January 2026). https://earthexplorer.usgs.gov

[40] Eurostat. *Data*. https://ec.europa.eu/eurostat/data (Accessed January 2026).

[41] Natural Earth. Free vector and raster map data. https://www.naturalearthdata.com (Accessed January 2026).

[42] OpenStreetMap. Export data. (Accessed January 2026). https://www.openstreetmap.org/export#map=18/41.984784/21.419346

[43] EUMETSAT. User Portal. https://user.eumetsat.int/catalogue (Accessed January 2026).

[44] European Centre for Medium-Range Weather Forecasts (ECMWF). Charts Catalogue. https://charts.ecmwf.int (Accessed January 2026).