Upravljanje prostorno-vremenskim podatcima povezivanjem grafičkih i kartografskih prikaza

Ivanković, Damir

Doctoral thesis / Disertacija

2023

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of Electrical Engineering, Mechanical Engineering and Naval Architecture / Sveučilište u Splitu, Fakultet elektrotehnike, strojarstva i brodogradnje**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:179:497669

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-20**

Repository / Repozitorij:

Repository of the Faculty of Electrical Engineering, Mechanical Engineering and Naval Architecture - University of Split

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

S V E U Č I L I Š T E U S P L I T U FAKULTET ELEKTROTEHNIKE,
STROJARSTVA I BRODOGRADNJE

Damir Ivanković

UPRAVLJANJE PROSTORNO VREMENSKIM PODATCIMA POVEZIVANJEM GRAFIČKIH I KARTOGRAFSKIH PRIKAZA

DOKTORSKA DISERTACIJA

Split, 2022.

S V E U Č I L I Š T E U S P L I T U
FAKULTET ELEKTROTEHNIKE, STROJARSTVA I BRODOGRADNJE

Damir Ivanković

Upravljanje prostorno-vremenskim podatcima povezivanjem grafičkih i kartografskih prikaza

DOKTORSKA DISERTACIJA

Split, 2022.

Doktorska disertacija je izrađena na Institutu za oceanografiju i ribarstvo, Split

Mentor: prof dr. sc. Vlado Dadić
Rad br. 181

PODATCI ZA BIBLIOGRAFSKU KARTICU

Ključne riječi: vizualizacija podataka, prostorno-vremenski podatci
Znanstveno područje: Tehničke znanosti
Znanstveno polje: Računarstvo
Znanstvena grana: Informacijski sustavi
Institucija na kojoj je rad izrađen: Institut za oceanografiju i ribarstvo, Split
Mentor rada: prof dr. sc. Vlado Dadić
Lektorirala: Sonja Krvavica
Broj stranica: 126
Broj slika: 72
Broj tablica: 6
Broj korištenih bibliografskih jedinica: 87

Povjerenstvo za ocjenu doktorske disertacije:

1. Izv. prof. dr. sc. Ljiljana Šerić, Fakultet elektrotehnike, strojarstva i brodogradnje, Split
2. Izv. prof. dr. sc. Eugen Mudnić, Fakultet elektrotehnike, strojarstva i brodogradnje, Split
3. Izv. prof. dr. sc. Ante Šiljeg, Sveučilište u Zadru, Odjel za geografiju
4. Izv. prof. dr. sc. Marjan Sikora, Fakultet elektrotehnike, strojarstva i brodogradnje, Split
5. Dr. sc. Ivana Nižetić Kosović, znanstvena suradnica, Ericsson Nikola Tesla d.d.

Povjerenstvo za obranu doktorske disertacije:

1. Izv. prof. dr. sc. Ljiljana Šerić, Fakultet elektrotehnike, strojarstva i brodogradnje, Split
2. Izv. prof. dr. sc. Eugen Mudnić, Fakultet elektrotehnike, strojarstva i brodogradnje, Split
3. Izv. prof. dr. sc. Ante Šiljeg, Sveučilište u Zadru, Odjel za geografiju
4. Izv. prof. dr. sc. Marjan Sikora, Fakultet elektrotehnike, strojarstva i brodogradnje, Split
5. Dr. sc. Ivana Nižetić Kosović, znanstvena suradnica, Ericsson Nikola Tesla d.d.

Disertacija obranjena dana: 24. siječnja 2023.

Prostorno-vremensko upravljanje podatcima povezivanjem grafičkih i kartografskih prikaza

Sažetak:

Prostorno-vremenski podatci mogu se vizualizirati na mnogo različitih načina. Za razliku od uobičajenih statičkih prikaza, dinamičke mrežne stranice omogućuju bolje upravljanje prostorno-vremenskim podatcima i lakše otkrivanje novih spoznaja. Napredni prikazi omogućavaju lakše otkrivanje statusa i trenda, pronalaženje ekstremnih vrijednosti u okolišnim podatcima i općenito njihovu bolju iskorištenost. U ovom su radu razvijene i implementirane nove metode prikaza i upravljanja podatcima u mrežnom okolišu. Doprinosi ove disertacije očituju se u tri nove metode: 1) prostorno-vremenske povezane prikaze za uočavanje statusa i trenda u podatcima, 2) prikazi podataka s automatskih mjernih sustava koji omogućuju lakši pronalazak zanimljivih izmjerenih pojava i 3) efikasniji prikaz rezultata numeričkih modela za lakši uvid u detalje i usporedbe s izmjerenim vrijednostima. Za svaku metodu definiran je model arhitekture i implementacije te je pokazano kako nova metoda doprinosi upravljanju podatcima. Implementacija se oslanja na relacijsku bazu podataka, JavaScript i vizualizacije sa klijentske strane. Prikazano je kako nove metode prikaza omogućavaju lakše izvlačenje sadržanih znanja iz podataka koristeći učinkovitu razmjenu podataka između klijenta i servera.

Ključne riječi:
Vizualizacija prostorno-vremenskih podataka na mreži, okolišni podatci, status i trend, automatski mjerni sustavi, vizualizacija numeričkih modela

Spatio-temporal data management achieved by connecting graphical representation with maps

Abstract:

Spatio-temporal data, which includes environmental data, can be visualized in many different ways. Dynamic web pages can facilitate data management and the discovery of new knowledge better than static representations. Improved representations make it easier to identify status and trends and find extreme values in environmental data. In this thesis, new methods for data representation and management in web environment were developed and implemented. The contributions of this dissertation manifest in three new methods: 1) spatio-temporal linked representations for observing status and trends in data, 2) representations of data from automatic measuring systems that make finding interesting measured phenomena easier, and 3) improved visualization of numerical model results for easier comparison with measured values and insight into details. For each method, architecture and implementation models are defined and the contribution of the new method to data management is shown. The implementation is based on a relational database, JavaScript, and client-side visualizations. It is shown how these representation methods enable easier extraction of the contained knowledge from data using efficient data exchange between client and server.

Keywords:
Web spatio-temporal visualisation, environmental data, status and trend, automatic measurements systems, numerical models visualizations

Zahvala

Ovom doktorskom disertacijom zahvalio bih svojoj obitelji, posebno supruzi Luiđi. Isto tako želio bih zahvaliti svojim kolegama sa Instituta za oceanografiju i ribarstvo na dugoj i plodnoj suradnji.

Sadržaj

Sažetak iv
Abstract v
Zahvala vii
Popis tablica xii
Popis slika xv

1. UVOD **1**

2. VIZUALIZACIJA PODATAKA **5**
2.1. Grafička vizualizacija podataka – vrste grafova 6
2.2. Vizualizacija vremenskih podaka – vremenski grafovi 7
2.3. Vizualizacija prostornih podataka 8
2.3.1. Geoinformacijski sustav (GIS) 9
2.4. Vizualizacija prostorno-vremenskih podataka 10
2.5. Vremenska geografija (engl. *Time geography*) 10
2.6. Prostorno-vremenska kocka 11
2.7. Hibridni prostorno-vremenski prikazi 13
2.8. Prikazi bez klasičnih karata 13

3. PRIKAZI PODATAKA NA MREŽI **17**
3.1. Statični unaprijed generirani prikazi 17
3.2. Dinamički i interaktivni grafički prikazi 20
3.3. Asinkrono učitavanje podataka 22
3.4. Dinamički mrežni kartografski prikazi 23
3.5. Kartografski mrežni servisi i standardi 26
3.5.1. Mrežni servis karte - WMS 26
3.5.2. Mrežni servis svojstava - WFS 27
3.5.3. Mrežni servis pokrivenosti - WCS 28
3.5.4. Open Geospatial Consortium servisi 29
3.6. Programski paketi za poslužitelje namijenjeni kreiranju dinamičkih kartografskih prikaza - mrežni GIS 31
3.7. Korištenje relacijskih baza podataka 34
3.8. Relacijske baze i JSON 35

3.9. Relacijske baze i prostorni podatci 36
3.10. Primjeri prikaza prostorno-vremenskih podataka 38
3.10.1. DHMZ - Državni hidrometeorološki zavod 39
3.10.2. Yr prognoze Norveškoga meteorološkog instituta 41
3.11. Zaključak 42

4. PRIKAZI OCEANOGRAFSKIH PODATAKA I POVIJESNI RAZVOJ 43
4.1. Osnovni zahtjevi za rukovanje oceanografskim podatcima 43
4.1.1. Prostorna komponenta 44
4.1.2. Vremenska komponenta 44
4.1.3. Mjerni parametar 44
4.1.4. Vrijednost parametra (izmjerena vrijednost) 45
4.1.5. Vrste podataka i mjerenja 45
4.2. Zašto razvijati vlastita programska rješenja? 46
4.3. Rukovanje oceanografskim podatcima u drugim institucijama 47
4.4. Povijesni razvoj programske podrške 48
4.4.1. Aplikacije bez grafičkog sučelja 49
4.4.2. Aplikacije s grafičkim sučeljem 49
4.4.3. Mrežne aplikacije prve generacije 49
4.4.4. Mrežne aplikacije druge generacije 50
4.4.5. Treća generacija 51
4.5. Zaključak 52

5. OBOSTRANO POVEZANI GRAFIČKI I KARTOGRAFSKI PRIKAZI 53
5.1. Motivacija 53
5.2. Ciljevi istraživanja 54
5.3. Postojeća rješenja 55
5.3.1. Programska rješenja opće namjene 55
5.3.2. Ocean data view 56
5.3.3. WISE Marine 57
5.3.4. Usporedba svojstava postojećih rješenja 58
5.4. Materijali i metode primjenjeni za realizaciju novog rješenja 59
5.4.1. Svojstva podataka 60
5.4.2. Zahtjevi pri vizualizaciji podataka 60
5.4.3. Dizajn i optimizacije relacijske baze 61
5.4.4. Položaj elemenata sučelja 62
5.4.5. Prilagodljiv filtar podataka 65
5.4.6. Provjera 66
5.5. Implementacija 66
5.5.1. Korištene tehnologije 67

5.5.2. Primjer implementacije 68
5.5.3. Implementacija prilagodljivih filtara 68
5.5.4. Dvosmjerno povezivanje grafa i karte 69
5.5.5. Statistika 69
5.5.6. Od statusa do trenda 70
5.5.7. Srednjak za vodeni stupac ili prikaz vrijednosti s pojedine dubine . 71
5.6. Rezultati 71
5.6.1. Implementacija za projekt HarmoNIA 72
5.6.2. Hrvatska nacionalna baza podataka monitoringa 73
5.7. Prostorno-vremenska pretraga podataka (engl. *data mining*) 73
5.8. Zaključak 74

6. PRIKAZ I UPRAVLJANJE PODATCIMA U STVARNOM VREMENU 77
6.1. Područje istraživanja 77
6.2. Ciljevi istraživanja 78
6.3. Postojeća rješenja 78
6.4. Materijali i metode 79
6.4.1. Dohvat podataka i asinkroni prijenos 79
6.4.2. Dizajn baze podataka 80
6.4.3. Elementi sučelja i njihov dizajn 82
6.5. Implementacija 82
6.5.1. Korištene tehnologije 83
6.5.2. Prilagodljiv dizajn 83
6.5.3. Navigacija i upravljanje mrežnom aplikacijom 85
6.5.4. Prostorne komponente i kartografski prikazi 86
6.5.5. Organiziranje podataka 87
6.5.6. Prikaz podataka kao prostornog sloja 88
6.5.7. Upravljanje događajima 89
6.5.8. Korisničke postavke 91
6.5.9. Optimizacije učitavanja stranice 92
6.6. Rezultati 93
6.7. Zaključak 93

7. PRIKAZ REZULTATA NUMERIČKIH MODELA 95
7.1. Područje istraživanja 95
7.2. Ciljevi istraživanja 97
7.3. Postojeća rješenja 97
7.3.1. Usporedba svojstava postojećih rješenja 101
7.4. Materijali i metode za realizaciju novog rješenja 102
7.4.1. Obrada i tijek podataka 102

7.4.2. Dizajn baze podataka 103
7.5. Implementacija 105
7.5.1. Korištena tehnologija i učitavanje podataka 105
7.5.2. Optimizacija prikaza 106
7.5.3. Učitavanje prikaza 107
7.5.4. Upravljanje i kontrole prikaza 108
7.5.5. Glavni prostorni prikaz modela 109
7.5.6. Virtualne postaje - usporedba s mjerenim vrijednostima 111
7.6. Zaključak 112

8. ZAKLJUČAK **115**

LITERATURA **121**

Popis tablica

3.1. Biblioteke za prikaz grafova korištenjem JavaScripta. 21

3.2. Najboljih 10 kartografskih JavaScript biblioteka. 24

5.1. Svojstva postojećih rješenja. 59

5.2. Brzine prikaza mrežne stranice (milisekunde). 72

7.1. Svojstva postojećih rješenja 102

7.2. Postotci ostatka broja polja nakon sažimanja po parametrima 107

Popis slika

2.1. Problem kapaciteta ljudske percepcije 6

2.2. Prikaz količine prodanog sladoleda po kvartalima 8

2.3. Primjer prostorno-vremenske kocke korištenjem točaka za prikaz 12

2.4. Primjer prostorno-vremenske kocke s vremenskim osima 12

2.5. Primjer hibridnog prikaza 13

2.6. Princip prikaza za "Pričajući graf" (Storygraph) 14

2.7. Primjer prikaza kretanja dviju osoba pomoću "Pričajućeg grafa" 14

2.8. Prikaz razvoja D3.js projekta. Označene su linije lokacija s najviše doprinosa (UK i US) kao i lokacije s manje doprinosa (linije) 15

3.1. Primjer statično generiranog prikaza podataka 18

3.2. Primjer statično generiranog kartografskog prikaza 19

3.3. Prikaz slijeda učitavanja mrežne stranice sa statičnim prikazom 19

3.4. Usporedba klasičnog sinkronog i AJAX asinkronog učitavanja stranice . . . 23

3.5. Shematski prikaz mrežnog servisa karte (WMS) 27

3.6. Shematski prikaz mrežnog servisa svojstva (WFS) 28

3.7. Shematski prikaz mrežnog servisa pokrivenosti (WCS) 29

3.8. Povezanost i korištenje standarada i servisa po OGC specifikacijama 30

3.9. Shematski prikaz rada mrežnog GIS poslužitelja 32

3.10. Primjer kreiranja parametriziranoga prostornog sloja iz relacijske baze podataka u Geoserveru 37

3.11. Tablični prikaz mjerenih podataka sa stranice meteo.hr 39

3.12. Grafički prikaz sa stranice meteo.hr 40

3.13. Prikaz dnevnih vremenskih prilika 40

3.14. Osnovni prikaz prognoze za pojedinu lokaciju na stranici yr.no 41

4.1. *Emodnet chemistry pretraga metapodataka* 47
4.2. *Prostorni prikaz temperature mora projekta Copernicus* 48
4.3. *Oracle forms aplikacija s C++ dodatcima za vizualizacije podataka* 49
4.4. *Mrežna aplikacija s Java Appletom za prikaz karte* 50
4.5. *Mrežna aplikacija s prostornim prikazom s pomoću Google maps API-a* . . 51
4.6. *Mrežna aplikacija s dinamičkim izbornicima* 52

5.1. *Tradicionalni tijek podataka pri kreiranju podatkovnog proizvoda* 55
5.2. *Izgled klasične ODV aplikacije* 56
5.3. *Primjer vizualizacije podataka s WISE Marine mrežne stranice* 58
5.4. *Unaprijeđen tijek podataka uz koritenje mrežnog preglednika* 59
5.5. *Tablice i njihove relacije* 62
5.6. *Shematski prikaz položaja elemenata sučelja* 63
5.7. *Izgled prve verzije korisničkog sučelja* 63
5.8. *Prikaz učitavanja mrežne aplikacije* 67
5.9. *Primjer dvosmjernog povezivanja* 70
5.10. *Od statusa do trenda u jednom kliku* 70
5.11. *Primjer korištenja funkcije "jedna dubina"* 71
5.12. *Primjer prikaza kategorija morskog otpada* 73

6.1. *Prikaz podataka na stranici pljusak.com* 78
6.2. *Dohvat i odrada dva seta podataka* 80
6.3. *Glavne tablice u bazi podataka* 81
6.4. *Prikaz rasporeda osnovnih elemenata na stranici* 82
6.5. *Ruža vjetrova za 24 sata sa 6 kategorija* 83
6.6. *Primjer prilagodljivog dizajna* 84
6.7. *Meni na aplikaciji za prikaz rezultata automatskih mjernih postaja* 85
6.8. *Meni za odabir prikaza za određeni dan* 85
6.9. *Odabir perioda prikaza na grafu* 86
6.10. *Jednostavna karta postaja* 86

6.11. Dva parametra na grafičkom prikazu 87

6.12. Tlak zraka s mreže mikrobarografskih postaja 88

6.13. Prikaz mjerenja VF radara kao prostorni sloj 89

6.14. Primjer prilagođene vremenske crte na prikazu automatski mjerenih podataka 90

6.15. Vremenska crta s prikazom detektiranih vrtloga unutar dnevnih srednjaka polja površinskih struja 90

6.16. Vremenska crta sa satnim vrijednostima 91

6.17. Dio prikaza "Lighthouse" alata za analizu performansa stranice preglednika Chrome 92

7.1. Operativna shema AdriSC prognoze meteoroloških cunamija 96

7.2. Prikaz rezultata modela sa stranice meteo.hr 98

7.3. Prikaz rezultata radarskih mjerenja uz meteorološke mjerne postaje na prikazu wundermap 99

7.4. Osnovni prikaz prognoze vremena sa stranice windy.com 100

7.5. Prikaz valova i podataka s mjernih postaja sa stranice windy.com 101

7.6. Tijek podataka 103

7.7. Osnovna grupa tablica 104

7.8. Prikaz temperature mora s vidljivom granicom polja 106

7.9. Prikaz temperature mora s pojedinačnim ćelijama 106

7.10. Analiza brzine učitavanja 108

7.11. Kontrole prikaza 109

7.12. Glavni elementi prikaza 110

7.13. Prikaz virtualnih i automatskih mjernih postaja 111

7.14. Usporedni prikaz rezultata mjerenja i modela 112

8.1. Međuodnosi u sustavu Pokretač, Pritisak, Stanje, Utjecaj, Mjera 116

AJAX	Metoda asinkronog dohvata podataka unutar mrežnih stranica (Asynchronous JavaScript And XML)
API	Aplikacijsko programsko sučelje (Application Programming Interface)
BSD	Berkeley Software Distribution
CGI	Sučelje za pokretanje programa na poslužitelju (Common Gateway Interface)
GIF	Grafički format namijenjen pohrani slika bez gubitaka (Graphic Interchange Format)
GIS	Geografski informacijski sustav
HTML	Prezentacijski jezik za izradu mrežnih stranica (HyperText Markup Language)
HTTP	Protokol za prijenos podataka na mreži (Hyper Text Transfer Protocol)
JavaScript	Skriptni programski jezik koji se izvršava u mrežnom pregledniku
JPEG	Komprimirani slikovni format s gubitcima (Joint Photographic Experts Group)
JSON	Zapisivanje objekata u JavaScriptu (JavaScript Object Notation)
KML	XML notacija za prostorne podatke (Keyhole Markup Language)
NetCDF	Binarni samodefinirajući format za pohranu višedimenzionalnih nizova podataka
NoSQL	Dinamičke nerelacijske baze podataka (Not only SQL)
OGC	Međunarodno udruženje za razvoj otvorenih geoprostornih standarada (Open Geospatial Consortium)
OSGeo	Neprofitna organizacija za suradnju u razvoju geoprostornog slobodnog softvera otvorenog koda (Open Source Geospatial Foundation)
PDF	Format zapisa dokumenata (Portable Document Format)
PNG	Otvoreni grafički format namijenjen pohrani slika bez gubitaka (Portable Network Graphics)
SDK	Skup programskih alata za kreiranje aplikacija (Software Development Kit)
SLD	Opis stilova za prikaz prostornog sloja (Styled Layer Descriptor)
SQL	Računalni jezik za rad s relacijskim bazama podataka (Structured Query Language)
TIFF	Grafički format namijenjen pohrani slika (Tagged Image File Format)
URL	Mrežna adresa - usklađeni ili jedinstveni lokator sadržaja (Uniform Resource Locator)
WCS	Mrežni servis pokrivenosti (Web Coverage Service)
WFS	Mrežni servis svojstava (Web Feature Service)
WMS	Mrežni servis karte (Web Map Service)
XML	Jezik za označavanje podataka (EXtensible Markup Language)

1. UVOD

Napretkom informacijskih i komunikacijskih tehnologija i razvojem svijesti o potrebi očuvanja okoliša, količina podataka o okolišu ubrzano se i neprekidno povećava. Ulažu se veći napori u klasično prikupljanje podataka uz brz razvoj automatskih mjernih sustava korištenjem Interneta stvari (IoT). Svim podatcima je zajedničko da su prikupljeni na određenom mjestu i u određeno vrijeme, odnosno imaju i vremensku i prostornu opisnu komponentu. Sredstva i napori uloženi u prikupljanje tih podataka znatni su. Nažalost, korištenje podataka o okolišu često je ograničeno samo jednim primarnim ciljem, te se istovremeno rijetko koriste u više različitih svrha ili u kombinaciji s drugim podatcima i podatcima iz dužih razdoblja. Kako smo svjedoci klimatskih promjena, tako je važnost uočavanja trendova u podatcima postala veća, za što je nužno podatke prikazati i analizirati na odgovarajući način. Internet kao globalna računalna mreža omogućio je brz i jednostavan pristup informacijama iz raznih izvora. Način prikaza i vizualizacija podataka olakšavaju korisniku razumijevanje i izvlačenje informacije iz cijelog skupa podataka. Dobro organizirano upravljanje koje uzima u obzir i kontekst podataka povećava njihovu dostupnost, odnosno korisniku omogućuje lakše "kretanje" kroz velike količine podataka. Dvije stvari su posebno bitne u kontekstu promatranja određenih okolišnih parametara na nekom području u neko (duže) vrijeme: stanje i trend. Stanje se odnosi na određeno razdoblje (godina, sezona, mjesec) i to za čitavo promatrano područje. Trend je promjenjivost određenog parametra tijekom nekog razdoblja u istom geografskom području. Ako pogledamo način i dostupnost prikaza okolišnih podataka na Internetu, uočiti ćemo da prevladavaju meteorološki podatci. Osim meteoroloških podataka dostupni su i oceanografski podatci, kao i različiti podatci ili vrijednosti različitih ekoloških pokazatelja. Iako se u posljednjih nekoliko godina mogu naći napredniji prikazi, ponajprije rezultata meteoroloških modela i satelitskih mjerenja, prikazi takvih podataka često su "jednodimenzionalni", odnosno prikazani su na jedan način i sa samo jednom svrhom. Na primjer, ako se prikazuju temperature zraka u određeno vrijeme, iz takvog prikaza nije jednostavno dobiti kretanja temperature zraka za određenu mjernu postaju tijekom dužeg vremena. Isto tako, ako se prikazuju analize i trendovi kroz vrijeme, iz takvog prikaza nije jednostavno doći do prikaza cijele "scene", odnosno svih prostornih podataka mjerenih u prošlosti u određeno vrijeme. Osim nemogućnosti korisnika da se jednostavno "kreće" kroz prostor i vrijeme, prikazi okolišnih podataka su često i statični. To znači da su podatci prikazani na isti način kako su se prikazivali prije razvoja informacijskih tehnologija

to jest na način kao mape na papiru. Takvi prikazi mogu biti dobri i informativni, ali dinamičnim i interaktivnim prikazom korisnik može "izvući" znatno više informacija iz istog seta podataka.

Tijekom više od 20 godina razvoja programske podrške svjedočili smo napretku računalnih znanosti i velikim promjenama koje je omogućila umreženost računala i Internet. Sustavnim uvođenjem standarda i standardnih protokola fokus razvoja aplikacija se s lokalnih desktop aplikacija preselio na mrežne aplikacije. Nadalje, količina mjerenih podataka se znatno povećala i zajednički rad više ljudi i institucija na istom setu podataka postao je standard.

Vizualizacija podataka može se promatrati i kao posebno istraživanja područje istraživanja i ima bitnu ulogu u upravljanju i korištenju podataka općenito. U poglavlju 2 dat je pregled osnovnih principa u vizualizaciji podataka i relevantnih znanstvenih radova tog područja.

U poglavlju 3 dat je općeniti prikaz i teorijska podloga tehnologija i načina vizualizacija podataka, uz relevantne znanstvene radove na tom području, koji su doveli do pretpostavki rješenja specifičnih problema i zadataka predloženih u ovome radu.

U poglavlju 4 dat je kratak povijesni pregled razvoja programske podrške za upravljanje oceanografskim podatcima sa specifičnim izazovima i konkretnim primjerima implementacije. Razvojem programske podrške stekli su se uvjeti za korištenje naprednijih sustava i rješenja za rukovanje raznim vrstama oceanografskih podataka.

Slijedeća tri poglavlja opisuju izvorne doprinose ovog rada. Svako od ta tri poglavlja bavi se jednom specifičnom vrstom problema i predlaže nova rješenja. Svako od rješenja opisano je u radu objavljenom u znanstvenom časopisu ili prezentiranom na međunarodnoj znanstvenoj konferenciji. Nadalje, svaki od ova tri dijela sadrži opis postojećih rješenja, motivaciju za istraživanje, novo rješenje i zaključak.

U poglavju 5 opisan je izvorni sustav za prikaz i provjeru podataka s obostrano povezanom vremenskom i prostornom komponentom u mrežnom sučelju. Obostrana povezanost vremenske i prostorne komponente omogućava prikaz pojedinačnih mjerenja, identificiranje i označavanje potencijalno neispravnih vrijednosti i spremanje te oznake zajedno sa samim vrijednostima, a također i povezivanje stanja i trendova kod pokazatelja stanja okoliša (agregirani podatci). Obostrano povezivanje znači mogućnost istovremenog isticanja lokacije na karti i grafičkog prikaza, bez obzira na to bira li korisnik lokaciju ili vrijednost s grafičkog prikaza. Grafičke prikaze moguće je povezati i uz postojeća rješenja mrežnih geografskih informacijskih sustava namijenjen prikazima prostornih slojeva.

U poglavlju 6 objašnjena su izvorna rješenja upravljanja podatcima s automatskih mjernih sustava. Podatci se prikupljaju pomoću automatskih mjernih sustava i mogu biti prostorno smješteni na jednoj lokaciji (mjernoj postaji), ili na mreži lokacija s određenog prostora (npr. visokofrekventni radari). Mrežna sučelja uključuju obrasce za odabir prostora i vremena za kojeg se podatci prikazuju, uz mogućnost prikaza standardnih statičnih prostornih slojeva putem mrežnog GIS-a.. Vremensko upravljanje uključuje jednostavan pronalazak ekstremnih situacija u posebno prikazanim vremenskim osima podataka. Osim uobičajenog upravljanja podatcima prema određenom danu i vremenu, na vremenskim osima su označeni pojedini "događaji" unutar izmjerenih podataka.

Poglavlje 7 opisuje novo izvorno rješenje prikaza podataka kreiranih pomoću numeričkih modela uz korištenje relacijske baze podataka i vizualizacije s klijentske strane. Rezultati numeričkih modela su vrijednosti s mreže lokacija za više parametara i predstavljaju niz scena jednako razmaknutih u vremenu. Prikaz uključuje mogućnost vremenske animacije, kao i grafički prikaz vremenskog niza za pojedinu lokaciju uz usporedbu sa stvarnim mjerenjima. Za razliku od uobičajene prakse gdje se prikazuju unaprijed pripravljene slike i slojevi, klijent server arhitektura predloženog rješenja provodi iscrtavanje slojeva na strani klijenta, što omogućuje prijenos manje količine podataka i ne zahtijeva posebno angažiranje poslužitelja i pohranu slika čime znatno ubrzava dobivanje izlaznih rezultata u odnosu na postojeća rješenja. Korištenjem baze podataka omogućuje se prikaz bilo koje scene iz raspoloživog seta podataka i njezine usporedbe s rezultatima mjerenja i drugih numeričkih modela. Rasponi boja kod prikaza manjih područja dinamički se prilagođavaju, što omogućuje bolji uvid u prostornu promjenjivost parametra.

U Poglavlju 8 dat je skupni zaključak za sva tri polja istraživanja, naglašeni znanstveni doprinosi disertacije i izneseni planovi za daljnji rad na ovom području.

2. VIZUALIZACIJA PODATAKA

Veće količine podataka ljudima je teško razumjeti ako su oni navedeni u tablicama, ili kao niz brojeva. Vizualizacijom podataka doprinosi se lakšem razumijevanju i pamćenju podataka. Kod vizualizacije podataka važno je odabrati pravi način vizualizacije, ovisno o strukturi podataka i o onome što se iz istih pokušava prikazati, odnosno izvući kao zaključak. Vizualiziraju se kvantitativni kategorizirani podatci s različitim ciljevima prikaza.

Generalno vizualizacija podataka može se podijeliti na dva glavna područja: statistička grafika i tematska kartografija [1]. Oba se odnose na vizualni prikaz kvantitativnih i kategorijskih podataka, ali su im ciljevi prezentacije različiti. Kartografska vizualizacija ponajprije se bavi prikazom ograničenim na prostornu domenu; statistička grafika primjenjuje se na bilo koju domenu u kojoj se nalaze grafičke metode u službi statističke analize. Postoji mnogo preklapanja, ali što je još važnije, dijele ih zajedničke povijesne teme intelektualnog, znanstvenog i tehnološkog razvoja. Osim toga, kartografija i statistička grafika dijele zajedničke ciljeve vizualnog prikaza u cilju istraživanja i otkrivanja. Oni se kreću od jednostavnog mapiranja lokacija (kopnena masa, rijeke, teren), preko prostorne raspodjele geografskih obilježja (vrsta, bolest, ekosustavi), do široke raznolikosti grafičkih metoda za prikaz uzoraka, trendova i pokazatelja [2]. U svom radu [2] G. L. A. Babu i suradnici općenito razmatraju potrebu i metode za vizualizaciju velike količine podataka (engl. *Big Data*). Prije vizualizacije podatci se moraju obraditi primjerenom metodom i tek nakon toga slijedi vizualizacija. Prednosti upotrebe vizualizacijskih tehnika su: bolje donošenje odluka, bolja *ad hoc* analiza, bolja suradnja i dijeljene informacija, bolji povrat investicija, ušteda na vremenu i omogućavanje korisnicima samodostatnosti (vezano uz interpretaciju podataka). Bitno je da korištene tehnike vizualizacije budu u skladu s mogućnostima ljudske percepcije i shvaćanja.

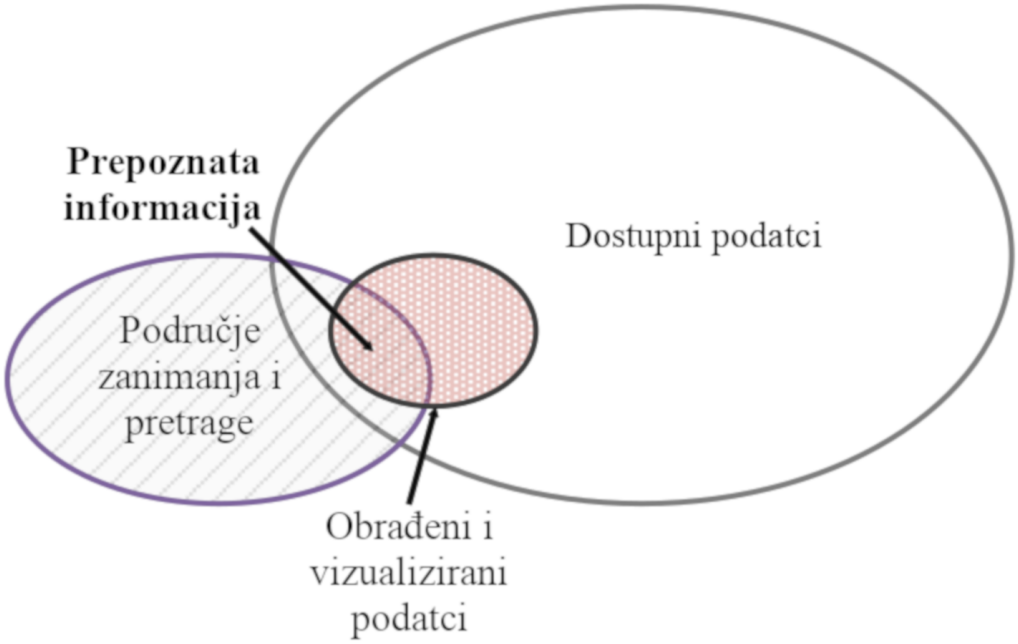

Slika 2.1: Problem kapaciteta ljudske percepcije [3]

Očito, broj vizualnih oblika koji se mogu pojaviti vizualizacijom ograničena je samo ljudskom maštom. Glavni zahtjev je jasnoća i jednostavnost analize prikazanih podataka. Tehnike vizualizacije mogu biti i elementarne (linijski grafikoni, stupčasti grafikoni itd.) i složene (na temelju matematičkih funkcija). Nadalje, za vizualizaciju se može koristiti kombinacija različitih metoda. Međutim, takav prikaz podataka je apstraktan i izrazito ograničen kapacitetom ljudske percepcije (slika 2.1). U radu [3] E. Olshannikova i sur. razmatraju mogući slijedeći korak na polju vizualizacije podataka, a to je korištenje proširene stvarnosti. Tako bi se mogućnosti ljudske percepcije, koje već jesu na neki način evoluirale korištenjem računala općenito, mogle još više unaprijediti. Daljnjim poboljšanjima postojećih tehnika vizualizacije podataka i njihovim smještanjem u vidno polje korisnika, uz interdisciplinarnu suradnju više polja znanosti, postigao bi se napredak u mogućnostima prihvaćanja informacija, pogotovo za ljude s poteškoćama u vidu i kod percipiranja vizualnih informacija.

2.1. Grafička vizualizacija podataka – vrste grafova

Iako se teoretski možemo za vizualizaciju koristiti različitim i mnogobrojnim metodama, u praksi se pokazalo da se podatci za prikaz mogu podijeliti u sedam glavnih kvantitativnih vrsta poruka. Jednostavnim prepoznavanjem vrste poruke i znajući odgovarajuća dizajnerska rješenja koja odgovaraju tom tipu, moguće je odrediti većinu dizajnerskih izbora. Drugim riječima, moguće je primijeniti nekoliko općih načela na bezbroj specifičnih izazova prezentacije podataka kao što navodi S. Few u svojem općenitom radu vezanom uz izbor

odgovarajućeg tipa grafa, ovisno o vrsi poruke koju želimo prenijeti [4].

Nabrojimo tih sedam vrsta podataka s pripadajućim načinima vizualizacije.

1. Nominalne usporedbe (uporedba kategorija bez posebnog redoslijeda)

   Stupci vertikalni ili horizontalni.

2. Vremenski nizovi (više istih mjerenja u različitim vremenskim intervalima)

   Linije za naglašavanje trenda, ili stupci za naglašavanje pojedinih vrijednosti ili točke povezane linijom za manje isticanje pojedinih vrijednosti uz istodobno pokazivanje trenda. Na osi x uvijek se nalazi vrijeme - vremenska os.

3. Rankiranje (potpodjele po kategorijama poredane po veličini)

   Stupci horizontalni ili vertikalni. Za naglašavanje većih vrijednosti poredak je padajući ili rastući za naglašavanje manjih vrijednosti.

4. Dio cjeline (ukupna količina nečega razdijeljena po kategorijama)

   Stupci vertikalni ili horizontalni. Korištenje kumulativnih stupaca za istodobni prikaz podjele i ukupne vrijednosti.

5. Devijacije (razlika od neke referentne vrijednosti, na primjer planirano/ostvareno)

   Linije kada se prikazuju devijacije kroz vrijeme, kao vremenska serija. Stupci za naglašavanje pojedinih vrijednosti ili točke povezane linijom za manje isticanje pojedinih vrijednosti uz istodobno pokazivanje trenda. Uvijek je nužno prikazati referentnu vrijednost (ako referenca nije sama os x - nulte vrijednosti).

6. Frekfentna distribucija (broj nečega po kategorijama ili intervalima)

   Vertikalni stupci za naglašavanje individualnih vrijednosti (histogrami). Linije za naglašavanje uzorka (poligon frekfencija).

7. Korelacije (usporedba dviju veličina radi detekcije njihove korelacije)

   Točkasti raspršeni prikaz (engl. *scatter plot*). Može se dodati linija trenda za bolje uočavanje korelacije. Mogu se koristiti i upareni stupci za prikaz (korelacijski stupci) - po dva susjedna stupca za svaku od veličina.

2.2. Vizualizacija vremenskih podaka – vremenski grafovi

Jedan od najčešće korištenih grafičkih prikaza je prikaz promjene neke vrijednosti kroz vrijeme što još nazivamo i vremenski niz podataka (engl. *Time series*). Vremenski niz podataka je grupa mjerenja ili observacija gdje je svaki podatak zabilježen u točno određeno vrijeme.

Prema općenitom preglednom radu S. Das [5], gdje se analiziraju isključivo aspekti vremenskih nizova podataka, ovakav niz podataka može se podijeliti na diskretan vremenski niz gdje su podatci dobiveni u određenim diskretnim intervalima (minutni, satni, dnevni). Ovdje spadaju i setovi s diskretnim i nepravilnim intervalima. Druga vrsta niza je kontinuirani niz. U praksi je to na primjer analogni EKG prikaz rada srca tijekom nekog vremena, ili analogni mareograf za bilježenje razine mora. Digitalizacijom ovakav niz postaje diskretan. Na kraju imamo i vremenske nizove diskretnih vrijednosti (broj oboljelih tijekom nekog vremena, broj sunčanih dana itd.).

Na vremenskom grafu možemo uočiti nekoliko elemenata vezanih uz pojavu koju promatramo, a to su ponajprije trend promjene vrijednosti kroz vrijeme, zatim sezonske ili periodične promjene i na kraju određeni šum (engl. *Noise*). Ovi elementi su vidljivi na slici 2.2.

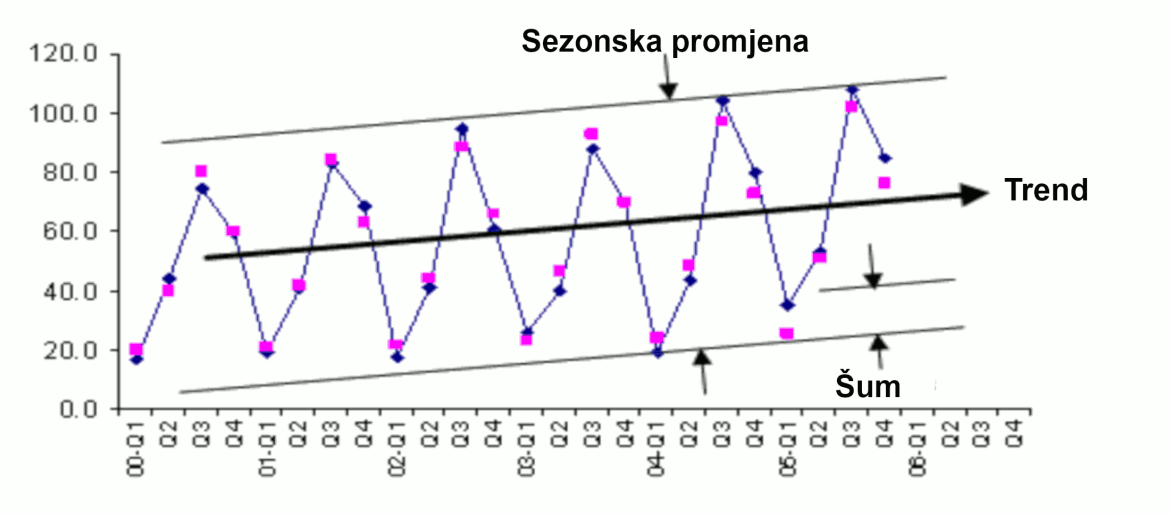

Slika 2.2: Prikaz količine prodanog sladoleda po kvartalima [5]

Glavni motivi za izradu vremenskih grafova za određeni set podataka koji opisuje neku pojavu su [6]:

- prognoza ponašanja u budućnosti
- kontrola procesa (kako bi prepoznali neku opasnu intenciju)
- razumijevanje same pojave i njezinih mehanizama.

2.3. Vizualizacija prostornih podataka

Vizualizacija prostornih podataka još se naziva i kartografija. Sam prikaz prostornih podataka naziva se karta ili zemljovid.

Definiciju karte i kartografije možemo pronaći u mnoštvu izvora u literaturi. Jedan od njih je i u radu M. Miletić Drder [7] u kojem se razmatra uloga kartografske građe u kontekstu kulturne baštine. Riječ karta je izvedena iz latinske riječi *charta* (list, papir), a koja dolazi od starogrčke riječi χαφτηζ (papir iz papirusa). U Hrvatskoj se uz riječ karta, u najnovije vrijeme, kao i u prošlosti, ponovo sve češće upotrebljava izraz zemljovid. Autori Lapaine i Kljajić smatraju da izraz zemljovid nije sasvim odgovarajući iz stručnoga geografskog i kartografskoga gledišta. Navode i zašto: "Naziv zemljovid može se upotrebljavati za opću geografsku kartu. Međutim, on ne može zamijeniti naziv karta zbog nekoliko razloga. Prvo, osim geografskih ili topografskih karata koje prikazuju Zemlju i zemljište, postoji velik broj tematskih karata na kojima je prikaz Zemlje, odnosno zemljišta u drugome planu. Nadalje, kartografija se bavi i drugim planetima. Sigurno ne bi bilo dobro reći zemljovid zvjezdanog neba, zemljovid Mjeseca ili zemljovid Marsa... Prema tome, na pitanje čemu dati prednost zemljovidu ili karti, možemo odgovoriti da je karta naziv bez kojeg ne možemo. Zemljovid je pojmovno uži i stoga ne može zamijeniti staru riječ karta". J. Roglić, međutim definira kartu ovako: "Karta (lat. charta = papir) ili zemljovid je smanjeni prikaz na plohi zemljine površine ili njezinih dijelova. To je najvažniji način predočivanja prostora i najpogodnije sredstvo geografskog izražavanja i sporazumijevanja. Karte imaju prvorazredno značenje u informiranju i sporazumijevanju, otuda opća potreba poznavanja njihove biti i pravilne upotrebe" .

Prostorni podatci se uobičajeno prikazuju kao jedan od slojeva preko neke osnovne topografske karte. Korisniku je tako intuitivno jasan prostoran položaj samih podataka.

2.3.1. Geoinformacijski sustav (GIS)

Po definiciji Geografski informacijski sustav (GIS) je skup metoda i sredstava za prikupljanje podataka o smještaju i opisu objekata u prostoru, njihovo pohranjivanje, obrada te u prvom redu dobivanje grafičkih informacija u obliku karata. Na neki način je ideja, ali i praktična upotreba, principa Geografskog informacijskog sustava bila tijekom povijesti čovječanstva uvijek prisutna. U svom stručnom radu V. Maček i B. Lipovšćak vezanom uz primjenu geografskoga informacijskog sustava na informacijske sustave opisuju potrebu zapisa i obrade prostornih podataka općenito i korištenjem računala, odnosno samih informacijskih sustava [8]. Tijekom povijesti je postojala potreba za prostorno definiranje raznih objekata i njihovih opisa, posebno i u odnosu na njihovo okruženje. Spomenimo na primjer da su Vikinzi prije tisuću godina, viking Eirik, otkrivši Ameriku, atribuirali taj geolocirani komad Amerike kao zemlju gdje raste vinova loza, Vinland. I tako je bilo kroz povijest, i prije i poslije toga. Kako su potrebe za lociranjem i opisivanjem objekata u prostoru rasle, tako su se usavršavale i metode te sredstva. Danas smo stigli do satelitskog snimanja, digitalne konverzije u baze podataka geolociranih objekata, relacijskih baza njihove atribucije te tiskanja tematskih karata prema željenom sadržaju, u prozvoljnom mjerilu uz promjenu atribucije boja.

GIS alati po stvarnoj funkciji odlikuju se sposobnostima da korisniku prikažu stvaran svijet i topološke odnose. Moguće je selektiranje mjerila, kombinacije tematskih slojeva, preklapanja i povezivanja segmenata karata te stavljanje na raspolaganje vlastitih podataka drugim sudionicima u mreži GIS-a.

Prema namjeni i složenosti GIS alati veoma su heterogeni te je važno dobro odmjeriti ciljeve pri izboru operativnog sustava, GIS alata, relacijske baze te komunikacija [8].

2.4. Vizualizacija prostorno-vremenskih podataka

Prostorno-vremenske podatke je općenito dosta složeno vizualizirati, a da sam prikaz bude jasan, razumljiv i kognitivno nezahtjevan. Prostorne podatke je najbolje prikazati na kartografskom prikazu. Kartografski prikazi su već dugo u upotrebi i intuitivno su razumljivi. Za prikaz vremenske komponente podatka dodatno nam nedostaje jedna "dimenzija" povrh standardnih dviju dimenzija (x i y koordinata) na kartografskom prikazu.

Osim same metode vizualizacije, da bismo dobili izlazni rezultat, treba paziti na samu implementaciju, odnosno na ograničenja raspoložive tehnologije i programskih rješenja.

Da bi rezultat vizualizacije bio primjenjiv i uspješan, potrebno je riješiti niz problema i zahtjeva. U svome polemičkom radu o problemima pri vizualizaciji podataka B. Hibbard [9] kao prioritetne i motivirajuće navodi najvažnije probleme koje je potrebno zadovoljavajuće riješiti pri vizualizaciji podataka. To su redom:

- velika količina podataka koju treba obraditi,
- prihvatljivo vrijeme obrade, odnosno vrijeme odziva za korisnika,
- lijepi, vizualno atraktivni izlazni rezultati,
- abstrakcija, odnosno primjerena metoda vizualizacije,
- pronaći korisnike, odnosno financiranje projekta vizualizacije.

2.5. Vremenska geografija (engl. *Time geography*)

Geografija vremena snažan je konceptualni okvir za razumijevanje ljudskog prostornog ponašanja, osobito ograničenja i kompromisa u dodjeli ograničenog vremena među aktivnostima u prostoru. Posljednja dva desetljeća svjedočimo oživljavanju vremenske geografije jer su istraživači poboljšali računske prikaze osnovnih vremenskih geografskih entiteta kao što su prostor-vrijeme i prizma. Najnoviji razvoj tehnologija za prepoznavanje lokacije (engl. *Location Acquire Technology*) i usluga utemeljenih na lokaciji (engl. *Location Based Services*) ima potencijal bržeg razvoja i primjene vremenske geografije u društvenim istraživanjima i geografskim informacijskim uslugama. U svom radu H. J. Miller se bavi teorijom

mjerenja u vremenskoj geografiji, gdje bi bilježenje lokacija u kontrolnim točkama poslužilo za pronalaženje funkcija koje opisuju kretanje objekta kroz vrijeme i prostor, te mogu poslužiti za predviđanje daljnjeg kretanja [10]. Mogućnost predviđanja kretanja je također u direktnoj korelaciji s točnošću mjerenja vremena i pozicije u prostoru. Zahtjeva i korištenje naprednih tehnologija pozicioniranja i analize vremensko-prostornih podataka.

Razvojem tehnologije, posebno pametnih telefona opremljenih uređajima za precizno pozicioniranje, danas je moguće prikupiti puno više podataka o kretanjima i aktivnostima pojedine osobe. Ovo daje dodatne dimenzije vremenskoj kartografiji, jer sada osim same prisutnosti pojedine osobe na određenom mjestu u određeno vrijeme, omogućava praćenje različite aktivnosti i interakcije te osobe. Isto tako prisutnost osobe nije više isključivo vezana za stvaran prostor, nego se može proširiti i na virtualan prostor. Ovo širenje na dodatne dimenzije i dodatni prostor predstavlja još veće izazove pred ionako složenu problematiku prikaza prostorno-vremenskih procesa. Ovakav novi pogled na vremensku geografiju dala je H. Couclelis u radu, u kojem navodi teoretske osnove za danas sve više prisutne servise koji su bazirani na podatcima o kretanju određene osobe u prostoru [11].

2.6. Prostorno-vremenska kocka

N. Andrienko i sur. su dali prijedlog novog načina prikaza prostorno-vremenskih podataka na osnovi dostupnih postojećih rješenja [12]. Jedno od predloženih novih načina prikaza je i prostorno-vremenska kocka. Prostorno-vremenska kocka je način vizualizacije prostorno-vremenskih podataka tako da se iznad kartografskog prikaza doda treća vremenska dimenzija unutar koje su prikazani prostorno-vremenski podatci. Na primjeru sa slike 2.3. veličina i oblik točaka iznad karte pokazuju vrijednosti parametra, dok položaj određuje prostorno-vremensku komponentu (objekti bliže karti prikazuju ranije događaje). Ovakav prikaz je intuitivno jasan korisniku. Za vrijednosti koje su vremenski i vizualno više odmaknute od kartografskog prikaza teže je utvrditi na koju prostornu poziciju se odnose. Ovisno o samim podatcima prikaz može biti više ili manje pregledan.

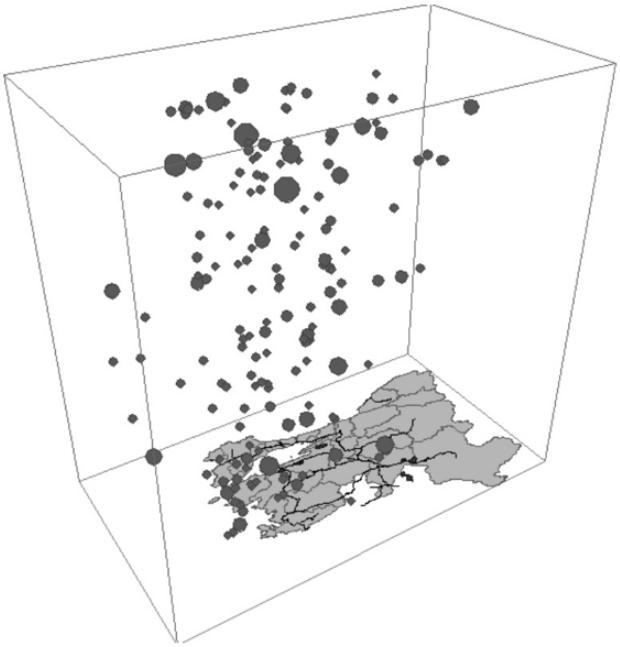

Slika 2.3: Primjer prostorno-vremenske kocke korištenjem točaka za prikaz [12]

P. Gatalsky i sur. u radu o interaktivnoj analizi podataka o događajima primjenom prostorno-vremenske kocke daju daljnje načine njezine primjene [13]. Prikaz se može realizirati i tako da se iznad dvodimenzionalne karte prikaže vremenska linija na kojoj su dodatnim svojstvima prikaza (na primjer bojom) prikazane vrijednosti i njihova promjena kroz vrijeme, slika 2.4. Kod ovakvih prikaza bitno je da se vremenske osi vizualno ne preklapaju, što donekle ograničava mogućnosti upotrebe ovakvog prikaza. Primjeri iz rada su realizirani korištenjem specijaliziranih programa za vizualizacije podataka. Nije naveden niti poznat primjer korištenja prostorno-vremenske kocke u mrežnom okolišu.

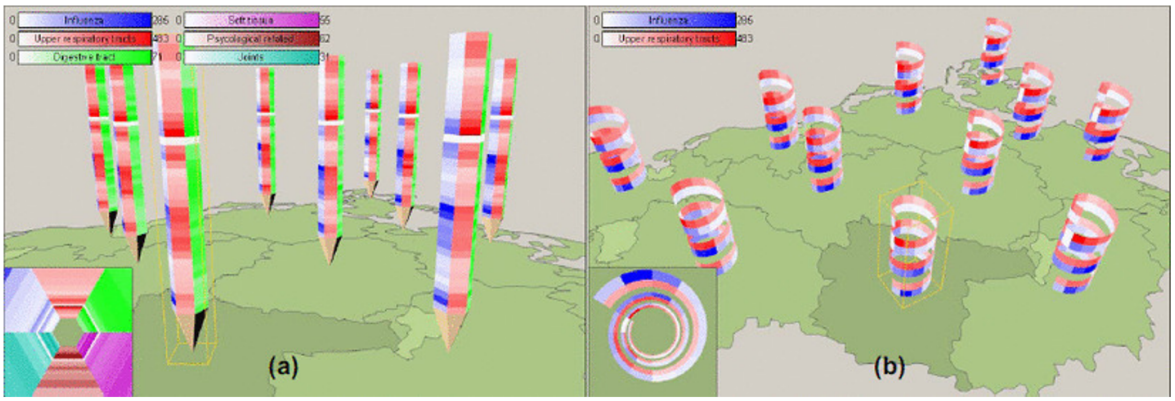

Slika 2.4: Primjer prostorno-vremenske kocke s vremenskim osima [13]

2.7. Hibridni prostorno-vremenski prikazi

Hibridni prikazi uključuju dodavanje vremenskih grafičkih prikaza preko kartografskog prikaza kako bi se pokazala vremenska promijenjivost određene vrijednosti. Prostorno pozicioniranje je intuitivno jasno, dok se za vremenske prikaze koristi nešto grublja vremenska skala (kraće razdoblje). Potrebno je osigurati dovoljan "razmak" prostornih podataka kako se vremenski prikazi ne bi preklapali. Dodatno se korištenjem boje može pokazati još jedan parametar/svojstvo podatka. G. Andrienko i sur. u radu, koji je svojevrsni nastavak radova [12] i [13], dalje razrađuju načine prikaza prostorno-vremenskih podataka [14]. Analiziraju se serije podataka kao što su pozivi mobilnih telefona u Milanu i objave slika na servisu Flicr. U ovom radu spominje se i interaktivnost prikaza, kao i to da se razvijaju mrežni servisi u svrhe vizualizacije. Identificirani su problemi u prikazu i navedeni daljni smjerovi istraživanja. Na primjeru sa slike 2.5 prikazana je dinamika poziva mobilnim telefonima u vremenu i prostoru.

Slika 2.5: Primjer hibridnog prikaza [14]

2.8. Prikazi bez klasičnih karata

Nedostatak dodatne dimenzije za prikaz vremenske promjenjivosti nekog parametra može se pokušati riješiti tako da se klasičan prostoran prikaz "reorganizira" kako bi se dobio prostor za prikaz vremenske promjenjivosti. Jedan takav način prikaza podataka je "Pričajući graf" (engl. *Storygraph*). U svojoj disertaciji o vizualizacijama prostorno-vremenskih podataka A. Shrestha uvodi takav način prikaza i daje njegove teoretske osnove uz nekoliko primjera na stvarnim podatcima [15]. Razmatra se i prikaz manje određenih podataka u vremenu

i prostoru (reprezentacija vremenskih i prostornih raspona). Isto tako se daje poveznica prema ostalim hibridnim spomenutim prikazima prostorno-vremenskih podataka. U ovom načinu prikaza klasičan kartezijski prostor se transformira tako da se os x dodaje kao druga os y, dok se os x koristi za prikaz vremenske promjenjivosti. Na slici 2.6 prikazan je način transformacije.

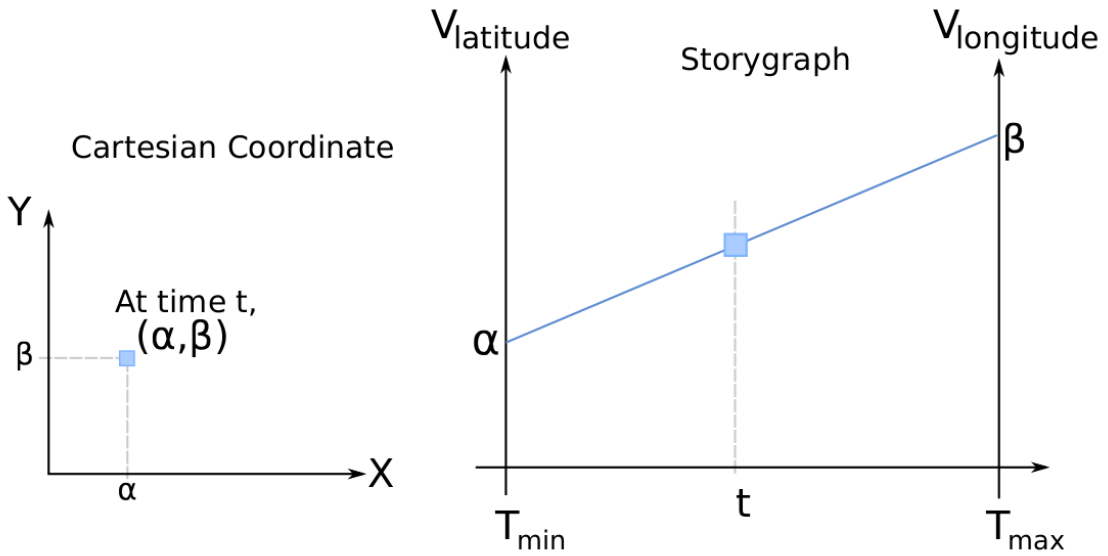

Slika 2.6: Princip prikaza za "Pričajući graf" (Storygraph) [15]

Iako se ovakvim načinom prikaza mogu uredno i pregledno prikazati prostorno-vremenski podatci, sam prikaz nije intuitivno jasan i zahtijeva navikavanje radi činjenice da je dvodimenzionalan prostor prikazan s pomoću dviju paralelnih, a ne okomitih osi. Već i prikazi jednostavnijih događaja kao što su kretanje dviju osoba kroz prostor sa slike 2.7, zahtijeva značajan napor za razumijevanje. Zbog te činjenice ovakvi prikazi nisu ušli u širu upotrebu.

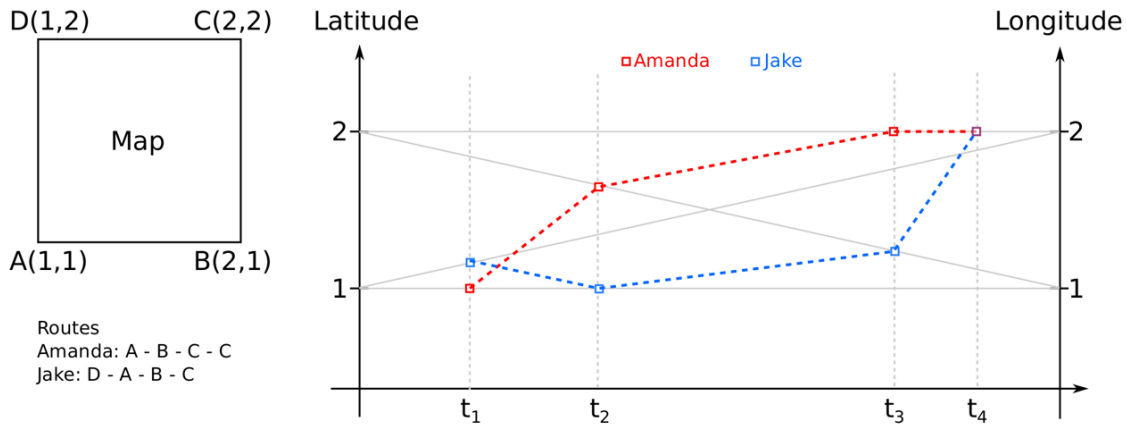

Slika 2.7: Primjer prikaza kretanja dviju osoba pomoću "Pričajućeg grafa" [15]

Konkretna implementacija opisana u disertaciji realizirana je uz korištenje Microsoft .NET i WPF razvojnog okruženja (Windows Presentation Foundation). Za pohranu podataka korištena je MySQL relacijska baza. Implementacija je napravljena kao desktop aplikacija, a kao podatci za prikaz su korišteni podatci o lokacijama i vremenu kod razvoja pojedinih projekata otvorenog koda na platformi GitHub (slika 2.8).

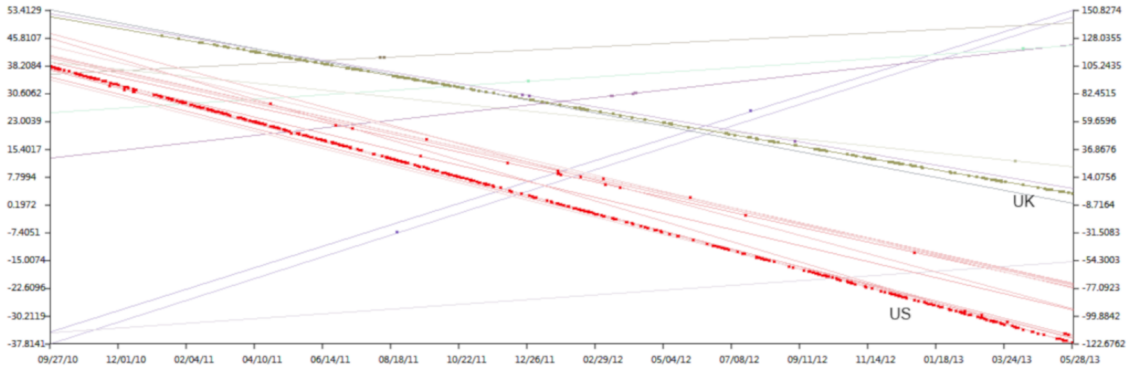

Slika 2.8: Prikaz razvoja D3.js projekta. Označene su linije lokacija s najviše doprinosa (UK i US) kao i lokacije s manje doprinosa (linije) [15]

3. PRIKAZI PODATAKA NA MREŽI

Defense Advanced Research Projects (DARPA) inicirala je 1973. godine istraživački program s osnovnim ciljem povezivanja računala u mrežu. Tako nastaje TCP/IP skup protokola. Internet prvo koriste vojne, znanstvene, obrazovne i državne ustanove, a kasnije se uključuju komercijalni korisnici i industrija. Tijekom 80-ih TCP/IP postaje dostupan za široku uporabu. Britanskom fizičaru Timothyju Berners-Leeu, (CERN), palo je na pamet da na internetu koristi hipertekst, odnosno da hipertekst poveže s već postojećim, raširenim i prihvaćenim TCP/IP protokolima i razvijenim DNS-om. Bila je to ideja iza koje se skrivao World Wide Web. 25. prosinca 1990., on i Robert Cailliau prvi put uspješno uspostavljaju komunikaciju između HTTP klijenta i poslužitelja i to Internetom [16]. Dana 6. kolovoza 1991. pokrenuta je prva mrežna stranica. Nakon toga broj računala uključenih na globalnu mrežu strelovito raste. Osim količine dostupnog sadržaja unapređuju se načini i formati prikaza podataka na mreži [17].

3.1. Statični unaprijed generirani prikazi

Kako bi se vizualizacija podataka mogla objaviti na mreži (i Internetu općenito) mogu se u tu svrhu koristiti statični unaprijed generirani prikazi (primjer je na slici 3.1). Statični prikazi su prikazi u formi nekog od formata za prikaz slika. Kako je riječ o unaprijed generiranoj slici, naknadne promjene prikaza, kao i interakcija s korisnikom nisu moguće. Uglavnom se sastoje od relativno malo boja i velikih površina iste boje. Za takve prikaze se uobičajeno koriste formati s indeksiranim sustavom boja i bez gubitaka u kompresiji kao što su PNG ili GIF format. Nerijetko se mogu naći i prikazi u neodgovarajućem JPEG formatu koji je namijenjen za fotografije.

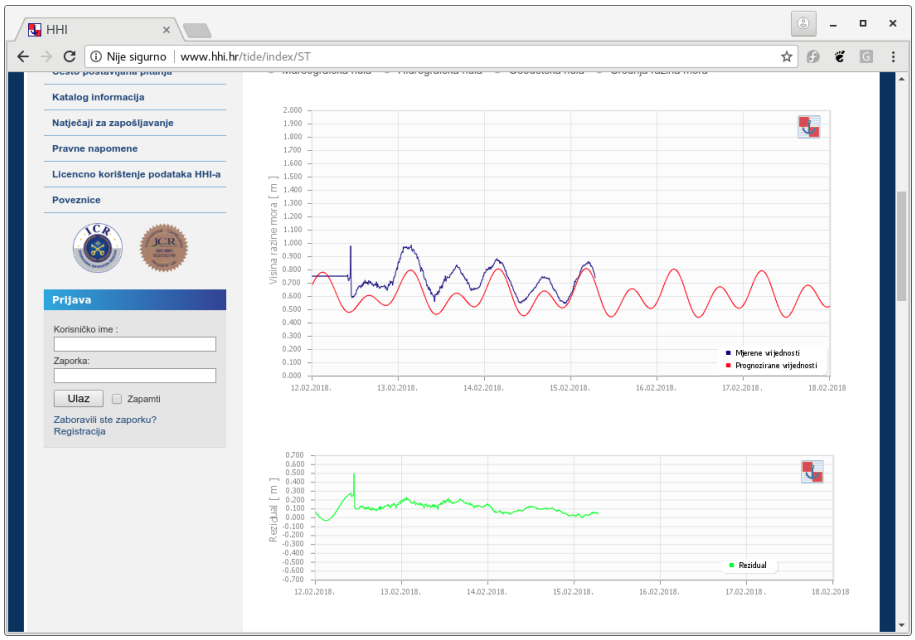

Slika 3.1: Primjer statično generiranog prikaza podataka [18]

Grupa podataka prikaže se korištenjem nekog računalnog programa, i takva se slika objavi na mrežnoj stranici. Samu izradu i objavu slike moguće je organizirati na dva načina: ručna (pojedinačna) i automatizirana izrada i objava slike. U slučaju objave jednokratnih podataka i prikaza gdje nema ponavljanja tijekom nekog razdoblja koristi se ručna objava. U slučaju da se podatci i objava ponavljaju u vremenu, koristi se automatizirani proces gdje se na poslužitelju pokreću skripte koje generiraju slike i objavljuju ih (ažuriranjem postojećih ili izradom novih mrežnih stranica).

Ako postoji više podataka s istom vremenskom komponentom, a drukčijom prostornom komponentom, oni se mogu prikazati na kartografskom prikazu. To znači da se u nekom od specijaliziranih računalnih programa kao podloga uzme neko osnovno prostorno svojstvo (obalna linija, državne granice) i preko toga se prikažu prostorni podatci. Često se kao pokazatelj vrijednosti koristi boja prikaza, a u slučaju vektorskih vrijednosti na prikazu crtaju se strelice. Primjer ovakvog prikaza se vidi na slici 3.2.

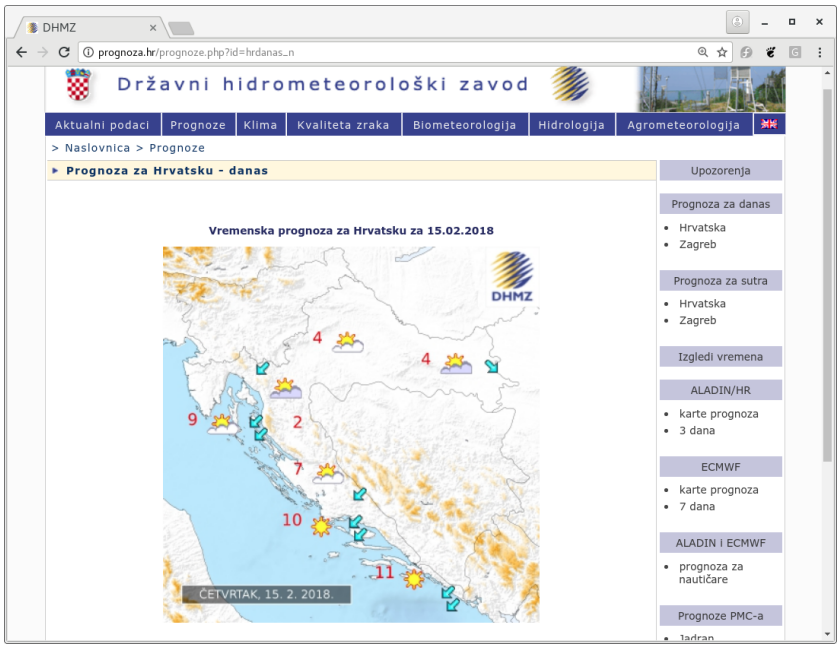

Slika 3.2: Primjer statično generiranog kartografskog prikaza [19]

Učitavanje i prikaz slika podržani su u preglednicima Interneta od njihovih samih početaka. Nije potrebno korištenje JavaScripta i opterećenje klijenta u smislu korištenja računalnih resursa je minimalno. Kod slika veće rezolucije količina prenesenih podataka može biti nešto veća, ali korištenjem odgovarajućih formata za kompresiju slika, i to se opterećenje može smanjiti.

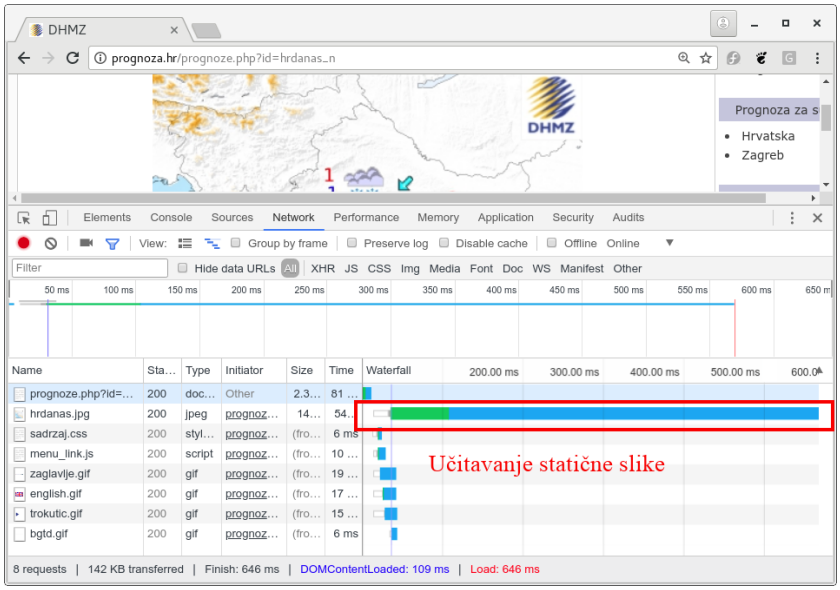

Slika 3.3: Prikaz slijeda učitavanja mrežne stranice sa statičnim prikazom [20]

U primjeru sa slike 3.3 prikaz "hrdanas.jpg" glavni je sadržaj stranice i uzima najviše vremena za učitavanje, veličine je 142,7 kB u neodgovarajućem JPEG formatu. U PNG for-

matu s 256 boja, korisnik ne vidi nikakvu razliku, a veličina tako sažetog prikaza je 75,9 kB, što je značajno manje. Korištenjem PNG formata smanjuje se količina prenesenih podataka i skraćuje vrijeme učitavanja stranice. Glavni nedostatak ovakvog prikaza je nemogućnost inerakcije s korisnikom. Prikaz je statičan i korisnik ne može mijenjati elemente ili scenu prikaza. Ako se želi prikazati više serija podataka ili više različitih scena u slučaju kartografskih prikaza, za svaku od dodatnih varijanti potrebno je izraditi sliku. Iako se ovakav način prikaza još uvijek koristi na puno mrežnih stranica, polako ga zamjenjuju noviji i napredniji interaktivni prikazi sadržaja.

3.2. Dinamički i interaktivni grafički prikazi

U početcima Interneta i prikaza mrežnih stranica, sama stranica je korisniku pružena u obliku statičnog dokumenta. Razvojem objektnog jezika JavaScript koji se izvršava unutar preglednika Interneta i HTML4 standarda s CSS definicijama svojstava objekata, stekli su se uvjeti za iscrtavanje raznih grafičkih prikaza koje dinamički obavlja klijentsko računalo. JavaScript programski jezik omogućava uvođenje interaktivnih sadržaja u prikazu zato što se izvršava unutar mrežnog preglednika te ima direktan pristup svim elementima dokumenta. JavaScript je objektno-orijentiran skriptni jezik koji se isključivo izvršava na korisnikovom računalu (klijentsko računalo). Najčešća upotreba programiranja JavaScript koda jest prilikom pisanja funkcija ugniježđenih unutar HTML stranica. Upravo zbog činjenice da se kôd izvršava na strani korisnika, a ne na nekom udaljenom poslužitelju, moguća je brža reakcija preglednika na korisničke radnje, čime se postiže dinamičnost mrežne aplikacije koja nije bila moguća isključivom upotrebom HTML-a. Danas svaki Internetski preglednik ima u sebi integriranu JavaScript podršku, odnosno tumač (engl. *interpreter*) koji interpretira JavaScript izvorni kôd i izvršava skriptu. Danas je JavaScript najčešće korišteni skriptni programski jezik u svijetu. Od samog početka vrlo je brzo postigao veliku popularnost među programerima u izradi mrežnih stranica.

Korištenjem platna (*canvas*) koji je definiran unutar HTML5 specifikacije, u JavaScript jeziku je moguće kreirati grafički prikaz [21]. Isto tako razvojem standardnih formata podataka kao što su XML i JSON i metodama njihova pozadinskog učitavanja, dolazi do razvoja velikog broja skupova gotovih programskih okvira (engl. *frameworks*) i biblioteka (engl. *libraries*) kojima je olakšan i ubrzan razvoj mrežnih stranica i aplikacija (skup mrežnih stranica koje čine programsko rješenje). Osim formata za pozadinsko učitavanje podataka, katkada se koriste i specijalizirani protokoli kao što su WebSocket [17]. Danas su dostupni već gotovi specijalizirani paketi za iscrtavanje grafičkih prikaza od kojih su neki navedeni u tablici 3.1.

Tablica 3.1: Biblioteke za prikaz grafova korištenjem JavaScripta.

Naziv	Razvijatelj
Highcharts [22]	Highsoft
Google charts [23]	Google
Chart.js [24]	Chart.js
plotly.js [25]	Plotly.js

Općenito, za kreiranje grafičkog prikaza s pomoću JavaScripta, potrebno je:

- odrediti u kojem će se objektu na mrežnoj stranici graf iscrtavati (obično je to element,
- definirati svojstva i vrstu grafičkog prikaza,
- odrediti interaktivne elemente prikaza i definirati funkcije odgovora na akcije korisnika,
- osigurati podatke koji će se prikazivati (iscrtavati).

S. Alimadadi i sur. u preglednom radu za razumijevanje interakcija zasnovanih na događajima unutar JavaScript programskog jezika, detaljno opisuju način izvršavanja i same objektne elemente jezika [26]. JavaScript se pri izvršavanju oslanja na objektni model dokumenta (engl. Document Object Model DOM). JavaScript je pokretan dodađajima i omogućuje programiranje detekcije na različitim dijelovima objektnog modela. Većina događaja je uzrokovana interakcijama korisnika osim tajmera i asinkronih poziva. Da stvari budu još složenije, isti događaj se može detektirati na više različitih, hijerarhijski ustrojenih dijelova objektog modela dokumenata. Posebnu pažnju je također potrebno posvetiti asinkronim događajima, odnosno čekati ishod samog asinkronog poziva, ako je njegov rezultat bitan za daljnje izvršavanje koda.

Sve nabrojeno omogućuje dinamičkim prikazima da budu interaktivni, odnosno da korisniku daju mogućnost prilagodbe prikaza. Neke od mogućnosti dinamičkih grafičkih prikaza su:

- isključivanje ili uključivanje prikaza serije podataka,
- zumiranje prikaza na određeno područje,
- prikaz točne vrijednosti za odabranu točku na grafu,
- kreiranje statične slike grafičkog prikaza.

Najzastupljenije JavaScript biblioteke za kreiranje dinamičkih grafičkih prikaza su Highcharts i Google charts.

Highcharts je JavaScript biblioteka koja omogućuje jednostavno kreiranje raznih vrsta interaktivnih grafičkih prikaza koristeći samo čisti JavaScript i HTML5. Besplatna je za korištenje za nekomercijalnu upotrebu. Dokumentacija je opširna i dostupna. Otvorenog je koda i razvijana je od zajednice, kao i od tvrtke Highsoft koja pruža i komercijalnu podršku korisnicima.

Glavne prednosti ove biblioteke su:

- prilagodljivost i jednostavna upotreba,
- prikazi prilagođeni malim ekranima (responsivnost),
- brzina.

Highcharts je dosta korištena biblioteka i može se pohvaliti s dosta velikih korisnika kao što su: Wall Street Journal, IBM, Mastercard, Microsoft, Facebook [27].

Google charts je biblioteka koju je razvio Google. Potpuno je besplatna za korištenje i podržava više različitih vrsta grafova. Otvorenog je koda iako Google u uvjetima korištenja traži da se biblioteka učitava isključivo s njihovih poslužitelja (nije ju moguće koristiti s vlastitog poslužitelja). Poput HighChartsa podržava puno vrsta prikaza prilagodljivih i za male ekrane. Prema nekim procjenama Google charts biblioteka realizira trećinu svih dinamičkih JavaScript grafičkih prikaza. Uz biblioteku je također dostupna baza predložaka spremnih za korištenje (jednostavne grafike, mape ili vremenski grafovi).

3.3. Asinkrono učitavanje podataka

Podatci potrebni za iscrtavanje grafičkih prikaza mogu biti učitani s mrežnom stranicom koja sadrži prikaz, ili naknadno učitani. Za naknadno učitavanja podataka koristi se AJAX. Pod pojmom AJAX podrazumijeva se skup metoda integriranih unutar JavaScripta za pozadinski prijenos podataka između Internet preglednika i poslužitelja. Na taj način je mrežnim aplikacijama omogućeno primanje i slanje podataka s poslužitelja u pozadini, bez ometanja sadržaja i ponašanja same stranice. Učitavanje je moguće učiniti sinkrono i asinkrono. Kod sinkronog učitavanja JavaScript procedura se ne izvršava sve dok podatci nisu dohvaćeni, i tek tada nastavlja izvršavanje. Kod asinkronog učitavanja kontrola se odmah vraća, a samo iscrtavanje se pokreće pri događaju završetka učitavanja i to ako je učitavanje prošlo bez grešaka. U posljednje vrijeme neki preglednici (Chrome) više i ne dopuštaju sinkrono učitavanje radi boljega korisničkog iskustva. Podatci koji se naknadno učitavaju uglavnom su u JSON (JavaScript Structure Objects Notification) formatu. U preglednom radu J. J. Garrett predstavlja AJAX kao novi pristup u izradi mrežnih aplikacija [28]. Osim detaljnog opisa načina na koji funkcionira, autor također ispravno predviđa njegovu sve masovniju primjenu u budućnosti.

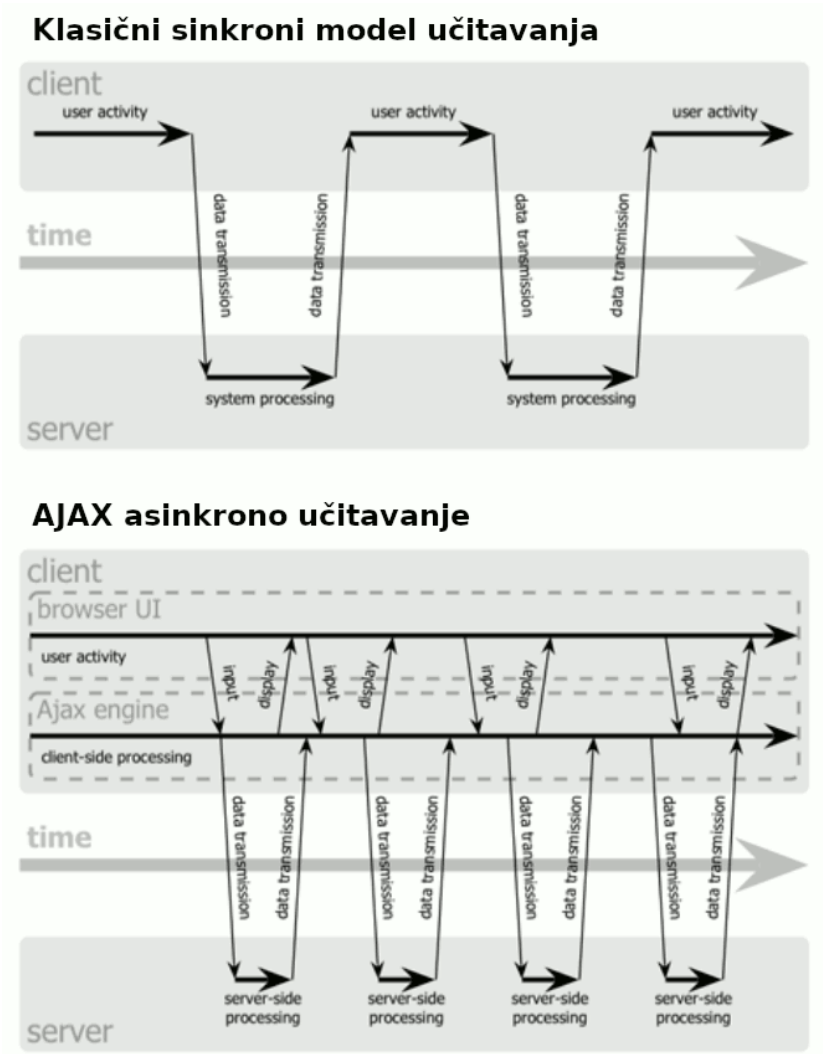

Slika 3.4: Usporedba klasičnog sinkronog i AJAX asinkronog učitavanja stranice [28]

3.4. Dinamički mrežni kartografski prikazi

Dinamički kartografski prikaz podrazumijeva određen minimum operacija i interakcija sa samom kartom. To je kao prvo i osnovno mogućnost zumiranja karte na željeno područje. Dodatno, moguće su interakcije s objektima na karti, prikaz koordinata s karte, promjena osnovnog sloja i dodatnih slojeva na karti. Do razvoja preglednika i JavaScript programskog jezika ovakav se prikaz mogao dobiti samo s pomoću specijaliziranih računalnih programa kojima se koristio ograničen skup ljudi. Pojavom dinamičkih prikaza u mrežnom okruženju kartografske prikaze koristi veliki broj korisnika i prisutni na sve većem broju mrežnih stranica.

Najjednostavniji način da se na mrežnoj stranici prikaže dinamički kartografski prikaz korištenje je nekih od biblioteka na temelju JavaScript programskog jezika. JavaScript se izvršava unutar preglednika Interneta s klijentske strane. Sama biblioteka sadrži već gotove

objekte, funkcije i procedure čijim se korištenjem kreira prikaz karte. Na mrežnoj se stranici učita kod biblioteke sa stranica razvijatelja, ili s istog poslužitelja na kojem je i sama stranica. Osnovni se slojevi kreiraju korištenjem nekih od dostupnih "Tile servera" (poslužitelji gotovih preddefiniranih dijelova karte). Preko osnovnog sloja dodaju se korisnički objekti koji mogu biti oznake, linije ili poligoni. Prvih deset najboljih biblioteka nude pregršt mogućnosti. Neke od njih su slične onima unutar više biblioteka, dok su neke jedinstvene. Pomoću njih je moguće prikazati interaktivne i statične karte, animirane karte, geokodiranje, izračun ruta u prometu, podatke o elevaciji pojedine točke i gustoću prometa [29].

Kod odabira kojom se bibliotekom koristiti, bitni su:

- popularnost biblioteke,
- potencijal odnosno implementirane mogućnosti,
- dokumentacija,
- lakoća korištenja.

Tablica 3.2: Najboljih 10 kartografskih JavaScript biblioteka [29].

Naziv	Razvijatelj
Google Maps	Google
Microsoft Bing Maps	Microsoft
OpenLayers	OpenLayers
Foursquare	Foursquare
OpenStreetMap	OpenStreetMap
MapQuest	MapQuest
Mapbox	Mapbox
CartoDB	CartoDB
Esri ArcGIS	Esri
Yahoo BOSS PlaceFinder	Yahoo

Biblioteke navedene u tablici 3.2 koriste se generalno pri izradi mrežnih kartografskih prikaza. Treba razlikovati same kartografske biblioteke koje ponajprije služe za prikaz i prikupljanje kartografskih podataka (kao što je OpenStreetMap), od biblioteka koje služe za izradu interaktivnih mrežnih karata, gdje korisnik može na kartu dodavati svoje objekte (kao što je OpenLayers). Slijedi kratak opis najpopularnijih biblioteka za izradu interaktivnih karata.

Google maps API je vrlo korištena biblioteka razvijena od kompanije Google. Kao osnovni slojevi se standardno koriste Google satelitski, kartografski ili kombiniran satelitski sloj s kartografskim oznakama. Korištenje biblioteke se ne naplaćuje ni za komercijalnu uporabu sve dok broj učitavanja karata ne prelazi 25.000 učitavanja unutar jednog dana. Od 18. lipnja 2018. godine za uporabu Google karata nužno je otvoriti račun i vezati uz njega

broj kreditne kartice. Svaki mjesec se dobije iznos od 200$ na računu koji pokriva navedeni limit korištenja. API osim oznaka (standardnih i prilagođenih) omogućuje iscrtavanje linija i poligona. Kod iscrtavanja poligona bitno je smanjiti broj točaka u poligonu (generalizacija prikaza) jer u suprotnom može doći do pogreške u prikazu ako je broj točaka u poligonu veći od 4.000. U prikazu je integriran i pregled okoliša (*Street View*). To omogućava interaktivno pregledavanje okoliša snimljenog s javnih prometnica tako da se simulira prolazak kroz njih. Satelitske snimke u osnovnom sloju su promjenjivih maksimalnih rezolucija tako da su u naseljenim mjestima snimke većih rezolucija, dok su izvan naseljenih mjesta manjih. Za velik broj gradova izrađeni su i trodimenzionalni modeli pomoću kojih je moguće interaktivno mijenjati perspektivu pogleda (ne samo pogled odozgo nego iz bilo kojeg smjera).

Bing karte su geoprostorna platforma tvrtke Microsoft. Trenutačno je aktualna verzija 8 biblioteke za mrežne stranice - SDK (Software Development Kit). Osnovni slojevi su karta i satelitski snimci. Korištenje biblioteke je besplatno za obrazovne i neprofitne ustanove te za ostale za promet manji od 10.000 učitavanja mjesečno. Za korištenje se nužno registrirati i dobiti programski ključ. Slično kao i kod Google karata moguć je i pregled okoliša (u Bing kartama to se zove "birds eye"). Pregled okoliša nije svugdje moguć (Hrvatska nije pokrivena) i donekle zaostaje za Googlovom implementacijom. Satelitske snimke su na svim područjima iste rezolucije, što Bing prikazima daje prednost nad Google snimcima izvan naseljenih mjesta. Na početku se za prikaz karata koristila danas napuštena Microsoftova SilverLight tehnologija, a nakon toga se ipak prešlo na standardizirani i opće prihvaćen HTML i JavaScript. Microsoft je dopustio slobodno korištenje Bing karata, satelitskih snimaka i servisa za OpenStreetMap, neprofitni projekt kojem je cilj kreiranje otvorene i slobodne karte pomoću doprinosa zajednice.

OpenLayers je klijentska JavaScript biblioteka, odnosno skup gotovih programskih funkcija, otvorenog koda, namijenjena za stvaranje interaktivnih mrežnih karata i njihovo prikazivanje u preglednicima. Omogućava izradu kompletnih kartografskih aplikacija, s mogućnošću prilagodbe svake komponente karte (slojeva, kontrola, događaja i drugo) prema vlastitim potrebama. Pruža podršku za rad s brojnim formatima poput GeoRSS, KML, GML, GeoJSON i kartografskim podatcima iz bilo kojeg poslužitelja koji se koriste OGC standardima kao što su WMS i WFS. Razvijen je kao projekt Open Source Geospatial Foundation (OSGeo) sa svrhom da posluži kao osnovno mrežno sučelje za prikaz kartografskog sadržaja u izgradnji nekomercijalnih geoinformacijskih mrežnih aplikacija. Svrha OpenLayersa je i razdvajanje kartografskih alata i prostornih podataka kako bi svi alati mogli raditi u kombinaciji sa svim podatcima. Često se koristi i u kombinaciji s programskim paketima otvorenog koda za poslužitelje kao što je Geoserver. Kao osnovni sloj često se koristi OpenStreetMap [30].

Leaflet je JavaScript biblioteka otvorenog koda. Slična je OpenLayers biblioteci i usmjerena je k jednostavnoj primjeni s uglavnom OpenStreetMap osnovnim slojem. Isto tako

je "lakša" (koristi manje koda) od OpenLayers biblioteke. Lakša je za implementaciju i orijentirana oko HTML objekata za razliku od OpenLayers biblioteke koja je prilagođena GIS svojstvima. U osnovi ima manje mogućnosti prikaza, ali je proširiva dodatcima. Ima vrlo široku bazu korisnika (Facebook, FourSquare, GitHub, Flickr). Za prikaz satelitskih snimaka koristi Bing karte. Za razliku od Google ili Bing karata Leaflet je čista JavScript biblioteka bez vlastitih izvora osnovnih slojeva. Besplatna je i za komercijalnu upotrebu bez ograničenja (BSD licencija).

3.5. Kartografski mrežni servisi i standardi

Mrežna usluga ili servis je metoda komunikacija između dvaju uređaja preko mreže (Interneta). Klijent može zatražiti od poslužitelja usluge koje poslužitelj nudi kao mrežne servise. Mrežni servis predstavlja jednu ili više informacija ili akcija. Za kartografske prikaze na mreži razvijeni su posebni servisi koji omogućuju dijeljenje i prikaz prostornih podataka. Ovi servisi su standardizirani i omogućuju interoperabilnost različitih komponenata potrebnih za kreiranje mrežnih kartografskih prikaza.

Osnovni servisi su:

- mrežni servis karte (Web Map Service - WMS),
- mrežni servis svojstava (Web Feature Service - WFS),
- mrežni servis pokrivenosti (Web Coverage Service - WCS).

3.5.1. Mrežni servis karte - WMS

Ovo je standardni protokol kojim mrežni kartografski poslužitelji kreiraju georeferencirane kartografske prikaze u rasterskom obliku. Sami izvori geoprostornih podataka ne moraju biti u rasterskom obliku. OGC je razvio ovaj protokol i prvi put ga objavio 1999. godine [31].

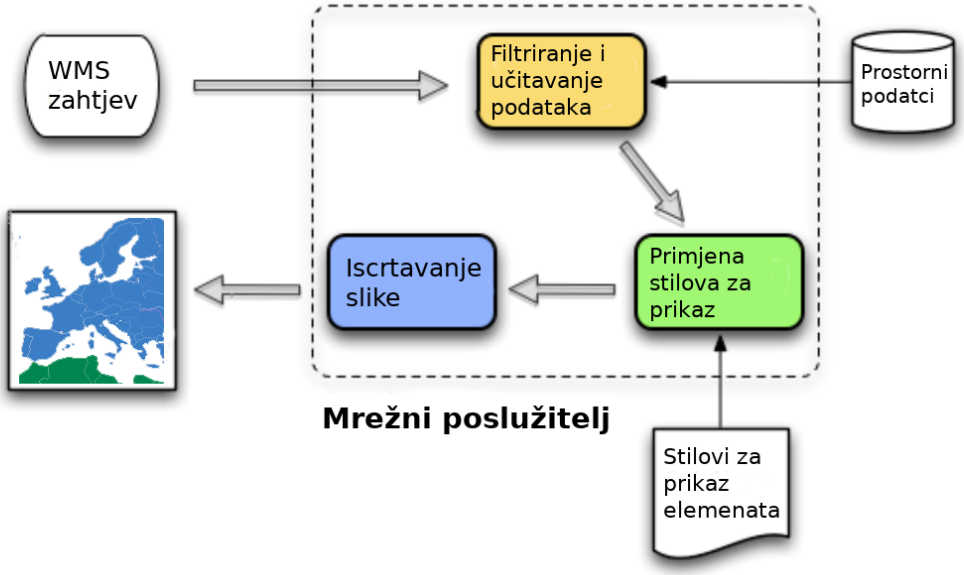

Slika 3.5: Shematski prikaz mrežnog servisa karte (WMS)

Na slici 3.5 prikazan je postupak: klijent šalje zahtjev, poslužitelj generira kartu na temelju parametra iz poslanog zahtjeva, poslužitelj vraća gotovu kartu (engl. *map image*). Izlazni formati su: PNG, PNG8, JPEG, GIF, TIFF, TIFF8, GeoTIFF, GeoTIFF8, SVG, PDF, GeoRSS, KML, KMZ, OpenLayers.

Servis ima definiran određen broj operacija (zahtjeva). To su:

- "GetCapabilities" - informacije o WMS servisu, operacije i parametre koje podržava, popis dostupnih slojeva,
- "GetMap" - dohvaćanje karte određenog sadržaja ovisno o definiranim parametrima u upitu (slojevi, koordinate vrhova okvira),
- "GetFeatureInfo" - podatci o geometriji i atributima objektne klase,
- "DescribeLayer" - dodatne informacije o sloju,
- "GetLegendGraphic" - legenda kartografskog prikaza.

3.5.2. Mrežni servis svojstava - WFS

Ovaj servis služi za dobivanje geoprostornih obilježja/prostornih podataka. Standard je za posluživanje vektorskih geoprostornih podataka. Dohvaćeni podatci su najčešće u vektorskom obliku, odnosno geometrija s atributima. Omogućuje razne analize u daljnjem radu, kreiranje drugih karta i aplikacija, transformacije između formata, vizualizaciju i slično [32].

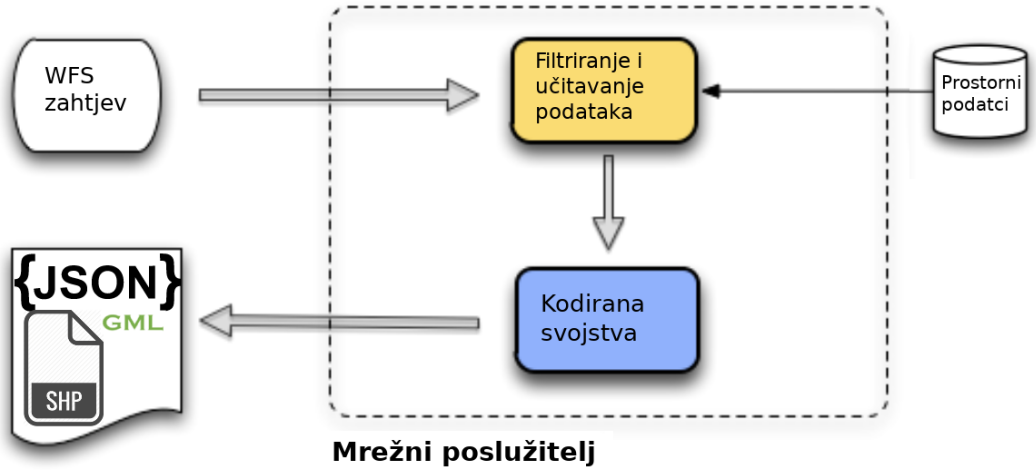

Slika 3.6: Shematski prikaz mrežnog servisa svojstva (WFS)

Na slici 3.6 prikazan je postupak: na zahtjev klijenta poslužitelj dohvaća podatke i kodira ih u traženom obliku. Koriste se različiti ulazni formati podataka, dok su izlazni formati: GML, ESRI Shape, JSON.

Definirane operacija (zahtjevi) su:

- "GetCapabilities" - informacije o WFS servisu, operacije i parametre koje podržava, lista dostupnih slojeva,
- "DescribeFeatureType" - opis obilježja koji se dohvaća,
- "GetFeature" - dohvaća obilježja/objekte iz baze podataka, uključujući geometriju i atribute.

3.5.3. Mrežni servis pokrivenosti - WCS

Mrežni servis pokrivenosti definira mrežnu implementaciju za pristup podatcima o pokrivenosti. Pokrivenost u ovom slučaju predstavlja geoprostornu informaciju koja opisuje fenomen koji se mijenja kroz prostor i vrijeme. Ovim servisom se dohvaćaju podatci za renderiranje/prikaz s klijentske strane ili za daljnu obradu kao npr. ulaz u numerički model. Servis omogućuje klijentu da dohvati dio podataka s poslužitelja na osnovi prostornih i drugih kriterija. Za razliku od mrežnog servisa karte (WMS) koji vraća samo slike generirane na poslužitelju, ovaj servis uz same podatke daje i njihov detaljan opis koji omogućuje da se podatci dodatno obrade i interpretiraju, a ne samo jednoznačno prikažu. Za razliku od mrežnog servisa svojstava (WFS) koji daje podatke za diskretna geoprostorna svojstva nepromjenjiva u vremenu, ovaj servis pokrivenosti dodaje višedimenzionalnu matricu svojstava. Servis omogućuje dohvaćanje osnovnih prostornih i vremenskih podskupova podataka. Ograničavanje skupa podataka putem upita vrši se na dva osnovna načina. Prvi je “rezanje” (*trimming*)

podataka gdje se dohvaćaju sva vremena/parametri (dimenzije) podataka, ali za ograničeno područje. Drugi je filtriranje (*slicing*) podataka gdje se za cijelo područje dohvaća samo neko vrijeme/parametar i tako se smanjuje dimenzija podataka. Kombiniranjem obaju načina može se doći do željenog poskupa za traženi prostorno/vremenski upit [33].

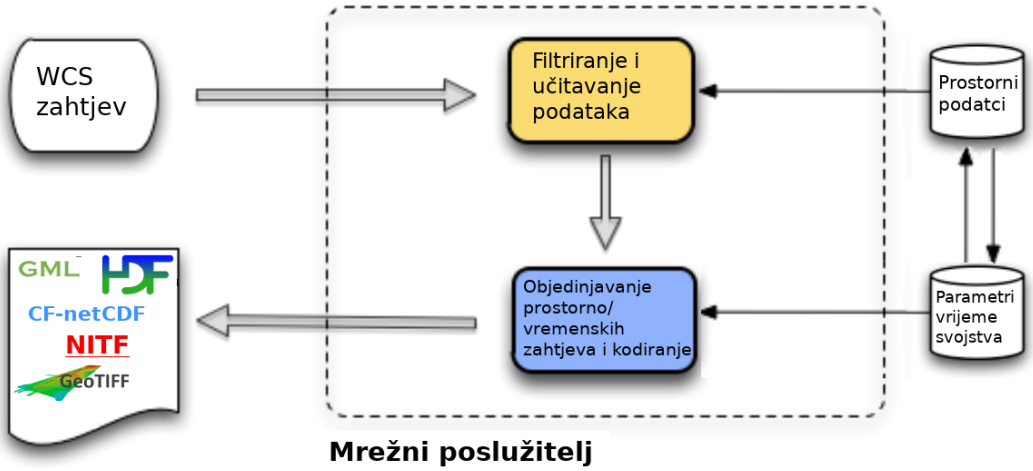

Slika 3.7: Shematski prikaz mrežnog servisa pokrivenosti (WCS)

Na slici 3.7 prikazan je shematski sam servis. Prostorni podatci i sami parametri/vrijeme u praksi su unutar iste baze podataka. Na shemi su razdvojeni kako bi se ilustrirala spomenuta dva osnovna načina ograničavanja podskupa podataka.

Definirane operacije (zahtjevi) su:

- "GetCapabilities" - informacije o servisu, svojstva i ponuđeni parametri,
- "DescribeCoverage" - opis pokrivenosti, prostorno-vremenski/parametarski,
- "GetCoverage" - dohvaća podatke u prikladnom formatu na osnovi dostavljenog upita.

3.5.4. Open Geospatial Consortium servisi

Servisi opisani u prethodna tri poglavlja definirani su i opisani kao Open Geospatial Consortium standardi. Open Geospatial Consortium (Udruženje za otvorenost prostornih podataka) neprofitna je organizacija za standardizaciju nastala 1994. godine. Okuplja preko 500 komercijalnih, vladinih, neprofitnih i istraživačkih organizacija. Ovi servisi predstavljaju promjenu u načinu na koji se geografske informacije stvaraju, mijenjaju i razmjenjuju na Internetu. Primjerice, umjesto dijeljenja geografskih informacija na razini datoteke s pomoću FTP protokola, WFS nudi izravan fino obrađen pristup zemljopisnim informacijama na razini svojstava i značajki. Usluge servisa omogućuju klijentima da samo dohvaćaju ili mijenjaju podatke koje traže, umjesto da dohvaćaju datoteku koja sadrži podatke koje traže,

a možda i mnogo više. Dohvaćeni podatci se mogu koristiti u različite svrhe čak i drugačije od osnovne svrhe radi koje su dostupni. U dokumentaciji standarda dostupne su detaljne specifikacije potrebne za njihovu implementaciju [34]. Većina standarda propisanih od udruženja ovisi o grubo definiranom ustroju opisanom u skupu dokumenata zajedničkim imenom opći tehnički opis (*Abstract Specification*). Ovi dokumenti opisuju osnovni podatkovni model za predstavljanje geografskih obilježja, i na njima se temelji niz specifikacija primjenom kojih je omogućen zajednički rad i razmjena podataka različitih tehnologija koje se bave prostornim i geolociranim podatcima.

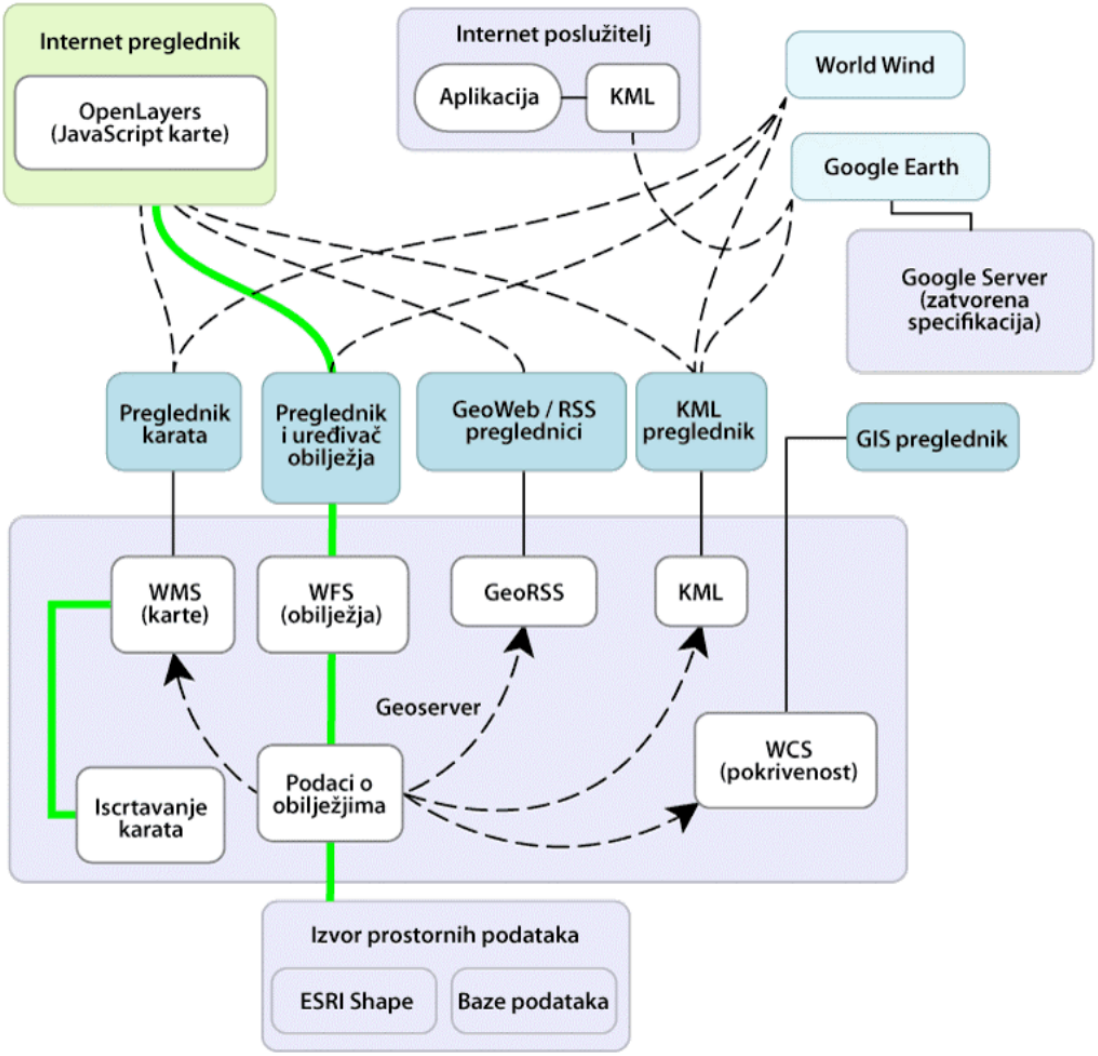

Slika 3.8: Povezanost i korištenje standarada i servisa po OGC specifikacijama [35]

Na slici 3.8 vidljivi su korisnici servisa na više različitih razina, od specijaliziranih GIS programa, preko mrežnih poslužitelja do mrežnog preglednika uz korištenje JavaScripta (OpenLayers). Geoserver je naveden kao referentna implementacija standarada. Osim veza navedenih na prikazu, moguće su i razne druge kombinacije kojih razvojem samih standarda i GIS tehnologije ima sve više. Kao dodatak servisima sve više se koriste (u nekim slučajema

postaju i obavezni) i servisi za pronalazak i katalogiziranje dostupnih mrežnih podataka na Internetu. GeoNetwork je referentna implementacija za ovu vrstu servisa. Koristeći standardizirane upite servisa i dodavanjem širih metapodataka dobivaju se pregledni i centralizirani katalozi prostornih podataka. Standardizacija mrežnih servisa omogućuje povezivanje podataka s različitih izvora radi analize i dobivanja dodatne vrijednosti, kao što je pokušaj kreiranja portala kopnenih voda na Novom Zelandu [36]. Autori H. Klug i A. Kmoch su opisali kreiranje OGC servisa za hidrologiju u svrhu bolje dostupnosti i vizualizacije podataka. Kod objedinjavanja podataka s više različitih izvora važnu ulogu ima standardizacija prostornih slojeva. Kod konkretne implementacije razmatrala se upotreba PostgreSQL i mySQL za pohranu podataka, UMN Mapserver i Geoserver kao poslužitelji prostornih podataka, Tomcat i Jetty kao mrežni poslužitelji, te OpenLayer, Mapbender i GeoExt kao JavaScript biblioteke s klijentske strane.

3.6. Programski paketi za poslužitelje namijenjeni kreiranju dinamičkih kartografskih prikaza - mrežni GIS

Mrežni GIS je distribuirani informacijski sustav koji se sastoji barem od poslužitelja i klijenta. Klijent je korisnik na mreži koji sadržaj konzumira samo preko mrežnog preglednika. Ovakvi programski paketi omogućuju uz prikaz samih slojeva, servise putem kojih se slojevi mogu uključiti u bilo koji prikaz. Kao izvor podataka ovi slojevi mogu se koristiti datotekama s poslužitelja ili nekom od prostornih baza podataka.

Nabrojimo osnovna svojstva mrežnog GIS-a.

- Kreiraju prikaze u obliku mrežnih stranica s jedinstvenom adresom (URL).
- Komunikacija s klijentima odvija se putem HTTP protokola.
- Na poslužitelju se izvršavaju GIS operacije (preklapanje slojeva).
- Izlaz s poslužitelja može biti u više oblika - HTML, slike, XML, JSON i slično.

Mrežni GIS poslužitelji instaliraju se na posebna poslužiteljska računala s jedinstvenom mrežnom adresom. Obično se na njima koristi neki od poslužiteljskih operacijskih sustava (u većini slučajeva neka od distribucija Linux operacijskog sustava). Na istom računalu može biti instalirana i relacijska baza, ali isto tako mrežni GIS poslužitelj može uključivati i više od jednog računala (ovisno o traženim performansama sustava).

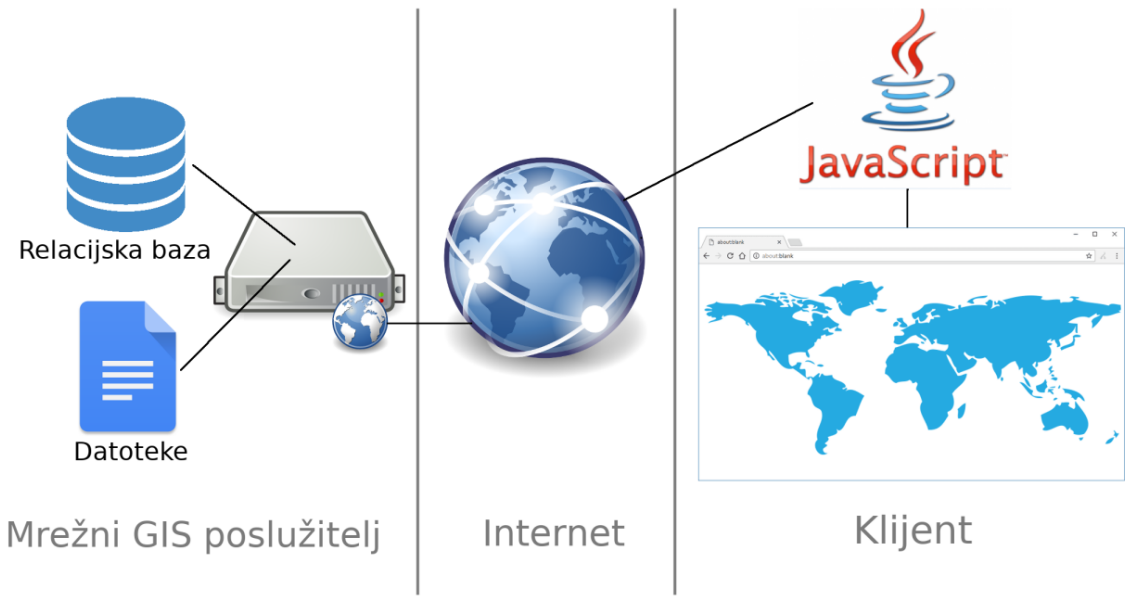

Slika 3.9: Shematski prikaz rada mrežnog GIS poslužitelja

Proces prikaza počinje od zahtjeva klijentskog računala putem http protokola. Mrežni GIS poslužitelj prvo pregledava ima li tražene servise već spremne u priručnoj memoriji (*cache*). Ako ih nema, onda proslijeđuje zahtjev izvoru podataka i kreira odgovarajući format za odgovor. Na kraju šalje odgovor putem Interneta, gdje se podatci prikazuju.

Neki od najviše korištenih su:

- "Geoserver",
- "UMN MapServer",
- "ArcGIS Server".

Geoserver je programski paket otvorenog koda pisan u programskom jeziku Java. Za korištenje se preferira Oracle implementacija Jave verzije 8, ali dobro radi i korištenjem otvorene OpenJDK 8 implementacije. Osim samog prikaza omogućuje i dijeljenje, obradu i uređivanje prostornih podataka. Dizajniran za interoperabilnost kao izvor prostornih podataka podržava razne izvore u skladu s otvorenim standardom.

Neki od podržanih izvora podataka su: PostGIS, Oracle Spatial, ArcSDE, DB2, MySQL, Shapefiles, GeoTIFF, GTOPO30, ECW, MrSID, JPEG2000.

Geoserver je referentna implementacija udruženja za otvorenost prostornih podataka (Open Geospatial Consortium) mrežnog servisa svojstva (Web Feature Service - WFS). Sadrži i OpenLayers (JavaScript biblioteka) klijent za pretpregled slojeva. Neki od izlaznih formata kroz standardne protokole su: KML, GML, Shapefile, GeoRSS, PDF, GeoJSON, JPEG, GIF, SVG, PNG, kao što navodi S. Iacovell u najčešće korištenom priručniku za instalaciju i korištenje Geoservera [37]. Geoserver je mrežna aplikacija i za svoj rad treba neki

od standardnih pokretača Java mrežnih servisa (Java servlet). Neki od najpoznatijih i najčešće korištenih su: Apache Tomcat, Jetty i GlassFish. Iako je Geoserver slobodna aplikacija otvorenog koda iza koje ne stoji neka velika kompanija, postoje organizacije/kompanije koje zainteresiranim korisnicima pružaju komercijalnu podršku pri korištenju Geoservera. Te iste organizacije su i razvijatelji Geoservera, tako da ga mogu i prilagođavati pojedinim specifičnim potrebama svojih korisnika. Ključni razvijatelji i davatelji komercijalnih podrška za Geoserver su: Planet Federal - kompanija iz Sjedinjenih Američkih Država koja je voditelj Geoserver zajednice i glavni razvijatelj, GeoSolutions - talijanska kompanija koja stoji iza mnogih implementacija Geoservera, vrlo aktivna u zajednici, Astun Technology - kompanija iz Ujedinjenog Kraljevstva i GeoCat [38]. Pri iscrtavanju kartografskih prikaza na računalu korisnika objekt karte na mrežnoj stranici komunicira s mrežnim poslužiteljem za prikaz podataka na karti. Sami podatci su pohranjeni na posebnom poslužitelju podataka. Na primjer, kad korisnik zumira kartu, klijent zahtijeva nove pločice karte s poslužitelja karte. Poslužitelj će generirati nove karte koje odgovaraju razini zumiranja. Novonastale karte bit će poslane na objekt karte, a klijent mrežne karte će ga prikazati na karti koja je integrirana u mrežnu stranicu.

Jedna od ključnih tehnologija na kojima je baziran GeoServer je GeoWebCache tehnologija kojom se omogućuje iznimno brzo kartiranje unaprijed spremljenih dijelova karte u međuspremnik (engl. *cache*). Također jedna od bitnih karakteristika je i podrška za otvoreni standard za definiranje stila prikaza karte (Styled Layer Descriptor - SLD). Zbog svojih značajki GeoServer je, uz UMN MapServer, najpopularnija i najraširenija aplikacija za prikazivanje interaktivnih karata na Internetu. Kao izvor prostornih podataka za postizanje najboljih performansi najbolje je koristiti bazu podataka uz korištenje prostornih baznih indeksa. Nakon toga po brzini idu Shapefiles i na kraju baza s neindeksiranim podatcima. To su rezultati koje je dobio J. Ružička u svojem istraživanju u kojem je usporedio brzinu učitavanja oko 8 GB prostornih podataka putem Geoservera na Linux poslužitelju pri čemu je koristio PostgreSQL bazu podataka s prostornim PostGIS dodatkom [39].

UMN MapServer je programski paket otvorenog koda za kreiranje mrežnih kartografskih prikaza. Razvijen je na sveučilištu Minesota i zato se naziva UMN (University of Minnesota) Map server kako bi se razlikovao od komercijalnoga, ali puno manje korištenog Map servera. MapServer je izvorno razvijen uz potporu Američke svemirske agencije (NASA) kako bi satelitski snimci bili dostupni na Internetu. Ovaj programski paket je opisan u radu R. R. Vatsavaija i sur. gdje su posebno istaknute njegove performanse i otvorenost [40]. Kartografski mrežni prikaz kreiran s pomoću Mapservera sastoji se od barem triju dijelova. Potrebno je imati prostorne podatke u obliku koji Mapserver prepoznaje, zatim konfiguracijsku datoteku koja zadaje Mapserveru način na koji će interpretirati te prostorne podatke i na kraju datoteku koja određuje sučelje prema korisniku (mrežna stranica). To može biti datoteka pisana u HTML-u, PHP-u ili nekom drugom jeziku koji čitaju Internetski preglednici.

Konfiguracijska datoteka zadaje objekte Mapservera unutar jednog projekta. Svaki objekt ima svoje parametre i podobjekte.

MapServer je, u osnovi, CGI (engl. Common Gateway Interface) program koji se nalazi na mrežnom poslužitelju i čeka zahtjeve. MapServer odgovara na zahtjev u skladu s prenesenim parametrima kroz URL i Map datoteke te stvori sliku zatražene karte. Zahtjev može također biti za slikom legende, slikom mjerila, slikom referentne karte te vrijednosti prenesene kao CGI varijable. Od verzije 6.0 dostupan je i MapCache dodatak za spremanje i brzi dohvat unaprijed generiranih dijelova karte.

ArcGIS server je komercijalni programski paket kompanije ESRI. ESRI (Environmental Systems Research Institute) privatni je institut sa sjedištem u Kaliforniji, Sjedinjene Američke Države. To je opsežna i integrirana programska platforma za izgradnju operativnog GIS-a. ArcGIS sadrži četiri ključna dijela softvera: geografski informacijski model za modeliranje aspekata stvarnog svijeta; komponente za pohranjivanje i upravljanje geografskim informacijama u datotekama i bazama podataka; skup aplikacija za stvaranje, uređivanje, upravljanje, mapiranje, analiziranje i širenje geografskih informacija; i skup mrežnih usluga koje pružaju sadržaj i mogućnosti (podatke i funkcije) mrežnim klijentima. Dijelovi programskog sustava ArcGIS mogu se postaviti na mobilne uređaje, prijenosna i stolna računala te poslužitelje [41].

Poslužiteljski programski paket moguće je instalirati na Solaris, Linux i Windows poslužiteljske operacijske sustave. ArcSDE je poseban dio paketa zadužen da omogući spajanje ArcGIS servera na relacijske baze podataka. Podržane su Oracle, PostgreSQL, DB2, Informix i Microsoft SQL Server relacijske baze. Programski paket se prodaje u tri varijante (edicije): Basic, Standard i Advanced. ArcGIS Server Basic je primarno samo za upravljanje višekorisničkim prostornim bazama podataka. Neki su od mrežnih servisa koje podržava ArcGIS Server Standard i Advanced, osim standardnih (mrežni servis karte - WMS, mrežni servis svojstava - WFS i mrežni servis pokrivenosti - WCS), Feature (za uređivanje putem mreže), Geodata (za replikaciju prostornih baza), Geocode (za pronalazak i prikaz lokacija i adresa), Geometry (za prostorne izračune kao što su izračun površine ili udaljenosti), Geoprocessing (za numeričke modele i prostorne analize), Globe (za 3D i renderiranje globusa), Image (za posluživanje rasterskih slika kao što su satelitske ili ortofoto slike), Keyhole Markup Language (KML), Map (za optimiziranje kartografskih servisa).

ArcGIS Server programski paket je u svom današnjem obliku prvi put izdan 2004. godine.

3.7. Korištenje relacijskih baza podataka

Danas implementacija većine dinamičkih mrežnih stranica koristi relacijske baze podataka (uz nerelacijske NoSQL baze). Mrežne stranice koje prikazuju prostorno-vremenske podatke

nisu izuzetak. Relacijske baze podataka se koriste kao izvor podataka za grafičke prikaze podataka i za prikaz mrežnih kartografskih prikaza. Korištenje baza podataka omogućuje jednostavniju implementaciju, kao i veće mogućnosti prikaza korištenjem prilagođenih upita prema bazi. Tako se iz ukupnog skupa dostupnih podataka brzo i jednostavno izvlači određeni podskup na temelju korisnikovih ulaza na samom mrežnom sučelju. Upiti se izvršavaju korištenjem standardiziranog "jednostavnog jezika za upite" (SQL - engl. *Simple Query Language*). Relacijska baza podataka nije direktno izložena prema korisniku mrežne stranice, nego se koristi s pomoću raznih "aplikacijskih servera", odnosno programske podrške implementirane na poslužitelju koja kontaktira bazu i generira dinamičke mrežne stranice. Aplikacijski server može biti općeg tipa (za kreiranje dinamičkih mrežnih stranica) ili programski paketi specijalizirani za dinamičke kartografske prikaze.

Najčešće korištene relacijske baze podataka su MySQL (u posljednje vrijeme popularnija kao MariaDB) i PostgreSQL relacijske baze otvorenog koda. Od komercijalnih baza podataka koriste se Oracle baza i SQL Server od Microsofta. Relacijske baze podataka mogu biti na istom poslužitelju s aplikacijskim serverom, ili ako je potrebno radi boljih performansa na posebnom poslužitelju. Većinom je riječ o poslužiteljima s Linux operacijskim sustavom, na kojem je moguće upogoniti čak i SQL Server Microsoftovu bazu podataka (uz naravno mogućnost korištenja i nekog od Windows poslužiteljskih operacijskih sustava).

3.8. Relacijske baze i JSON

Pri kreiranju dinamičkih grafičkih prikaza kao izvor podataka često se koristi JSON (JavaScript Structure Objects Notification) format. Podatci se u ovom formatu često naknadno učitavaju kako bi se prikazali pomoću grafičkih prikaza. JSON je u ovoj ulozi potisnuo stariji XML (jezik za označavanje podataka, engl. *EXtensible Markup Language*), ponajprije jer podržava definiranje i korištenje nizova podataka unutar srukture pojedinog zapisa. Osim toga JSON je lakši za rukovanje razvijateljima i omogućuje definicije objekata.

Kako bi se razvijateljima programskih rješenja olakšala uporaba JSON formata, mnoge relacijske baze podataka podržavaju taj format:

- MySQL (verzija 11.6) JSON tip podataka pretraživ po atributima i funkcije za rukovanje JSON podatcima,
- MariaDB (verzija 10.2) funkcije za baratanje JSON podatcima,
- PostgreSQL (verzija 9.3) tip podataka pretraživ po atributima i funkcije za rukovanje JSON podatcima,
- Oracle (verzija 12) JSON tip podataka pretraživ po atributima i funkcije za rukovanje JSON podatcima,
- SQL Server (verzija 2016) funkcije za rukovanje JSON podatcima.

3.9. Relacijske baze i prostorni podatci

Neke od relacijskih baza podataka imaju posebne tipove podataka za pohranu i upravljanje prostornim podatcima. U tim prilagođenim strukturama pohranjuju se i informacije o projekciji i vrsta prostorne geometrije zajedno s prostornim podatcima. Osim tipova podataka implementirane su i funkcije koje omogućuju određene prostorne analize unutar baze podataka. Kako bi upiti i analize bili učinkovitije izvršavani, baze omogućuju i kreiranje prostornih indeksa.

U nastavku su navedene često korištene relacijske baze s popisom prostornih mogućnosti.

- PostgreSQL - PostGIS dodatak s prostornim mogućnostima:
  - Tipovi za različite vrste geometrija,
  - Prostorne funkcije izračuna (udaljenost, površina),
  - Prostorne funkcije operacija (presjek, unija),
  - Prostorno indeksiranje,
  - Podrška za rastere (PostGIS WTK Raster).
- Oracle Locator - prostorni dio Oracle baze "Standard edition". Osnovni GIS tipovi podataka i osnovne funkcionalnosti:
  - Tipovi za različite vrste geometrija,
  - Prostorne funkcije izračuna (udaljenost, površina),
  - Prostorne funkcije operacija (presjek, unija),
  - Prostorno indeksiranje.
- Oracle Spatial - dodatne prostorne mogućnosti kao dio Oracle baze "Enterprise edition". Napredne GIS mogućnosti za posebne GIS aplikacije (dodatno uz locator):
  - Napredne transformacije koordinatnih sustava,
  - Prostorne funkcije boljih performansi (brzi paralelni upiti),
  - Napredne mogućnosti particioniranja tablica i poboljšani prostorni indeksi.
- MySQL - prostorni dio baze koji odgovara OpenGIS klasama. Osnovni GIS tipovi podataka i osnovne funkcionalnosti (u zadnjoj verziji iste funkcionalnosti podržava i MariaDB baza):
  - Tipovi za različite vrste geometrija,
  - Prostorne funkcije izračuna (udaljenost, površina),
  - Prostorne funkcije operacija (presjek, unija),

  - Prostorno indeksiranje.

- SQL Server - Microsoft relacijska baza. Osnovni GIS tipovi podataka i osnovne funkcionalnosti:
  - Tipovi za različite vrste geometrija,
  - Prostorne funkcije izračuna (udaljenost, površina),
  - Prostorne funkcije operacija (presjek, unija),
  - Prostorno indeksiranje.

Navedene prostorne mogućnosti čine relacijske baze podataka pogodnim izvorima podataka za specijalizirane programske pakete namijenjene kreiranju mrežnih dinamičkih kartografskih prikaza (poglavlje 3.6 - Geoserver, UMN MapServer, ArcGIS Server). Posebno se pri korištenju relacijskih baza kao prednost nad statičnim izvorima prostornih podataka iz datoteka izdvaja mogućnost "parametrizacije" prostornog sloja iz baze. "Parametrizacija" znači da se parametar s korisnikova upita može lako upotrijebiti kao kriterij na osnovi kojega se može izvući podskup prostornih objekata koji sadrže željeno svojstvo.

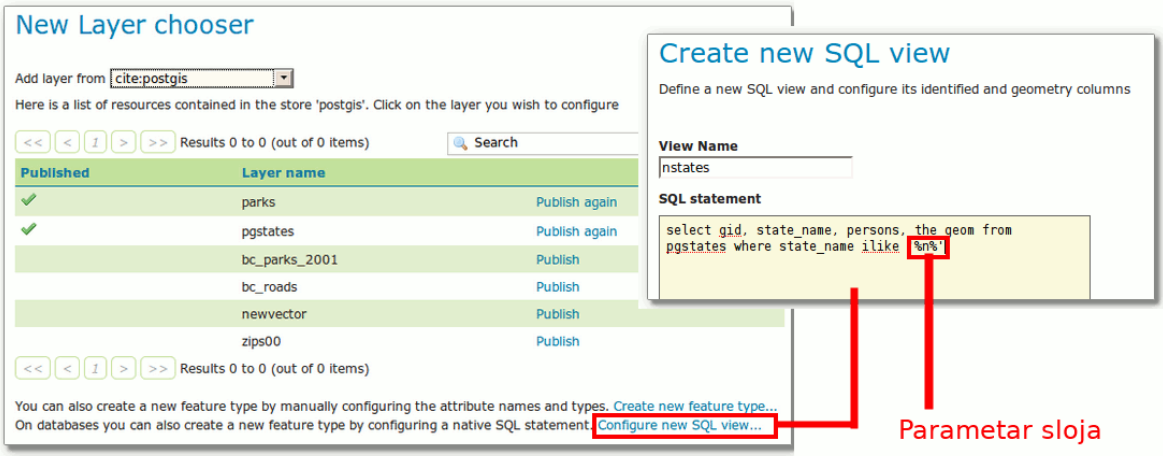

Slika 3.10: Primjer kreiranja parametriziranoga prostornog sloja iz relacijske baze podataka u Geoserveru

Primjer korištenja relacijske baze, konkretno PostgreSQL baze pri kreiranju složenog sustava za vizualizaciju prostorno-vremenskih podataka, sustav je za predviđanje i praćenje cunamija opisan u disertaciji B. Keon [42]. Korištena je PostgreSQL baza s PostGIS prostornim dodatkom. Baza je instalirana na Linux poslužitelju i bila je jezgra složenog sustava za mrežnu vizualizaciju rezultata numeričkog modela. Dio sustava bili su i mrežni poslužitelj (PHP i Apache) te poslužitelj za pokretanje numeričkog modela, oba također na Linuxu (RHEL 6). Daljni razvoj istog sustava s dodatnim mogućnostima opisan je u radu [43]. Spomenuti primjer je i iznimka po tome što je rezultat dostupan na Internetu na adresi `http://www.prism.oregonstate.edu/`.

3.10. Primjeri prikaza prostorno-vremenskih podataka

Prikaz prostorno vremenskih podataka na Internetu se u većini slučajeva odnosi na meteorološke podatke. Osim meteoroloških, moguće je pronaći, ali u puno manjem broju, i ostale okolišne podatke kao što su oceanografski ili ostali okolišni parametri povezani s ekologijom. U literaturi se mogu pronaći različiti teoretski opisi sustava. Neki su sadržani u projektima sa svrhom zaštite okoliša, kao što je sustav za praćenje i prognozu kretanja naftnih mrlja u Grčkoj. Sustav su opisali M. Kulawiak i sur. i razvijen je u okviru MARCOAST projekta [44]. Specifičnost ovog rada je u tome što daje usporedbu komercijalnog Esri ArcIMS sustava s Geoserverom i OpenLayersom otvorenog koda, uz zaključak da se s drugo navedenim postižu bolji rezultati. Drugi primjer je rad M. Hechera i sur. vezan uz prikaz prostornih meteoroloških podataka na mreži [45]. Ovdje uz kartografske možemo pronaći i grafove koji se odnose na prikazano područje. Rad se bavi teoretskom podlogom za izradu sustava za vizualizaciju podataka na mreži. Treći primjer je rad S. Harbole i V. Coorsa koji razmatra moguće primjene mrežnih analiza i vizualizacija prostornih podataka za "pametne gradove" [46]. U literaturi se mogu naći teoretske podloge, ali i korisne praktične informacije vezane za samu implementaciju raznih sustava. Jedan od problema je u tome što je razvoj tehnologije i programa tako brz da kada određeni rad izađe i postane dostupan, sustavi koje opisuje obično se više ne koriste tom inačicom (verzijom) programa, ili u takvom okolišu. Drugi je problem što je pristup sustavima opisanima u radovima, ako i jesu zaista implementirani, obično pod autorizacijom, uz upitnu operativnost nakon nekog vremena, tako da se ne mogu analizirati s praktične strane.

Postoji veliki broj specijaliziranih prostornih mrežnih portala za prikaz informacija o pojedinim gradovima ili područjima, ali tu je riječ o statičnim prostornim slojevima bez vremenske komponente.

Posebna vrsta prikaza su portali koji nude usluge i servise prostornih pretraga adresa i pronalaženja ruta od jedne do druge lokacije, gdje također imamo samo prostornu komponentu. Neki od ovakvih servisa uključuju u svoje izračune i podatke o trenutačnoj gustoći prometa na nekom području i uključuju ih u izračun potrebnog vremena putovanja. Ovakve komponente, iako vremenski promjenjive, zapravo ne dodaju vremensku komponentu zato što se izračun uvijek odnosi na trenutnu situaciju i korisnik ne može mijenjati vrijeme na koje se odnosi izračun.

Prikazom nekih tipičnih i često korištenih mrežnih stranica ilustrira se primjena tehnologija opisanih u prethodnim poglavljima u praksi. Isto tako se mogu pratiti raznolika rješenja problema prikaza, od jednostavnijih, manje prilagodljivih i manje okrenutih korisniku do složenih i zahtjevnih dinamičkih prikaza.

Tamo gdje je to moguće saznati iz opisa servisa, ili iz uvida u kôd stranice i korištene tehnike prikaza, bit će opisano i tehničko rješenje koje se koristi za realizaciju pojedine mrežne stranice iz primjera. Gdje nije moguće točno utvrditi pojedine tehničke komponente,

bit će data pretpostavka o korištenim rješenjima i alatima.

3.10.1. DHMZ - Državni hidrometeorološki zavod

Mrežna stranica Državnoga hidrometeorološkog zavoda na adresi `http://meteo.hr/` prikazuje vremensku prognozu za Hrvatsku, rezultate numeričkih modela i izmjerene podatke sa službenih meteoroloških postaja Zavoda [47]. Stranica je u kolovozu 2018. godine dobila novi izgled (redizajnirana je), tako da je prilagođena i za prikaz na manjim ekranima (responsivna je). Načini prikaza prostorno-vremenskih podataka nisu značajnije mijenjani. Stranica je realizirana uz upotrebu PHP jezika za kreiranje dinamičnih mrežnih stranica.

Za prikaz mjerenih podataka koristi se jedino tablični oblik bez dodatnih mogućnosti prikaza i vizualizacija podataka. Za biranje vremenske komponente koristi se niz poveznica iznad tablice koje kod prikaza ponovno učitavaju stranicu s tablicom za željeno vrijeme mjerenja (ne koristi se učitavanje podataka u pozadini - AJAX).

Vrijeme u Hrvatskoj 05.09.2018. u 23 h

Prikaz po regijama

23 00 01 02 03 04 05 06 07 08 09 10 11 12 13 14 15 16 17 18 19 20 21 22

Postaja	Vjetar: smjer i brzina (m/s)	Temperatura zraka (°C)	Relativna vlažnost (%)	Tlak zraka (hPa)	Tendencija tlaka (hPa/3h)	Stanje vremena
Bilogora	NW 3.7	19.2	67	1014.7	0.0	vedro
Bjelovar	NW 0.3	16.9	93	1015.3	0.0	-
Crikvenica	NE 1.8	20.2	69	1014.8	+0.7	-
Daruvar	SW 0.2	15.7	95	1016.2	+0.1	-
Dubrovnik	NW 1.4	23.8	46	1012.4	+0.1	-
Dubrovnik-aerodrom	N 7.0	23.0	50	1012.5	+0.2	vedro
Gospić	W 0.5	14.6	92	1016.9	+0.7	-

Slika 3.11: Tablični prikaz mjerenih podataka sa stranice meteo.hr [47]

Za prikaz rezultata numeričkog modela ALADIN za određenu lokaciju kroz vrijeme, koristi se grafički prikazi. Prikaz je interaktivan i realiziran s pomoću Google charts JavaScript programskog paketa. Podatci za iscrtavanje grafičkog prikaza uvijek se učitavaju zajedno s mrežnom stranicom (ne učitavaju se zasebno). Podatci su dani za svaka 3 sata uz posebne piktograme za vjetar i naoblaku.

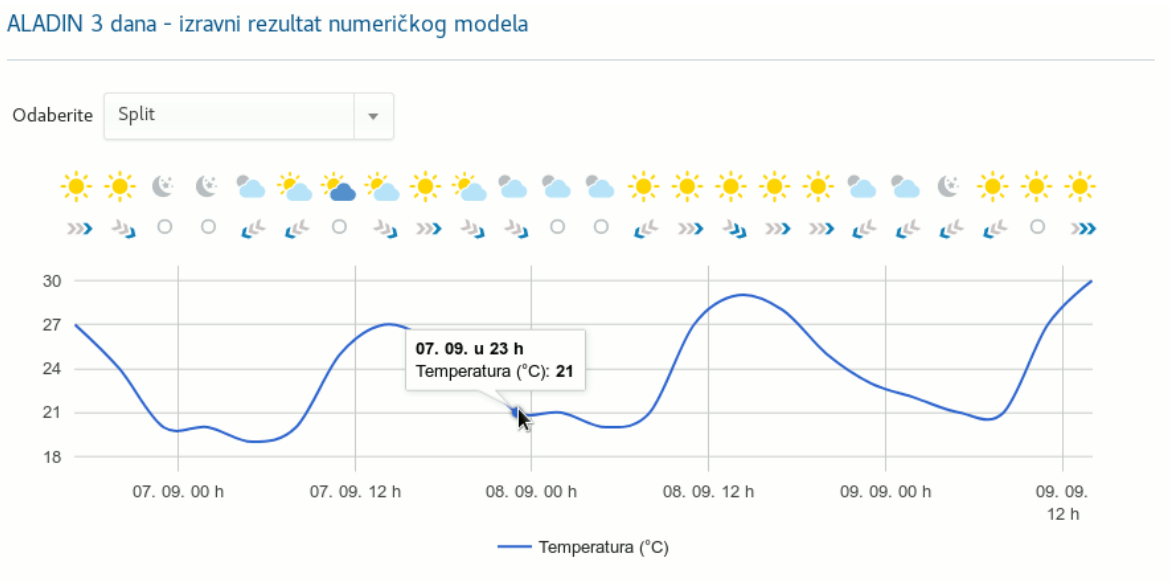

Slika 3.12: Grafički prikaz sa stranice meteo.hr [47]

Kod prikaza prostornog rasporeda meteoroloških prilika na stranici se koriste statične slike. Za prikaz rezultata ALADIN modela slike su potpuno statične bez mogućnosti ikakve interakcije. Za prikaz upozorenja koristi se karta s mapiranim područjima koja služe kao poveznica na upozorenja za određeno područje. Za prikaz vremenskih prilika i dnevnih prognoza koristi se statična pozadinska slika preko koje su na pojedinim lokacijama prikazani manji simboli (slike) s opisom pri prelasku pokazivača (osnovna ograničena interakcija).

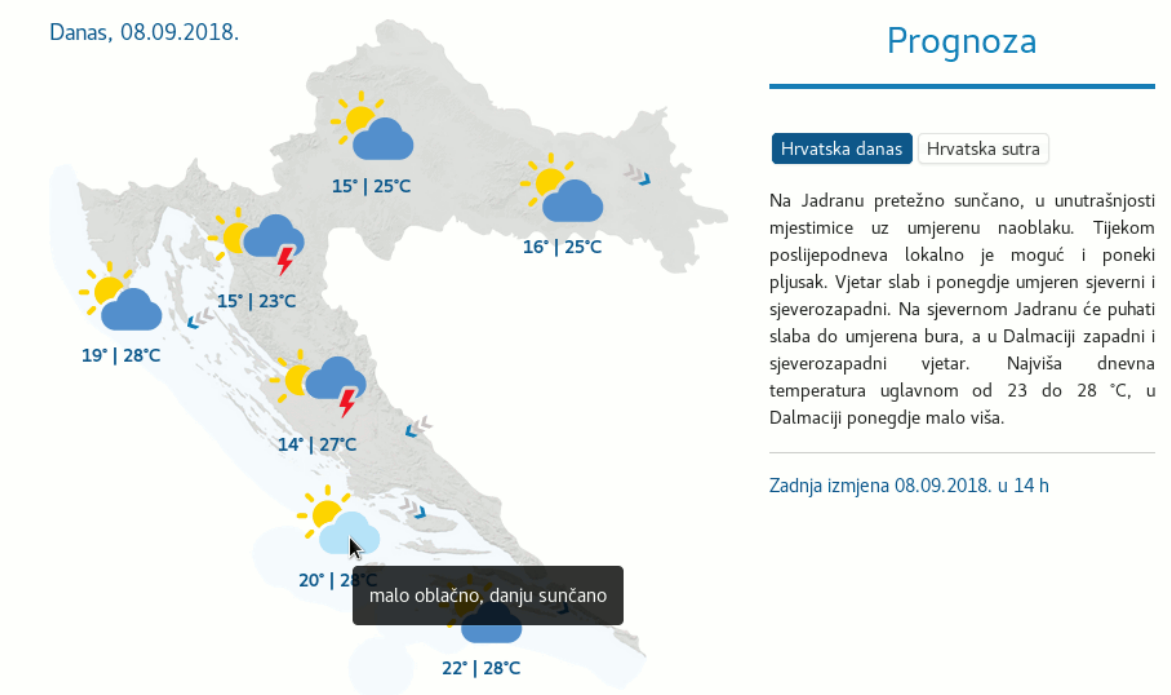

Slika 3.13: Prikaz dnevnih vremenskih prilika [47]

Po korištenim načinima prikaza mrežna stranica `http://meteo.hr/` koristi osnovne načine prikaza uz ograničene mogućnosti za interakciju od korisnika. Postoji prostor i za bolju optimizaciju učitavanja podataka kod prikaza (učitavanje samo podataka u pozadini bez ponovnog učitavanja cijele stranice).

3.10.2. Yr prognoze Norveškoga meteorološkog instituta

Mrežne stranice Yr prognoze Norveškoga meteorološkog instituta na adresi `https://www.yr.no/` daju vremenske prognoze za Norvešku i za cijeli svijet [48]. Osim po prilično točnim prognozama, stranice su poznate i po naprednijim tehnikama vizualizacija podataka, odnosno prikaza prognoza. Stranica je višejezična, i prognoze su dostupne na skandinavskim jezicima i na engleskom jeziku. Stranica nije prilagođena za male ekrane (resposivna), nego postoji zasebna mobilna verzija stranice. Stranica pruža prognoze i grafičke prikaze za oko 9 milijuna lokacija iz cijelog svijeta. Meteorološki podatci su besplatno dostupni i kao mrežni servisi. Stranica je realizirana uz korištenje Microsoftove ASP.NET tehnologije otvorenog koda.

Kod osnovnog prikaza vremenske prognoze za pojedinu lokaciju prikazane su tablično vremenski ogranizirani podatci koji se sastoje od numeričkih podataka i simbola. Pored tablice nalazi se osnovni kartografski prikaz lokacije uz mogućnost pokretanja animacije koja prikaz mijenja od trenutačnog vremena do prognoza za iduća dva dana.

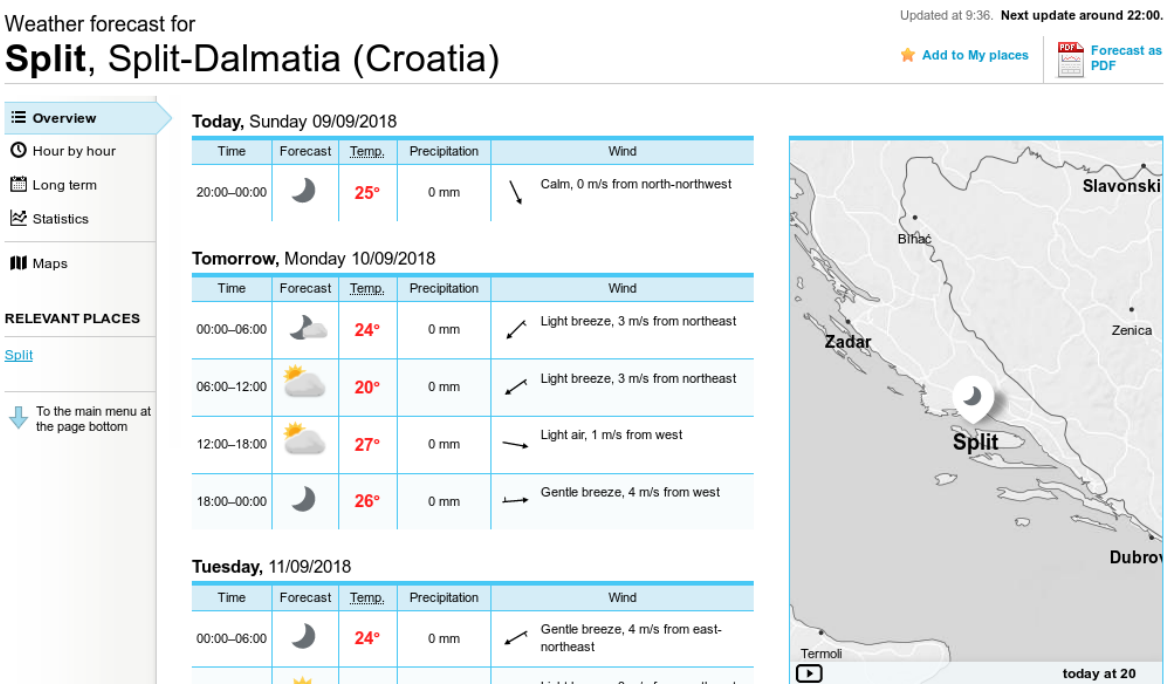

Slika 3.14: Osnovni prikaz prognoze za pojedinu lokaciju na stranici yr.no [48]

3.11. Zaključak

Prikaz prostorno-vremenskih podataka na mreži uključuje upotrebu različitih računalnih i programskih sustava. Možemo pronaći jednostavne unaprijed generirane slike, ali i složene dinamičke prikaze koji uključuju kartografske dijelove i intenzivnu upotrebu JavaScripta. Složeni prikazi koriste JavaScript biblioteke za grafičke i kartografske prikaze uz asinkrono učitavanje podataka u pozadini. Za dohvat kartografskih slojeva se koriste standardizirani (od strane OGCa) servisi i također specijalizirane JavaScript biblioteke.

4. PRIKAZI OCEANOGRAFSKIH PODATAKA I POVIJESNI RAZVOJ

Oceanografija kao znanost uključuje široko područje gdje se promatra i istražuje velik broj parametara. Prije razvoja računala podatci su zapisivani i obrađivani ručno na papiru. Razvojem računala nastala je potreba upisa i obrade podataka na računalu. Rukovanje oceanografskim podatcima kao međunarodno priznata disciplina pojavljuje se oko 1960. godine. Rukovanje oceanografskim podatcima uključuje prvo upis i provjeru podataka, a zatim strukturiranje (obradu), pohranu i vizualizacije podataka. Istraživanje klimatskih promjena daje dodatni poticaj u prikupljanju i obradi oceanografskih podataka. Visoka cijena prikupljanja podataka dodatno pridonosi težnji k njihovoj boljoj iskoristivosti. Veliku ulogu u tome ima računalna obrada podataka koja uključuje korištenje raznih programskih rješenja. Budući da u oceanografiji za razliku od meteorologije još uvijek nije organizirana operativna služba na svjetskoj razini, ne postoje sustavna globalna oceanografska mjerenja i odgovarajuća računalna programska podrška prilagođena tom području.

U ovom poglavlju dat je pregled nekih od rješenja za unos, provjeru i prikaz oceanografskih podataka razvijenih na Institutu za oceanografiju i ribarstvo u Splitu s naglaskom na sučelje prema krajnjem korisniku. Usporedno su navedena i neka od dostupnih rješenja u drugim institucijama.

4.1. Osnovni zahtjevi za rukovanje oceanografskim podatcima

Programska rješenja za rukovanje podatcima neovisno o tehnologiji i sučelju moraju zadovoljiti određene minimalne zahtjeve. To se ponajprije odnosi na sposobnost unosa i rukovanja ne samo s osnovnim podatkom nego i s osnovnim setom metapodataka. Riječ je o takozvanom wwww setu (od engleskog *when*, *where*, *who*, *what*), dakle kad, gdje, tko i što. Za učinkovito rukovanje oceanografskim podatcima bitno je paziti na njihova specifična svojstva.

4.1.1. Prostorna komponenta

Prostorna komponenta je najzahtjevnija za unos. Riječ je o točnim koordinatama na kojima je obavljeno mjerenje ili uzorkovanje. Za zapis koordinata potrebni su zemljopisna dužina i zemljopisna širina. Da bi one imale smisla, treba znati i koordinatni sustav/zemljopisnu projekciju. Problem kod koordinata je taj što je riječ o dva broja (dvije kolone) koje intuitivno za korisnika nemaju nikakvo značenje. Zbog toga se uglavnom koordinate zamjenjuju imenom postaje pri čemu ime postaje predstavlja referenciju za opis podataka s neke lokacije. Kod korištenja imena postaje treba uvijek dosljedno sačuvati tablicu koja povezuje ime s koordinatama, što često nije tako. Dodatni problem stvaraju uobičajena imenovanja postaja koje se u različitim projektima označavaju istim imenima (P1, P2, P3... ili S1, S2, S3) iako se nalaze na različitim lokacijama.

Kvalitetno sučelje za upis zemljopisnih koordinata mora uključivati i kartografski prikaz, gdje se koordinate upisuju klikom na kartu ili upisom koordinata uz istodobni prikaz lokacije na karti za kontrolu.

4.1.2. Vremenska komponenta

Vremenska komponenta uključuje točno vrijeme mjerenja. Točno vrijeme uključuje godinu, mjesec, dan, sat minutu i po potrebi sekundu. Uz ove podatke trebala bi biti zapisana i vremenska zona. Obično je riječ o lokalnom vremenu (npr. UTC+1 za srednjoeuropsku zonu) uz problem zimskog i ljetnog vremena. Sam zapis vremena se sastoji od više brojeva, a uz korištenje baze podataka rješava se formatom zapisa (postoji "date" tip podatka koji uključuje sve nabrojene komponente). Glede dizajniranja sučelja za upis vremena najbolje se pokazalo za datum koristiti posebne padajuće kalendare za upis (*day picker*), dok se vrijeme upisuje u posebno polje u formatu hh24:mi (sat u notaciji 0-23 i minute odvojeni dvotočkom).

4.1.3. Mjerni parametar

Mjerni parametar uključuje skup podataka o samom parametru kao što su mjerna metoda, mjerni instrument uz podatke o kalibracijama te vlasništvo podatka, odnosno osobu koja je obradila i unijela podatke. U dobro organiziranom sučelju najbolje je mjerne parametre birati iz hijerarhijski organizirane liste parametara. Primjer: grupa parametara fizika, mjerni parametar temperatura mora, grupa parametra CTD (Conductivity, Temperature and Depth) sonda i specifični parametar sonda Idronaut, serijski broj xy, kalibrirana na datume a, b c i d uz dodan podatak o vlasništvu (osobi koja je upisala/obradila podatke).

4.1.4. Vrijednost parametra (izmjerena vrijednost)

Ovo je krajnji podatak koji sadrži izmjerenu vrijednost. Ovaj podatak nije koristan bez ostalih metapodataka. Riječ je obično o numeričkoj vrijednosti. Kod dizajna sučelja za upis podataka nema posebnih pravila upisa (obično numeričko polje). Polje može sadržavati raspon, odnosno dopuštenu najmanju i najveću vrijednost koju parametar može poprimiti u određenom zemljopisnom području za pojedino klimatološko razdoblje. Ovo je tek prvi i automatski stupanj kontrole vrijednosti, dok se prava provjera ispravnosti podataka obavlja dodjeljivanjem validacijskih zastavica uz vizualizaciju podataka.

4.1.5. Vrste podataka i mjerenja

Ovisno o načinu mjerenja ili dobivanja podataka možemo izdvojiti neke tipične grupe.

- Podatci dobiveni klasičnim mjerenjima ili uzorkovanjima. Mjerenja se obavljaju tako da se istraživačkim brodom, ili bilo kojim drugim prijevoznim sredstvom (može se koristiti i osobni automobil za uzorkovanja uz samu obalu), dođe do određene lokacije gdje se ručno obavi mjerenje ili uzimanje uzorka koji se kasnije analizira. Glavno svojstvo ovakvih podataka jest to da se moraju ručno upisati, uz iznimku digitalnih sondi koje kreiraju datoteku s izmjerenim vrijednostima. U svim slučajevima potrebno je podatke povezati s metapodatcima.

- Automatski mjerni sustavi. Riječ je o uređajima koji u pravilnim vremenskim razmacima obavljaju mjerenja na određenoj lokaciji. Podatci se mogu očitati s uređaja nakon završetka mjerenja (primjer su uređaji postavljeni na morsko dno) ili sustav uz mjerenja stalno šalje podatke, i tada se to naziva automatski mjerni sustav u realnom vremenu. Ovakvi sustavi daju vremenske nizove podataka na jednoj ili više lokacija (npr. površinski visokofrekventni radari mjere površinske struje i valove u čitavoj mreži točaka).

- Numerički modeli daju podatke koji nisu direktno izmjereni, ali su dobiveni objektivnom analizom i prognozom na osnovi početnih uvjeta, asimiliranih izmjerenih podataka i fizikalnih povezanosti parametara. Podatke dobijamo u čvorovima pravilne prostorne mreže u pravilnim vremenskim razmacima. Sami podatci su diskretni, ali se zbog pravilne mreže mogu lako prostorno interpolirati i onda govorimo o rasterskim podatcima (oni su izvedenica originalnih numeričkih rezultata).

- Satelitske ili radarske slike. Ovdje je riječ o izvorno rasterskim podatcima za koje je jedan od izazova točna geolokacija slike. Kako bi se mogli lakše koristiti, ovakvi podatci se često "digitaliziraju", odnosno na osnovi boje piksela se pohranjuju numeričke vrijednosti u čvorovima pravilne mreže. Za razliku od triju prethodnih grupa, ovom vrstom podataka se nećemo baviti u ovom radu.

Uz sve nabrojene vrste mjerenih podataka, spomenimo još i interpolirane vrijednosti. One su dobivene na osnovi okolnih stvarnih vrijednosti s pomoću neke od metoda interpolacije. Najčešće se rade interpolacije po dubini (po vodenom stupcu) i u novije vrijeme prostorne interpolacije. U prošlosti su ove vrijednosti znale stvarati probleme pri rukovanju podatcima jer imaju prostorno ili vremenski stvarni pomak od pravih mjerenja i tako prolaze testove prostorno-vremenske jedinstvenosti, ali u stvari ne donose nove informacije ili vrijednosti. Napretkom računala sve je češća praksa da se ove vrijednosti računaju "u letu" i prema potrebi i da se posebno ne pohranjuju. U slučaju pohrane bitno je da se označe validacijskom zastavicom kao takve.

Formati pohrane svih vrsta podataka mogu biti raznoliki. Osim relacijskih baza podataka, u praksi se susreću razni tekstualni formati pohrane koji su praktični za direktno korištenje ili automatsko parsiranje. Od binarnih formata treba spomenuti NetCDF format. To je samodefinirajući, strojno neovisni format koji podržava više dimenzionalne nizove podataka. U znastvenoj zajednici postoje mnogi programi koji omogućavaju korištenje i vizualizacije podataka u ovom formatu, kao i pretvaranje u tekstualni oblik ili kreiranje na osnovi tekstualnih ulaza.

4.2. Zašto razvijati vlastita programska rješenja?

Generalno ne postoje dostupni specijalizirani računalni programi za upis oceanografskih parametara. Bez vlastite programske podrške upis podataka se svodi na dva glavna načina:

1. u manjem broju korišteni digitalni mjerni instrument kreiraju datoteku koja sadrži mjerene podatke, dok je uloga korisnika dodavanje metapodataka, i
2. u većini slučajeva korištenjem općenitih programa za upis mjerenjima dobijenih podataka ili nekog od tabličnih kalkulatora.

Tablični kalkulatori u pravilu jesu organizirani i napravljeni za što lakši upis većeg broja alfanumeričkih podataka, ponajprije korištenjem tipkovnice. Glavni problemi kod ovakvog unosa podataka su nejednoobraznost upisa (proizvoljni formati koji otežavaju sustavnu obradu i kontrolu podataka, kao i kozistentnost) i nepostojanje prostorne vizualizacije što dovodi do čestih grešaka kod upisa zemljopisnih koordinata. Bez dodatne programske podrške kvaliteta podataka je vrlo niska, podatci su nepovezani i nakon pisanja inicijalnog izvješća u pravilu nisu ponovno iskoristivi. U Institutu za oceanografiju i ribarstvo programska podrška se održava i razvija koristeći Fortran programski jezik, C i C++ programski jezik, PL/SQL programski jezik (Oracle SQL Developer), JavaScript uz HTML i CSS. Uz to se koristi Linux skriptni jezik Bash za automatiziranje obrada na poslužiteljima, zatim Matlab i Octave skripte za numeričko modeliranje i R skripte za statističke obrade.

4.3. Rukovanje oceanografskim podatcima u drugim institucijama

Rukovanje oceanografskim podatcima je prisutno u brojnim institutima i organizacijama širom svijeta. Posebno se to odnosi na institucije koje su ujedno i NODC (National Oceanographic Data Center), odnosno podatkovni centri za oceanografske podatke na nacionalnoj razini (Institut za oceanografiju i ribarstvo je NODC za Republiku Hrvatsku). Sama programska podrška koja se koristi za upis i provjeru podataka je specifična za svaku instituciju i u pravilu nije javno vidljiva. Na primjer, francuski NODC SISMER (Systèmes d'Informations Scientifiques pour la Mer) koristi Oracle relacijsku bazu podataka za pohranu podataka. Za upis i obradu koriste se lokalno razvijenim alatima za preformatiranje podataka kao i za provjeru ispravnosti (validaciju). Tu su još i SCOOP (sustav za provjeru oceanografskih parametara), CQDG (sustav za provjeru podmorskih geofizičkih parametara), alati za uređivanje i izvješćivanje, NAUTILUS mrežni portal i SELMED za rukovanje podatcima s CD-ROM-a i diskova. Od komercijalnih programa koriste MATLAB, NAG, windows + word, excel, Powerpoint. Za obradu podataka koriste SUN UNIX radne stanice i osobna računala s Windows operacijskim sustavima. BODC (British Oceanographic Data Center) Britanski NODC za vlastite potrebe razvija programsku podršku koristeći MATLAB, Microsoft Access, C++, Oracle SQL Developer, Java and Java Server Pages (JSP), Linux skriptni jezik, Python i Delphi. Za razvoj mrežnih aplikacija koriste ArcIMS, JSP, Perl, JavaScript, HTML and XHTML. Također koriste Oracle relacijsku bazu podataka. Obje navedene institucije su u potpunosti posvećene samo rukovanju podataka sa svojih oko 50 zaposlenika. Na Institutu za oceanografiju i ribarstvo rukovanjem podataka bavi se samo manji dio od oko 5 zaposlenika (Računski centar, Laboratorij za fiziku, projekti).

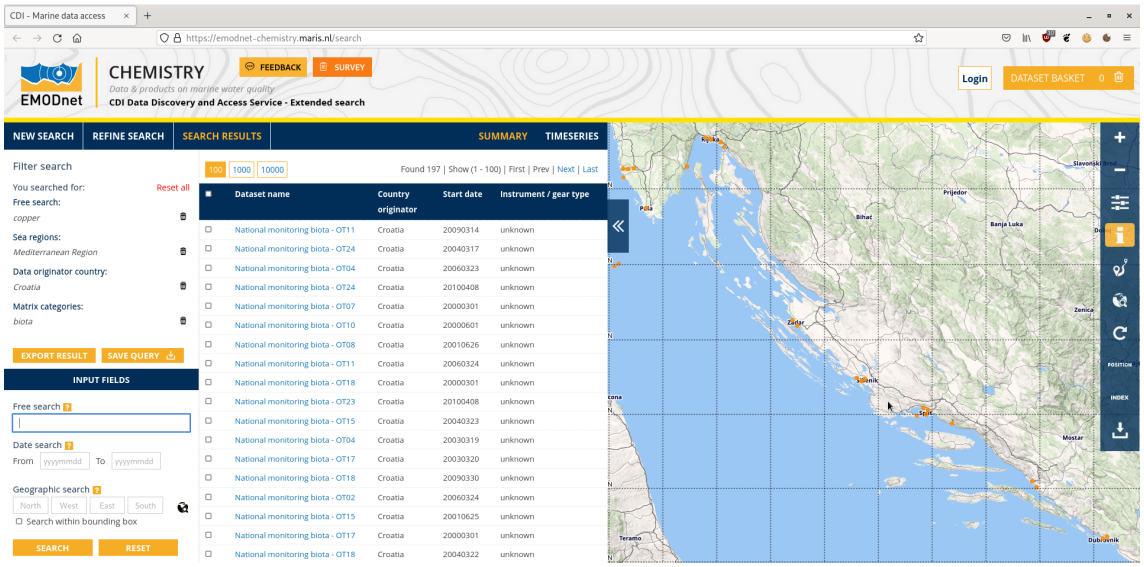

Slika 4.1: Emodnet chemistry pretraga metapodataka [49]

Osim institucija za rukovanje podatcima, ponajprije prikupljanjem, obradom i prezentacijom oceanografskih podataka bave se međunarodni projekti koji uključuju više institucija. Svi oni imaju mrežne stranice s raznim sučeljima za dohvat i prikaz podataka. Na slici 4.1 sučelje je za dohvat podataka Emodnet chemistry projekta [49]. Vidljiv je "klasičan" pristup odabiru uvjeta, dok se za prostornu vizualizaciju koristi vlastiti wms servis. Sve mjerne postaje su jednako označene, bez obzira na broj dostupnih podataka.

Copernicus [50] je također EU projekt koji pruža podatke i servise s područja oceanografije. Projekt se koristi podatcima dobivenim europskim satelitima "Sentiel" koji neprekidno snimaju površinu mora radarskom tehnikom. Projekt se također koristi i mrežom „in situ“ mjernih postaja za provjeru i kalibraciju podataka prikupljenih satelitima. Na slici 4.2 vidi se vizualizacija površinske temperature mora dobivene satelitom. Kod ovoga se projekta nešto više pažnje poklanjalo dizajnu stranice. Za prikaz prostornih podataka koristi se Geoserver i OpenLayers uz relativno malo područje koje zauzima sama karta.

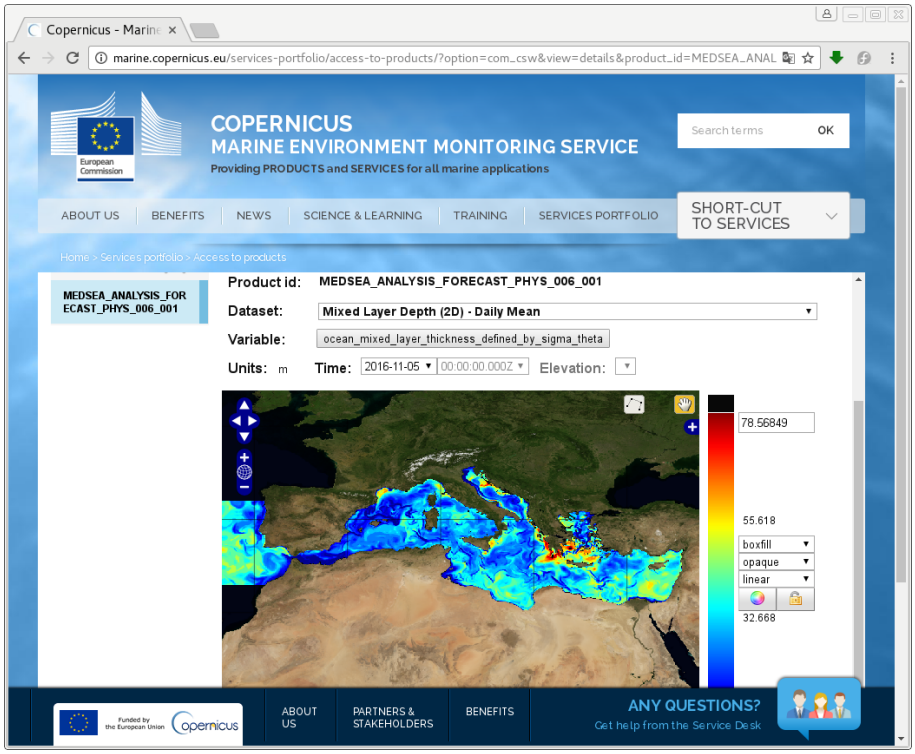

Slika 4.2: Prostorni prikaz temperature mora projekta Copernicus [50]

4.4. Povijesni razvoj programske podrške

Razvoj programske podrške bio je uvjetovan dostupnom tehnologijom. Programi su se razvijali na dostupnim platformama sa sučeljima u skladu s mogućnostima same platforme.

4.4.1. Aplikacije bez grafičkog sučelja

Nabavom prvih računala u Institutu se počelo s razvojem programske podrške. U to vrijeme (1980-e) računala su koristila isključivo alfanumerička sučelja. Programi su pisani u programskim jezicima C i Fortran. Grafički izlaz na ekranu nije bio dostupan, a neki grafički izlazi su kreirani uz pomoć plotera.

4.4.2. Aplikacije s grafičkim sučeljem

Uvođenjem relacijske baze Oracle i osobnih računala s Windows operacijskim sustavima, počeo je razvoj aplikacija koje su koristile grafičko sučelje (kraj 1990-ih). Na samom početku bila je riječ o "Oracle Forms" aplikaciji sa standardnim poljima za upis podataka. Već tada se pokazala potreba za prostornom vizualizacijom, što je tada riješeno razvojem posebne aplikacije pisane u jeziku C++ koja je crtala kartu i lokacije postaja. Sustav je opisan u radu [51]. Aplikacija za kartu je putem windows poruka dvosmjerno komunicirala s Oracle Forms aplikacijom, tako da je osim za prikaz, služila i za osnovno postavljanje prostornih kriterija za upis. Na slici 4.3 vidljive su sve komponente aplikacije: forma za upis podataka, prozor za prikaz prostorne komponente i prozor za vizualizaciju podataka.

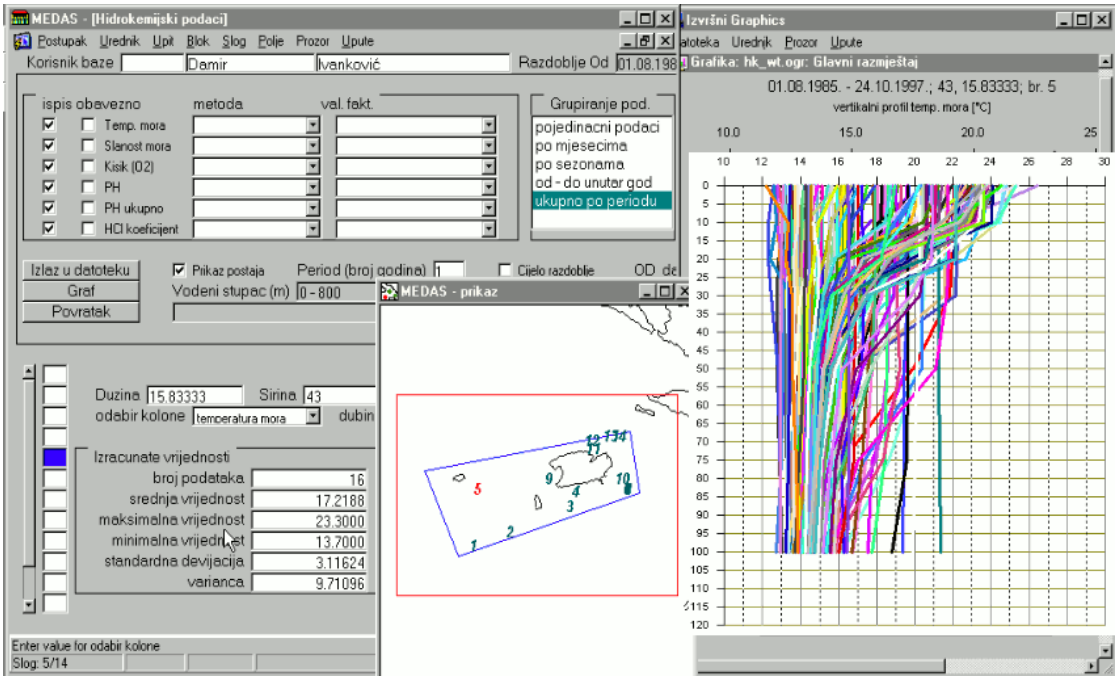

Slika 4.3: Oracle forms aplikacija s C++ dodatcima za vizualizacije podataka

4.4.3. Mrežne aplikacije prve generacije

Nakon Oracle Formsa razvoj je krenuo prema mrežnim aplikacijama (relativno rano 2002. godine). Prve verzije mrežnih aplikacija su za prostorne prikaze koristili java applet dodatak

preglednicima, u osnovi isti kod iz C++ aplikacije, prebačen u programski jezik Java [52]. Izgled takve mrežne aplikacije s Java dodatkom je vidljiv na slici 4.4.

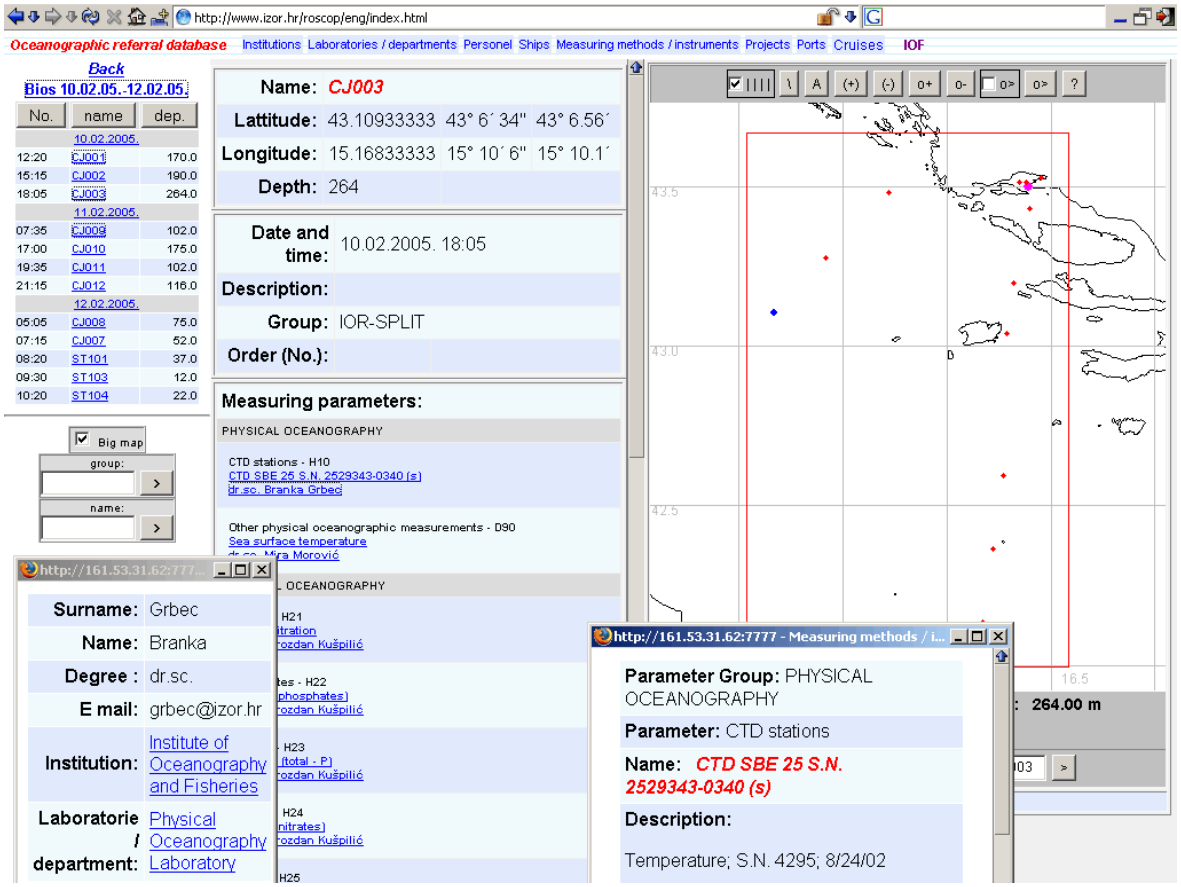

Slika 4.4: Mrežna aplikacija s Java Appletom za prikaz karte

Prikazi podataka su se tada radili s pomoću html tablica, a za svaku promjenu ili upis podataka pozivale bi se html forme posebno razvijene za svaki tip podatka i parametar. Ovaj način upisa podatka korisnici nisu najbolje prihvatili, te se i dalje većina podataka unosila preko tabličnih kalkulatora i naknadno u bazu podataka uz potrebno značajno vrijeme da se nestrukturirani podatci pravilno strukturiraju i da se isprave sve eventualne greške i nedostatci.

4.4.4. Mrežne aplikacije druge generacije

Pojavom novih projekata (Baza pokazatelja i kakvoća mora za kupanje) intenzivirao se rad na mrežnim aplikacijama. Uvedena su značajna poboljšanja: prikaz prostornih podataka putem Google maps API-a (slika 4.5), dinamički SQL za općenito rukovanje raznim tablicama i interaktivni grafički prikazi "upareni" sa pomenutim prostornim prikazima [53] [54].

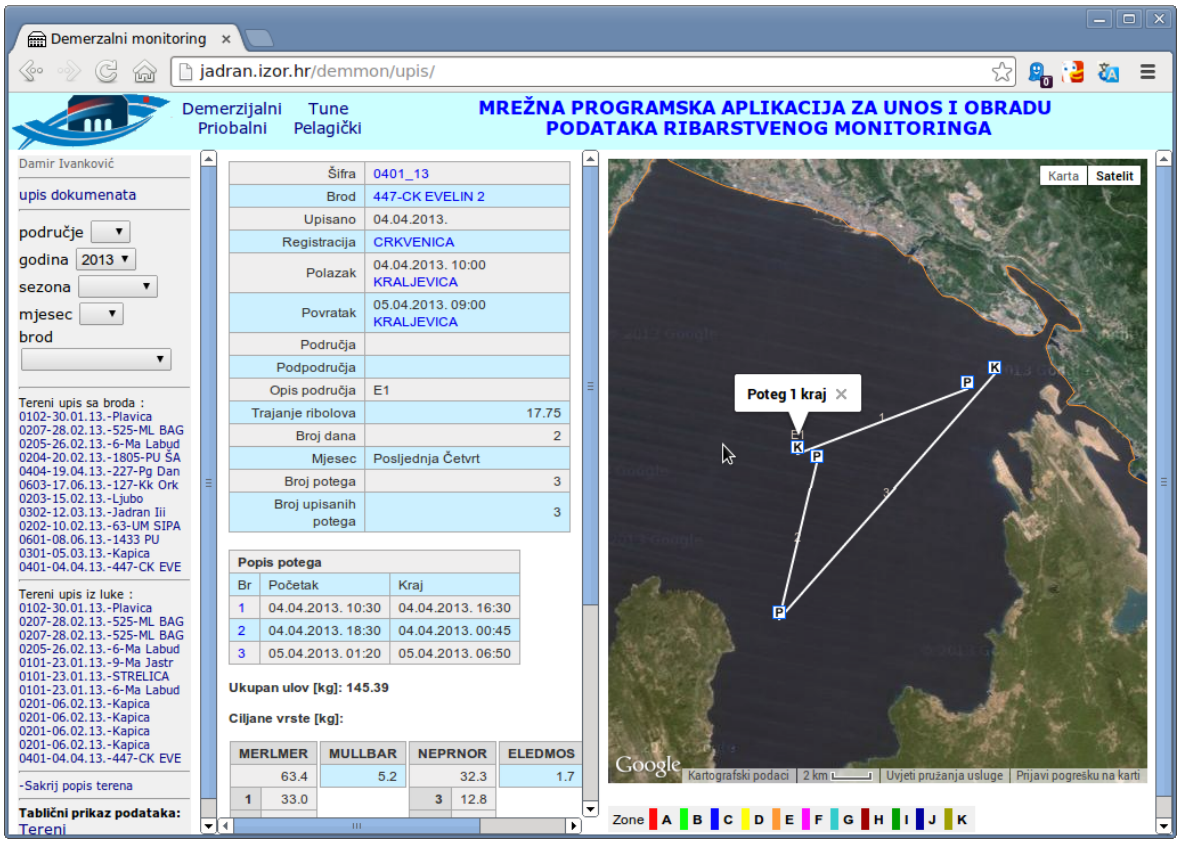

Slika 4.5: Mrežna aplikacija s prostornim prikazom s pomoću Google maps API-a

4.4.5. Treća generacija

U sklopu implementacije treće generacije aplikacija Java applet je zamijenjen JavaSriptom uz korištenje asinkronih poziva AJAX-a i JSON-a. S navigacija organiziranih kroz okvire (engl. *Frames*) prešlo se na jedinstvene stranice bez okvira s dinamičkim izbornicima pogonjenim JavaSriptom (primjer na slici 4.6). Korištenjem posebnih JavaScript dodataka (HighCharts, jQuery, Backgrid, PapaParse) uspjelo se korisničko iskustvo upisa podatka približiti načinu upisa u tablične kalkulatore (tablica na ekranu gdje se jednostavno klikne u neku ćeliju i uređuje se po potrebi) uz dodatni interaktivni prostorni prikaz. Idući veliki izazov odnosi se na intenzivniji razvoj prilagodljivih (responsivnih) aplikacija, gdje će fokus biti ponajprije na prikazu, dok za neki intenzivniji upis podataka mali ekrani i ekrani osjetljivi na dodir jednostavno nisu (za sada) dovoljno učinkoviti kod takvih primjena. Za kartografske prikaze i neke specifične namjene (osnovni slojevi, složeni prikazi) počinje se s korištenjem GeoServera [55].

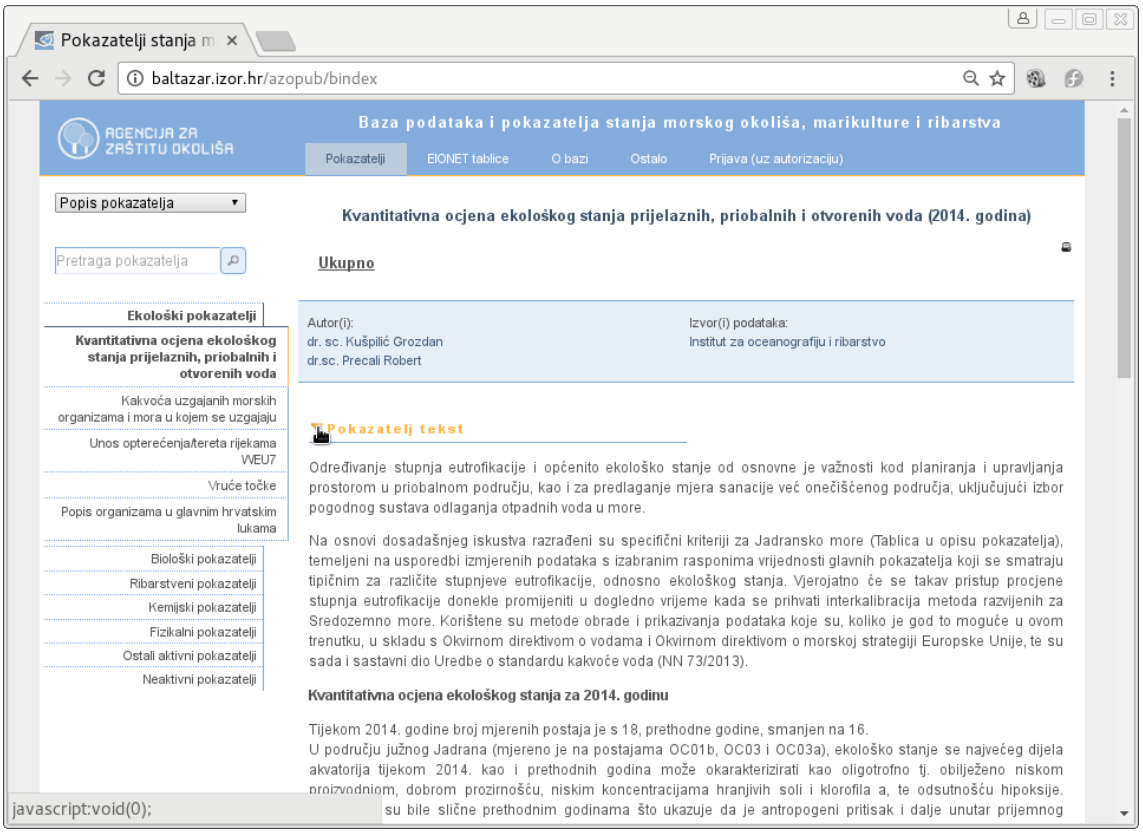

Slika 4.6: Mrežna aplikacija s dinamičkim izbornicima

4.5. Zaključak

Interne aplikacije za rukovanje podatcima uglavnom su orijentirane k nužnoj funkcionalnosti i po dizajnu i tehnologijama prilično "konzervativne". Njima se koristi manji broj ljudi u podatkovnim centrima. Dizajnu se u pravilu ne posvećuje veća pozornost. Programi opće namjene zahtijevaju složenije procese obrade podataka uz često veću mogućnost grešaka. Posebno razvijene aplikacije ubrzavaju proces provjere i obrade podataka te se njihovom primjenom dolazi do kvalitetnijih rezultata. Kako je često slučaj da na istom setu podataka radi istovremeno više ljudi, a neke prikaze je potrebno i javno objaviti, mrežne aplikacije se nameću kao optimalno rješenje.

5. OBOSTRANO POVEZANI GRAFIČKI I KARTOGRAFSKI PRIKAZI

Ovo poglavlje je prevedena i proširena verzija rada [56] objavljenog u posebnom broju znanstvenog časopisa "Applied Sciences" pod nazivom "Intelligent Systems Applied to Maritime Environment Monitoring".

Vizualizacija podataka o okolišu važna je za procjenu procesa koji se odvijaju u okolišu [57]. Vizualizacija prikupljenih podataka uključuje iscrtavanje grafikona ili crtanje karata s vrijednostima varijabli prikupljenih sustavom praćenja ili predviđenih softverom za modeliranje. Postoje mnogi alati kojima se koriste znanstvenici za okoliš, a razvijeni su u svrhu vizualizacije podataka. Međutim, svima njima nedostaje intuitivno sučelje za procjenu stanja, trendova i outliera u predstavljenom skupu podataka. U ovom poglavlju predstavljamo novi alat s intuitivnim mrežnim sučeljem sposobnim za temeljito ispitivanje podataka o okolišu u prostornoj i vremenskoj dimenziji. Dizajnirali smo alat za operativnu vizualizaciju imajući u vidu sve slojeve mrežne aplikacije: formate za pohranu i razmjenu podataka, optimizirane komunikacijske obrasce klijent poslužitelj i dizajnirano mrežno korisničko sučelje. Glavni ciljevi koje želimo postići su:

- intuitivno procijeniti stanje okoliša na temelju vrijednosti prikazanih varijabli,
- intuitivno procijeniti trendove stanja okoliša na temelju procesa koji se odvijaju u okolišu,
- intuitivno prepoznati pogrešku ili outlier u prikazanim podatcima mjerenja.

5.1. Motivacija

Znanost o okolišu s oceanografijom važna je za razumijevanje okoliša i rješavanje klimatskih promjena. Mjerenja, uključujući terenski rad i krstarenja, vrlo su skupa, što sa sobom nosi i veliku odgovornost upravljanja podatcima kako bi ta mjerenja omogućila nova znanja i razumijevanja prirodnih procesa. U više od 20 godina, koliko se autor bavi oceanografskim podatcima, svjedočili smo da je upravljanje podatcima vrlo često neadekvatno, ostavljajući podatke neprovjerenim ili nepotpunim. Velik dio krivnje u takvim slučajevima leži na neprikladnim alatima za organiziranje, pohranu, pregled i analizu podataka.

Riječ je o prostorno-vremenskim podatcima, odnosno diskretnim mjerenjima u pojedinim točkama prostora u određenom vremenu. Prostor i vrijeme su neodvojivi i ključni za kvalitetnu interpretaciju podataka.

Danas ne treba govoriti o prednostima mrežnih aplikacija u odnosu na klasične izvanmrežne. Okolišni podatci su često distribuirani na više različitih lokacija i zahtijevaju suradnju pri obradi i interpretaciji. Dotok podataka je stalan i može se distribuirati među mnogim izvorima. Sve ovo ide u prilog korištenju mrežnih aplikacija na ovom području. Mnogi podatci se dijele s više od jednog korisnika, a analiza podataka zahtijeva suradnju stručnjaka. Gotovo je nemoguće lokalno sinkronizirati sve podatke za korištenje namjenske klijentske desktop aplikacije ili takva sinkronizacija može potrajati značajno vrijeme uz veći uloženi trud.

Podatci o okolišu imaju prostornu i vremensku komponentu i povezujući ih nastojimo pružiti nove i poboljšane metode i alate u mrežnom okruženju za učinkovito i kvalitetno upravljanje podatcima okolišnih mjerenja raspršenih u 3D prostoru i vremenu. Pri tome je bitno da korisnici intuitivno i jednostavno mogu razumjeti grafičke i kartografske prikaze, kao i njihovu povezanost.

5.2. Ciljevi istraživanja

Utvrdimo ciljeve našeg istraživanja.

- Rješenje mora osigurati jednostavno i intuitivno korisničko sučelje. Korisnici trebaju koristiti aplikacijom bez posebne pomoći ili napora u učenju.
- Rješenje mora omogućiti brz i lak uvid u prostorno-vremenske podatke kako bi korisnici mogli izvući znanje iz prikazanih skupova podataka (stanje okoliša, trendovi, posebni događaji). Istodobno, korisnik može jednostavno provjeriti kvalitetu skupa podataka identificiranjem i označavanjem loših vrijednosti.
- Rješenje se treba implementirati kao mrežna aplikacija i biti upotrebljivo na stvarnim podatcima.

Za postizanje ovih ciljeva potrebno je analizirati proces upravljanja podatcima i vizualizaciju prostorno-vremenskih podataka okoliša [46]. Uključeni su alati i procesi kojima se koriste stručnjaci za okoliš u svom poslu upravljanja podatcima. Potrebno je uzeti u obzir njihove napore i probleme. Na kraju možemo predložiti metodologiju i njihovu implementaciju kako bismo pružili rješenje.

5.3. Postojeća rješenja

Tradicionalno, prostorno-vremenski (okolišni) podatci se obrađuju, provjeravaju i pohranjuju u datotečni sustav s pomoću specijaliziranih programskih paketa. Katkad se za pohranu podataka koristi samo datotečni sustav i različiti formati datoteka, od tekstualnih, formata tabličnih kalkulatora do naprednijih višedimenzionalnih formata kao što je NetCDF. Sve veća rasprostranjenost relacijskih baza podataka dovela je do njihove upotrebe i za upravljanje podatcima o okolišu. Prilagođeni klijentski programi koriste se za pristup bazi podataka i vizualizaciju i provjeru podataka. Korisnik stvara podatkovni proizvod iz podskupa podataka generirajući neke slike s kartama i grafikonima. Podatkovni proizvod je provjereni i vizualizirani skup podataka prilagođen specifičnoj namjeni. Rezultat je "jednodimenzionalni" prikaz korištenog skupa podataka. Na kraju se rezultat može objaviti kao mrežna stranica ili tekstualni dokument.

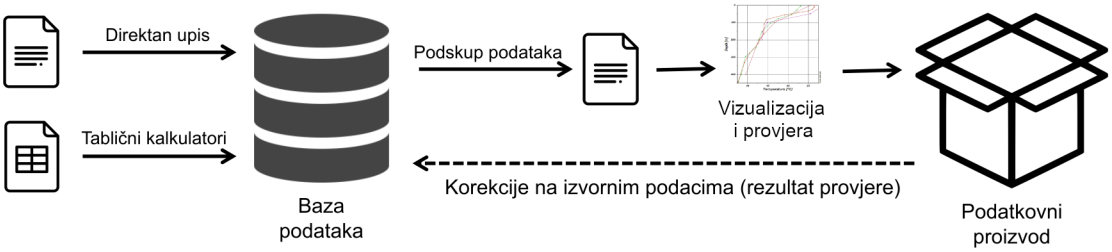

Slika 5.1: Tradicionalni tijek podataka pri kreiranju podatkovnog proizvoda

5.3.1. Programska rješenja opće namjene

U upravljanju podatcima o okolišu tradicionalno se koriste programski alati opće namjene. Na primjer, proračunske tablice (uglavnom MS Excel) koriste se za vizualizaciju podataka, a u nekim slučajevima i za pohranu. Za statističku analizu i napredne vizualizacije koriste se različiti statistički alati (kao što su Statistica ili R statistika). Programski alati opće namjene za za procesiranje prostornih podataka (poput QGIS [58] ili ESRI ArcView) koriste se za crtanje karata postaja. Spomenuti programi imaju široku primjenu u upravljanju podatcima, ali imaju određene nedostatke.

- Priprema podskupa podataka oduzima mnogo vremena. Iz tabličnoga kalkulatora nije trivijalno izvući podatke prema nekom kriteriju, npr. podatke za pojedinu postaju.
- Vraćanje rezultata analize u glavni skup podataka je dugotrajno ili ga nema. Nakon provjere podataka za pojedinu postaju potrebno je pronaći sve eventualno izmijenjene ili označene podatke.

- Vizualizacija samo podataka (graf) ili samo karte (postaje). Obično se posebno kreiraju i graf i karta i na kraju se zajedno ubacuju u program za obradu teksta.
- Slaba učinkovitost cijelog procesa. Opisane radnje su repetitivne i zahtjevne pa zahtijevaju i znatan napor i utrošeno vrijeme.

5.3.2. Ocean data view

Ocean data view (ODV) [59] jedan je od najboljih programskih alata za vizualizaciju oceanografskih podataka. Omogućuje različite grafičke vizualizacije, kreiranje mapa postaja i prostorne interpolacije. Sučelje prikazano na slici 5.2 temelji se na kontekstnim izbornicima, a zbog mnogih implementiranih opcija zahtijeva određene napore u učenju od novih korisnika.

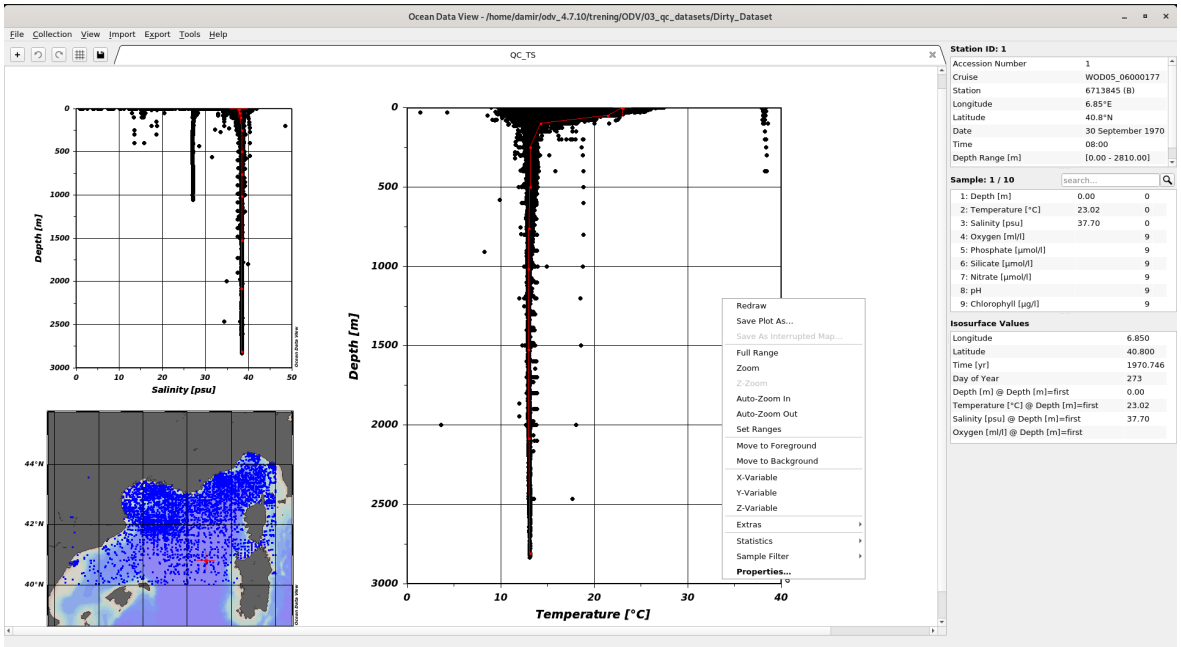

Slika 5.2: Izgled klasične ODV aplikacije

Unatoč vrlo dobrim i naprednim mogućnostima vizualizacije, ODV je samo alat za vizualizaciju podskupa podataka. Glavni nedostatci su:

- pohrana podataka temelji se na datotekama, što uvjetuje ograničene mogućnosti filtriranja
- program je desktop alat bez mogućnosti istovremenog rada više korisnika na istom setu podataka (suradnja)
- promjene i provjere učinjene u ODV-u mogu se izvesti u datoteku, a ne pohraniti u bazu podataka
- nepovezane i odvojene vizualizacije statusa i trenda.

Nedavno je Ocean data view dobio i mrežnu verziju [60]. Mrežno sučelje se implementira korištenjem mrežne utičnice (QtWebSockets) za pokretanje mrežnih aplikacija ili kombiniranog WebSocketa i HTML5 platna. Ove vrste rješenja grafičke su verzije terminalskog pristupa poslužitelju. Svaki klijent ima svoj izolirani proces na strani poslužitelja i izvodi razne operacije putem WebSocketa. Glavni nedostatak ovog pristupa je zahtjev određene procesorske snage na strani poslužitelja za svakog klijenta, a predmemorija preglednika (engl. *cache*) se slabo koristi. Mrežom se neprestano prenosi sučelje kreirano na poslužitelju. Sučelje je izgledom isto kao u desktop verziji. Mrežnom aplikacijom WebODV moguće je vizualizirati samo unaprijed pripremljene skupove podataka dostupne na mreži. Nije moguće raditi promjene na podatcima.

5.3.3. WISE Marine

Europska agencija za okoliš ima vlastite usluge za vizualizaciju i prezentaciju podataka. Jedna od tih usluga je Vodni informacijski sustav za Europu (WISE) Marine [61]. Namjera ovih mrežnih stranica je predstaviti stanje okoliša. Uz podatke dano je i objašnjenje: "Procjene morskog okoliša obično se temelje na pokazateljima koji se izvlače iz podataka praćenja na strukturiran način za svaku temu procjene. Pokazatelji mogu pokriti sve aspekte DPSIR okvira [62], ali su općenito više usredotočeni na pritiske, stanje i utjecaje. Procjene pokazatelja daju detaljne informacije uključujući korištene matrice, metrike i metode, kao i rezultate. U ovom odjeljku dat je popis pokazatelja koji se koriste u kontekstu rada regionalnih morskih konvencija ili ih je objavila Europska agencija za okoliš s paneuropskim pokrivanjem."

U mnogim vizualizacijama kao na slici 5.3 [63] prikazani su status i trendovi. Karta je prikazana kao statična slika koja prikazuje samo trend bez određenih vrijednosti. Grafikon prikazuje samo postotke trendova unutar područja. Karta i grafikon nisu povezani i karta nije interaktivna. Osim statičkih elemenata, vizualizacije podataka često ne pružaju osnovne informacije o skupu podataka: koji su rasponi vrijednosti, gdje su vruće točke i koji su trendovi za određene lokacije i vruće točke. Trend se često izračunava kao statistički značajno povećanje ili smanjenje vrijednosti tijekom vremena bez uzimanja u obzir same vrijednosti. Ovakvim pristupom lokacija s izmjerenom vrijednošću za neki parametar može imati jednogodišnji prosjek od 100, idući godišnji prosjek od 80, što je statistički značajno smanjenje. Druga lokacija za isti parametar može imati jednogodišnju vrijednost od 5 i iduću 6 za isti parametar. U vizualizaciji podataka prva lokacija ima bolji status od druge (smanjenje u odnosu na povećanje) bez obzira na to što je status po ovom parametru puno bolji na drugoj lokaciji nego na prvoj.

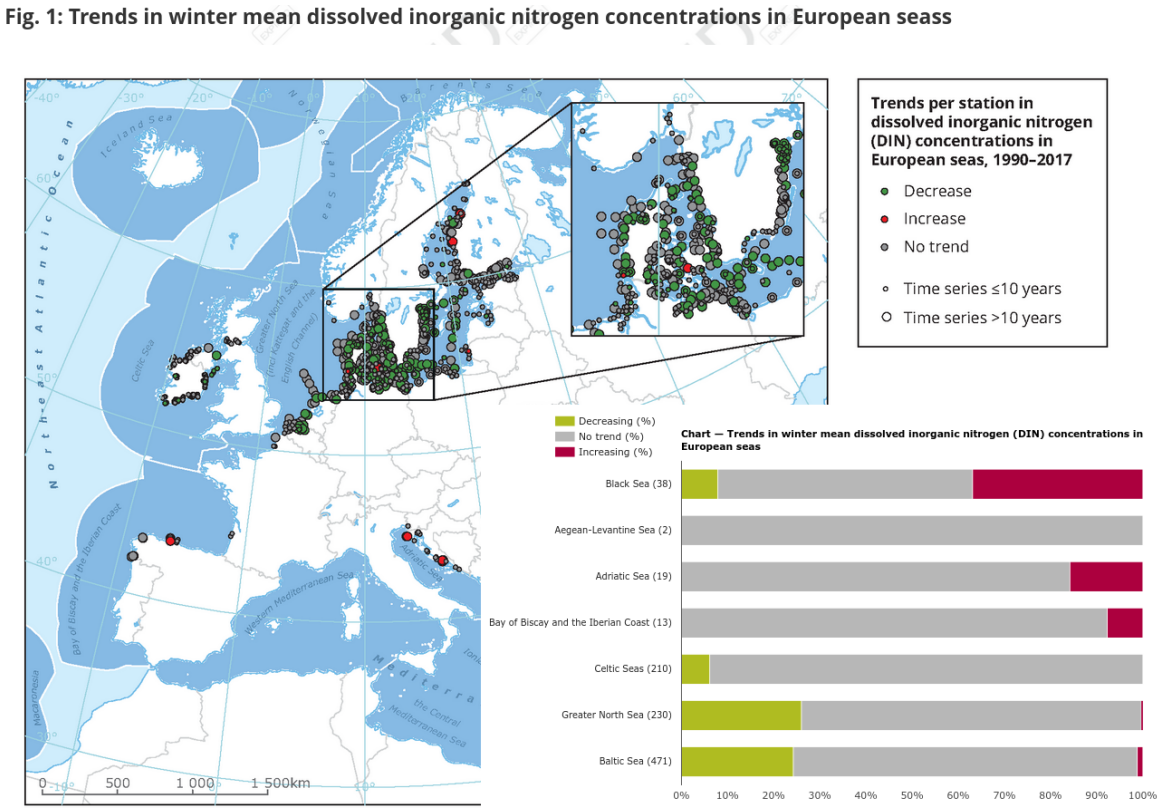

Slika 5.3: Primjer vizualizacije podataka s WISE Marine mrežne stranice [63]

5.3.4. Usporedba svojstava postojećih rješenja

Opisani programski alat i vizualizacije podataka koriste se u stvarnom svijetu za upravljanje oceanografskim podatcima i rezultatima njihove obrade. Postoje mnoge mrežne stranice koje sadrže oceanografske podatke. Mrežni servis WISE Marine odabran je jer je namijenjen praćenju statusa i trenda određenih oceanografskih parametara te zbog toga što ovo mrežno sjedište ima formalnu i relevantnu pozadinu (Europska agencija za okoliš). Tablica 5.1 prikazuje sažetak glavnih svojstava navedenih rješenja.

Kao što se može vidjeti u tablici 5.1, veliki problem s navedenim rješenjima je taj što se podatci ne mogu lako dodavati i mijenjati. S obzirom na to da se 20 % - 30 % oceanografskih podataka gubi u cijelom svijetu, to je još veći problem. Izvlačenje znanja iz podataka još je jedno važno pitanje. Identificiranje statusa, trendova i vrućih točaka važno je stručnjacima i postaje sve važnije široj javnosti. U ovom radu je ostvareno znatno unaprijeđenje upotrebom prostorno-vremenske vizualizacije ostvarene mrežnim rješenjem oslonjenim na relacijsku bazu podataka koji omogućuju jednostavan unos, ažuriranje i upravljanje podatcima.

Tablica 5.1: Svojstva postojećih rješenja.

Ime	Upis i ispravak podataka	Vizualizacija podataka	Prikaz grafa i karte	Mrežno sučelje
Rješenja opće namjene	Da, ali nestrukturirani zapis u datoteke	Djelomično i pojedinačno	Jedno ili drugo, nepovezano	Ne
Ocean data view	Ne, samo učitavanje podataka iz datoteka	Da, uz napredne mogućnosti	Da	Ne (Mrežna verzija je ograničena na unaprijed pripremljene setove podataka)
WISE Marine	Ne, samo vizualizacija	Da	Da, ali nisu interaktivni	Da

5.4. Materijali i metode primjenjeni za realizaciju novog rješenja

Kako bismo optimizirali tijek rada, uveden je dvosmjerni protok podataka s mrežnim preglednikom kao središnjim alatom za upite i podnošenje promjena podataka o okolišu. Shematski prikaz dvosmjernog tijeka prikazan je na slici 5.4

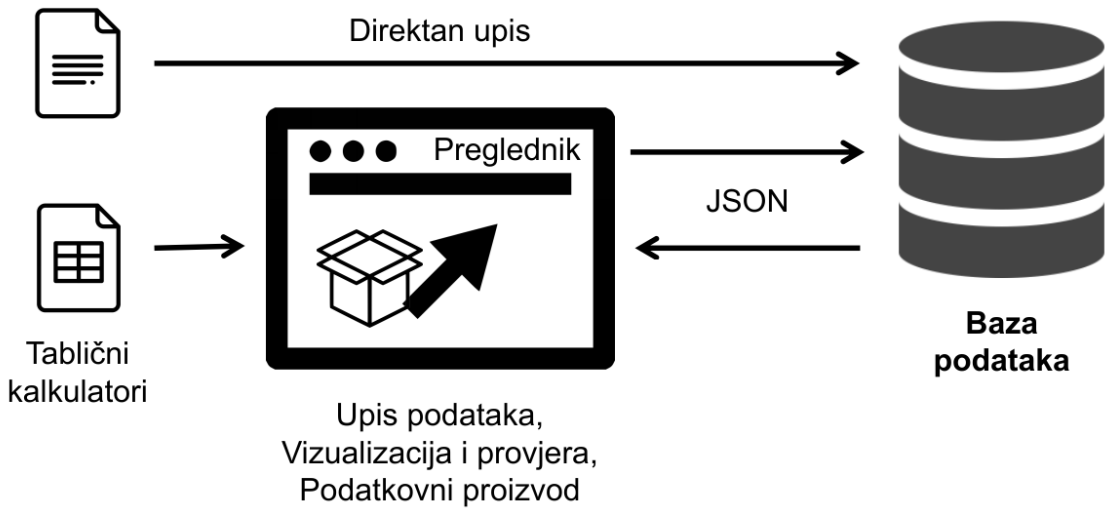

Slika 5.4: Unaprijeđen tijek podataka uz koritenje mrežnog preglednika

Korištenjem aplikacijskog poslužitelja i vizualizacije podataka u mrežnom pregledniku, cijeli se proces pomiče sa specijaliziranog i prilagođenog programskog alata za stolna ra-

čunala na dinamičke mrežne stranice. Vizualizacija podataka još se uvijek radi na strani klijenta, ali jedini programski alat koji se koristi je mrežni preglednik. Podatci se mogu prikupljati iz različitih izvora, a provjera i ispravci podataka jednostavno se vraćaju u bazu podataka.

5.4.1. Svojstva podataka

Podatci o okolišu općenito su rasuti u prostoru i vremenu. Mjerne postaje su teoretski mjesta mjerenja koja se redovito obavljaju u okviru nekog programa praćenja. Mogu postojati i neke lokacije sa samo jednokratnim mjerenjima i te se lokacije ne mogu koristiti za stjecanje trenda. Za prostornu interpolaciju pojedinog parametra mogu se koristiti podatci s više grupa postaja izmjerenih u približno istom vremenu ili prosjeci u nekom razdoblju. Skup mjerenja okoliša za određeni parametar trebao bi pružiti neke osnovne informacije.

- Gdje su žarišta ili lokacije s povećanim vrijednostima za pojedini mjereni parametar?
- Kakav je trend za svaku lokaciju, posebno za žarišta s povećanim vrijednostima?
- Jesu li vrijednosti i koje su iznad nekih pragova ili maksimalnih vrijednosti?
- Koja je kategorija svake vrijednosti ako su kategorije definirane za ovaj parametar (i područje)?

Lakši i najintuitivniji način za dobivanje odgovora na ova pitanja je putem dobre vizualizacije podataka. Priroda samih podataka uvjetuje tip grafova [4], a mi smo koristili linijske, stupce i složene kategorije grafova. Jednostavna statistička obrada nije dovoljno dobra jer je maksimum samo jedan, a u nekim slučajevima je lošije imati visoku vrijednost u blizini važnih objekata nego maksimalnu vrijednost u manje značajnom području. Za pravilno vrednovanje vrijednosti treba staviti u korelaciju s lokacijom. Osim samog izmjerenog podatka, postoji minimalni skup metapodataka koji bi trebali biti prikazani: parametar s mjernom jedinicom (što), vrijeme mjerenja uključujući vremensku zonu ili preračunato na lokalno vrijeme (kada), koordinate lokacije uključujući koordinatni sustav (gdje). U nekim slučajevima je važna osoba ili institucija koja je mjerila parametar (tko) i informacije u vezi s metodom mjerenja kao što su granice detekcije i granice kvantifikacije. Ovo je osnovni set metapodataka poznat i kao wwww od engleskog *what*, *when*, *where* i *who*.

5.4.2. Zahtjevi pri vizualizaciji podataka

Iz svega navedenog proizlaze pretpostavke za dobru vizualizaciju podataka o stanju okoliša:

1. korisnik treba odabrati neki podskup podataka za analizu i/ili provjeru valjanosti,
2. graf i karta trebaju biti istovremeno prisutni,

3. elementi grafa i oznake mjesta trebaju biti povezani
4. veze trebaju biti dvosmjerna: od vrijednosti do lokacije i od lokacije do vrijednosti,
5. trend treba biti lako dohvaćen i prikazan za svaku lokaciju (postaju).

5.4.3. Dizajn i optimizacije relacijske baze

Za optimalno korisničko iskustvo mrežna aplikacija treba biti brza u odgovorima na radnje i zahtjeve korisnika. Važnu ulogu u vremenu odziva ima dizajn relacijske baze podataka koji je razvijen tijekom razvoja aplikacije. Tijekom razvoja se došlo do nekih osnovnih zahtjeva koje dizajn mora zadovoljiti:

- potrebno je razdvojiti pohranu metapodataka i samih podataka,
- parametre je nužno implementirati dinamički, odnosno parametar je samo redak u tablici, nikako kolona koja zahtijeva složenu implementaciju i promjene koda,
- prostorni objekti moraju biti implementirani potpuno, s punom informacijom o korištenom koordinatnom sustavu,
- dizajn treba omogućiti učinkovite prostorne i vremenske upite, odnosno dohvat podskupa podataka,
- podatke treba moći jednostavno identificirati prema vlasništvu, odnosno dodatnim metapodatcima (institucija, projekt) prema kojima se implementiraju ograničavajući filtri,
- kod dizajna potrebno je uzeti u obzir i particioniranje najvećih tablica, kako upis većeg seta podataka ne bi s vremenom dovodio do usporavanja dohvata,
- međusobne relacije unutar baze moraju osigurati kozistentnost podataka.

Glavne tablice i njihove međusobne relacije vidljive su na slici 5.5. Metapodatci su pohranjeni u tablici META_DATA koja je povezana s lokacijama *LOCATIONS*, krstarenjima *CRUISE* i projektima *PROJ_PAR_META*. Sami podatci su u tablici MES_NUMBERS koja je povezana s parametrima.

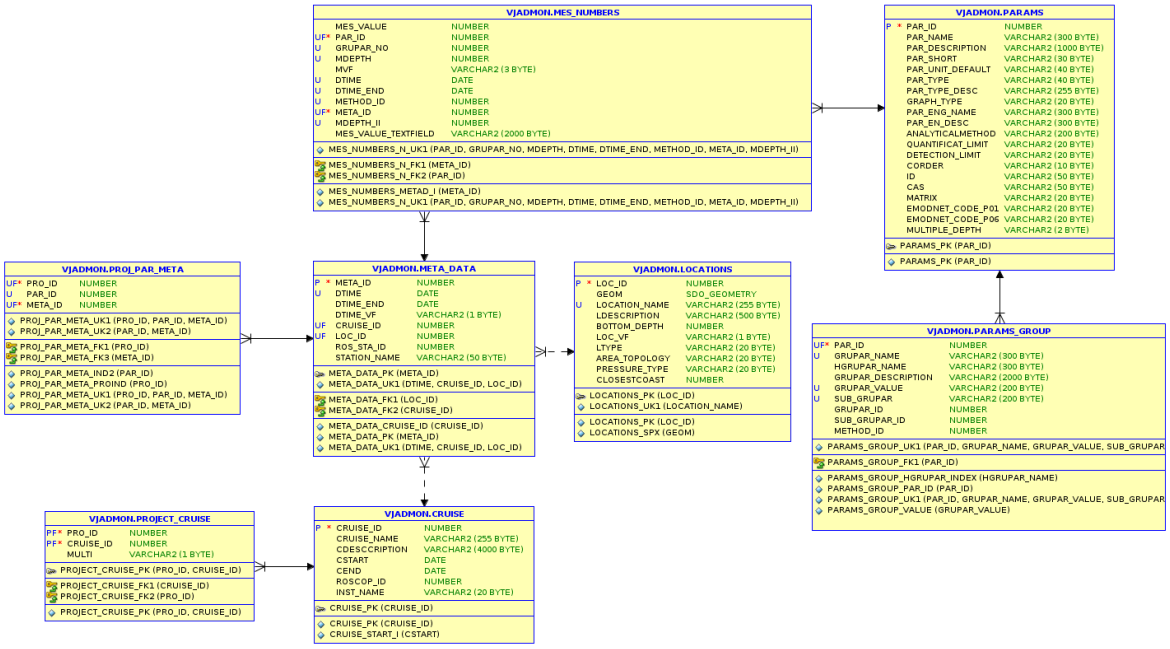

Slika 5.5: Tablice i njihove relacije

Osim optimizacije brzine dohvata, dizajn baze podataka treba omogućiti i upravljanje pravima pristupa raznih korisnika. Tijekom prakse najbolje su se pokazale restrikcije prema meta podatcima (vrijeme, mjesto, pripadnost projektu). Restrikcije pristupa se superponiraju na standardne korisničke filtre i nužno ih je implementirati samo unutar procedura koje dohvaćaju podatke u JSON obliku.

Postoji nekoliko načina poboljšanja odgovora iz baze podataka i općenito za mrežnu aplikaciju.

- Opća upotreba indeksa i optimizacija upita. Indeksiranjem kolona koje sadrže glavne kriterije upita, odnosno kvalitetnim dizajnom relacijske baze mogu se značajno unaprijediti performanse dohvata podataka.
- Korištenje automatske ili ručne (ovisno o značajkama baze podataka) particije tablice za velike skupove podataka.
- Korištenje JavaScripta za obrade podataka na strani klijenta (npr. za izračun osnovnih statističkih informacija o vizualiziranim skupovima podataka). Time se ostvaruje potreba prijenosa manje količine podataka i manje opterećuje bazni poslužitelj.
- Asinkrono učitavanje podataka (u pozadini uz pravilno rukovanje događajima).

5.4.4. Položaj elemenata sučelja

Proces analize i potvrđivanja počinje odabirom podskupa podataka za analizu. Nakon toga podatke treba dohvatiti iz pohrane i vizualizirati ih u grafičkom obliku i na kraju, nakon što

se svi podatci prikupe, zajedno ih s lokacijama mjerenja treba staviti u prostor na nekoj karti. Uzimajući u obzir redoslijed radnji i saznanja kako ljudi gledaju i kako se koriste mrežnim stranicama, predlaže se [64] organizacija sučelja mrežne aplikacije. Položaj elemenata prikazan je na slici 5.6.

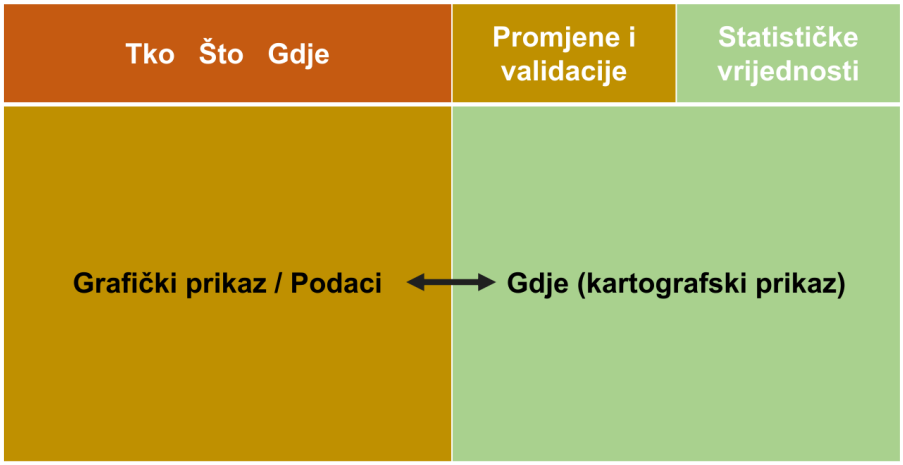

Slika 5.6: Shematski prikaz položaja elemenata sučelja

Nakon definiranja elemenata i njihova položaja na stranici, kreirana je prva implementacija mrežne aplikacije. Na slici 5.7 prikazana je prva verzija. Tijekom ispitivanja aplikacije postalo je jasno da prostor na korisničkom sučelju treba bolje iskoristiti. Također, sučelje nije bilo pravilno usklađeno i izgledalo je pomalo neuredno. Kako bismo poboljšali korisničko sučelje, odlučili smo se koristiti proširenim principima dizajna: "Veličina, boja, kontrast, poravnanje, ponavljanje, blizina, razmak, tekstura i stil" [65]. Primjenjujući ova načela razvijena su bolja sučelja s učinkovitijim korištenjem prostora i boljim dizajnom. Ovi elementi su obrađeni u sljedećim odjeljcima.

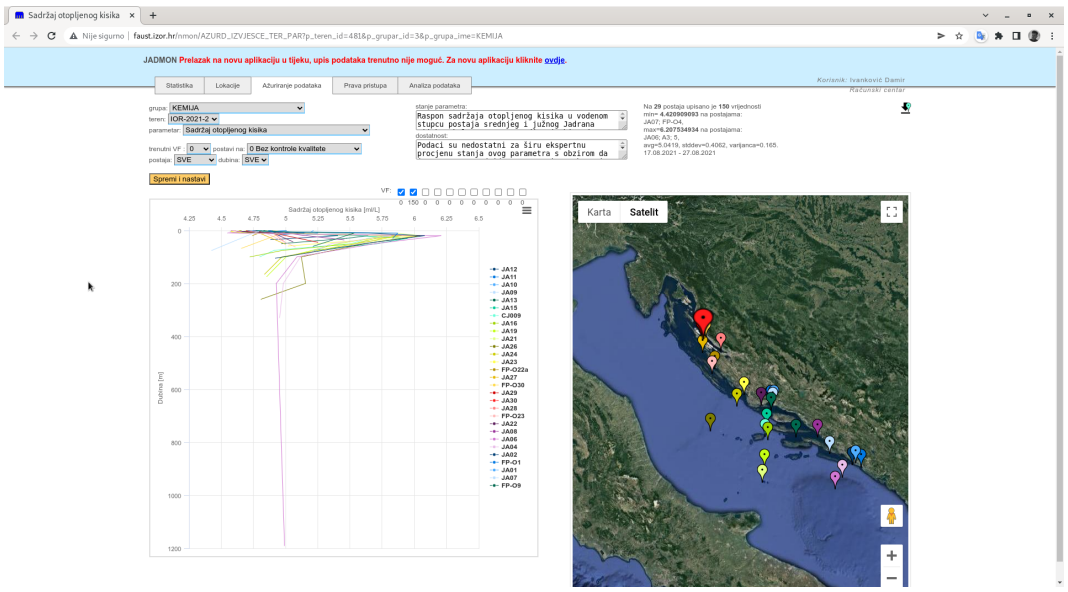

Slika 5.7: Izgled prve verzije korisničkog sučelja

Vizualno uparivanje bojom

Povezivanje elementa grafa i lokacije može se postići podudaranjem boje elementa grafa i markera lokacije. Za prikaz na mrežnim stranicama i ljudsku percepciju broj boja koje se mogu koristiti je ograničen. Broj mjerenja i lokacija može biti veći od broja korištenih boja (neke se boje moraju ponovno koristiti). U tom slučaju treba koristiti formulu za povezivanje svake boje s određenim mjestom. Obično svaka lokacija ima jedinstveni brojčani identifikator (primarni ključ) u bazi podataka. Tim se brojem koristimo za izračunavanje položaja boje iz niza boja [66] formulom:

$$
\begin{gathered}
niz_boja = [\#F0A3FF, \#0075DC, \#993F00, \#4C005C, \#191919, \#005C31, \\
\#2BCE48, \#FFCC99, \#808080, \#94FFB5, \#8F7C00, \#9DCC00, \#C20088, \\
\#003380, \#FFA405, \#FFA8BB, \#426600, \#FF0010, \#5EF1F2, \#00998F, \\
\#E0FF66, \#740AFF, \#990000, \#FFFF80, \#FFFF00, \#FF5005] \\
boja = niz_boja[(i \ \mathbf{mod} \ n)]
\end{gathered}
$$

gdje je i jedinstvena numerička šifra lokacije (id), n je broj boja u nizu odabranih boja za prikaz i **mod** je operacija ostatka cjelobrojnog dijeljenja (modulo).

Povezivanje grafičkih elemenata

Najintuitivniji način za povezivanje dvaju elemenata na mrežnoj stranici je korištenje događaja *hover* na nekom elementu. Tada će događaj *hover* prikladno označiti trenutni element (gdje je pokazivač miša) i sve ostale povezane elemente i tu akciju možemo nazvati "Vizualna povratna informacija". Osim događaja *hover* također možemo koristiti događaj *onClick*. Ovaj događaj se koristi za prebacivanje sa statusa na prikaz trenda ili za označavanje vrijednosti u procesu provjere valjanosti.

Vizualne povratne informacije trebaju pružiti korisniku vizualne informacije o povezanosti između elemenata tako da bi ovaj element trebao biti nekako "označen" na mrežnoj stranici. Mogući načini označavanja elemenata su:

- promjena veličine elementa
- promjena boje elementa
- promjena pozicije elementa.

Promjena pozicije elementa nije prikladna ni za markere na karti (položaj na karti sadrži važne informacije) niti za elemente grafa (teško je pratiti i razumjeti graf).

Promjena veličine elementa dobar je način za isticanje markera postaje. Budući da je marker usklađen u boji, bolje je promijeniti veličinu nego promijeniti boju.

Za isticanje elementa grafa potrebni su različiti pristupi za različite vrste grafova:

- linijski grafikon može se istaknuti korištenjem deblje linije
- za graf stupaca bolje je promijeniti boju jer je veličina stupca povezana s vrijednošću koju stupac predstavlja
- za kategorizirani grafikon i veličina (vrijednost) i boja (kategorija) sadrže informacije, isticanje se može napraviti promjenom boje pozadine naslaganog (kategoriziranog) stupca.

Tijek rada s podatcima

Nakon što se podatci dohvate i dinamički vizualiziraju, korisnik s objašnjenim interakcijama dobiva uvid u podatke i dobiva "dodatnu vrijednost" skupa podataka.

Postupci u analizi skupa podataka obuhvaćaju:

1. odabir skupa podataka za analizu s pomoću filtara podataka,
2. dobivanje grafičkog prikaza podataka (grafa) i karte lokacija postaja,
3. provjera podataka pronalaženjem sumnjivih vrijednosti ili vrućih točaka,
4. stjecanje znanja o skupu podataka i/ili podnošenje provjera valjanosti i/ili pisanje komentara/stručnosti o skupu podataka.

Navedene metode, iako se čine samorazumljivim i jednostavnim, proizašle su iz proučavanja načina i učinkovitosti različitih korisnika (ekoloških stručnjaka) koji upravljaju podatcima i potvrđuju ih. One su balansirane između minimalnog potrebnog napora (broj operacija korisnika) i maksimalno stečenoga vizualnog uvida i prikupljenog znanja iz analiziranog skupa podataka.

5.4.5. Prilagodljiv filtar podataka

Učitavanje podskupa podataka za analizu odgovor je na specifične zahtjeve korisnika. Korisnik odabire podskup podataka s pomoću filtara podataka koji se nalaze na stranici. Adaptivni filtri podataka su filtri koji dohvaćaju vrijednosti za svaku kategoriju u pozadini prema svim već definiranim kategorijama (npr. ako korisnik odabere određenu godinu, sljedeće polje za odabir mjeseca popunit će se mjesecima za koje imamo podatke za određene parametre). Korištenjem adaptivnih filtara podataka izbjegavaju se situacije u kojima korisnik odabere neku vrijednost za filtre samo kako bi saznao da za zatraženu kombinaciju podataka uopće nema.

5.4.6. Provjera

Prvi test predložene metodologije je implementacija u mrežnom okruženju. Izazov je razviti relativno složenu mrežnu aplikaciju s glatkom izvedbom i prihvatljivim vremenom odgovora (ispod jedne sekunde). Razvijena aplikacija se zatim predstavlja stvarnim korisnicima na testiranje upotrebljivosti.

Međunarodni projekt HarmoNIA [67] (Harmonizacija i umrežavanje za procjenu zagađivača u Jonskom i Jadranskom moru) sa specifičnim ciljem "Pojačati kapacitete u transnacionalnom rješavanju problema ranjivosti okoliša, fragmentacije i očuvanja usluga ekosustava u jadransko-jonskom području" je odabran kao okvir za provjeru predloženog rješenja. Partneri uključeni u HarmoNIA (10 institucija iz Italije, Hrvatske, Grčke, Slovenije, Crne Gore i Albanije) imaju dugogodišnju stručnost i iskustva u prikupljanju, obradi, kontroli kvalitete i upravljanju podatcima o kemiji mora te u implementaciji proizvoda za vizualizaciju podataka, zajedno sa stručnošću u razvoju i radu infrastrukture distribuiranih podataka. Jedan od radnih paketa i zadataka projekta je: "Usluga pregleda će se implementirati kako bi se omogućila laka vizualizacija položaja mjesta uzorkovanja i distribucije podataka o odabranim skupinama parametara (npr. teški metali, ugljikovodici,...). Obzirom na heterogenu i složenu prirodu podataka o zagađivačima, provest će se popis proizvoda za vizualizaciju podataka koji se obično koriste za procjenu zagađivača u Jadransko-jonskom moru kako bi se definirale najbolje prakse sintetskih i znanstveno smislenih načina za analizu i predstavljanje podataka, i definirati skup izlaznih podataka posebno relevantnih za Okvirnu direktivu o morskoj strategiji. Prikupljeni skupovi podataka će se koristiti, u dogovoru s pružateljima podataka i prema uvjetima pristupa definiranim unutar projekta, za stvaranje, u odabranim ključnim područjima, primjera zajedničkih izlaznih podataka korisnih za upravljanje kontaminacijom na transnacionalnoj razini." Provedba predloženih metoda kao službene vizualizacije podataka projekta dobar je način provjere. U testiranju rješenja sudjelovali su stručnjaci iz spomenutih deset institucija iz šest zemalja.

Dodatni način provjere je korištenje implementiranih metoda u procesu upravljanja podatcima i provjerama za nacionalnu bazu podataka oceanografskog monitoringa u Hrvatskoj. Baza podataka se koristi kao obvezni alat za pohranu i provjeru cjelokupnog hrvatskog nacionalnog programa praćenja mora.

5.5. Implementacija

Za implementaciju naših metoda potrebni su nam neki osnovni elementi. Prva je relacijska baza podataka koja sadrži podatke o okolišu. Drugi je http poslužitelj za posluživanje sadržaja na mreži i neka vrsta aplikacijskog poslužitelja za proizvodnju dinamičkih mrežnih stranica. Konačno, tu su odabrani JavaScript API-ji i prilagođene biblioteke za izradu za vizualizaciju podataka na strani klijenta unutar preglednika.

5.5.1. Korištene tehnologije

Kao relacijska baza podataka za konkretnu implementaciju koristi se ORACLE 19 baza podataka [68], standardno izdanje 2. Baza podataka je instalirana na Linux operacijski sustav (CentOs 7). Na istom poslužitelju je instaliran Apache http poslužitelj i Tomcat 9 aplikacijski poslužitelj. Pod Tomcat poslužiteljem aplikacija pokreće se Oracle REST Data Service (ORDS) za kreiranje dinamičkih mrežnih stranica iz procedura baze podataka. Na strani klijenta koristi se Highcharts 8, softverska biblioteka za crtanje napisana u čistom JavaScriptu. Za kartu se koristi JavaScript biblioteka Google maps API v3. Također se neke JavaScript biblioteke opće namjene koriste kao jQuery i Backgrid. Kao format prijenosa podataka između poslužitelja i klijenta koristi se JSON [28].

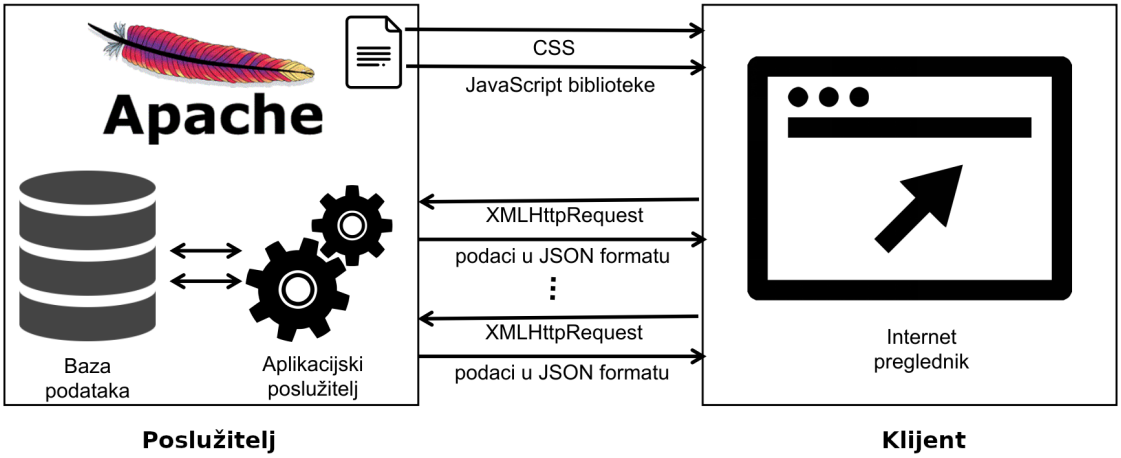

Slika 5.8: Prikaz učitavanja mrežne aplikacije

U predloženom pristupu koristimo se JavaScript bibliotekama za crtanje karata i prikaz prostornih podataka i za vizualizaciju podataka. Na sučelju se nalazi dinamički filtar podataka za odabir podskupa za vizualizaciju. Podatci se dohvaćaju s pomoću asinkronog XMLHttpRequest ili novijeg API-ja za dohvaćanje. Samo alfanumerički podatci u JSON formatu prenose se između poslužitelja i klijenta.

Učitavanju podataka mrežne stranice sastoji se od dviju glavnih komponenata.

- Učitavanje CSS elemenata i JavaScript knjižnica kao statičkog sadržaja s mrežnog poslužitelja. Predmemorija preglednika može se koristiti za dodatno smanjenje količine prenesenih podataka.

- Učitavanje podskupa podataka za vizualizaciju kao odgovor na specifične zahtjeve korisnika. Korisnik odabire podskup podataka s pomoću filtara podataka koji se nalaze na stranici.

Shematski prikaz procesa učitavanja stranice prikazan je na slici 5.8.

Asinkroni XMLHttpRequest ili API za dohvaćanje koristi se za učitavanje podataka u pozadini. Sinkrono učitavanje podataka onemogućeno je u nekim preglednicima. Prilikom asinkronog učitavanja podataka potrebno je odgovarajuće rukovanje događajima. Tek kada je trenutni proces dohvaćanja podataka i crtanja završen, korisnik može odabrati drugi skup podataka ili parametar i započeti novi ciklus. Za prijenos podataka koristi se JSON format. Iako se JavaScript metoda zove "XMLHttpRequest", koristi se format JSON, a ne XML. JSON format dopušta nizove i složene strukture te je sažetiji od XML-a.

5.5.2. Primjer implementacije

Postoji više od jedne implementacije metoda, a neke su navedene u odjeljku 5.4.6. Implementacija vizualizacije podataka u okviru projekta HarmoNIA otvorena je za javnost i to zato što je ova implementacija zgodna za prikaz kao primjer implementacije. HarmoNIA vizualizaciju podataka: `https://vrtlac.izor.hr/ords/harmonia/`.

5.5.3. Implementacija prilagodljivih filtara

Skupovi podataka projekta HarmoNIA o opasnim tvarima u sedimentu, bioti i vodenom stupcu izrađeni su uz pomoć inicijative EU EMODnet za upravljanje i pružanje fragmentiranih podataka o moru te u okviru projekta HarmoNIA. Skupovi podataka pokrivaju Jadransko i Jonsko more i obuhvaćaju razdoblje 1980 - 2017. Ovi podatci dolaze iz 10 različitih institucija. Podatci su prikupljeni na 2149 postaja koje su uzorkovane više od 4282 puta. To rezultira konačnim brojem od 95231 vrijednosti podataka povezanih s 510 različitih parametara u 22 skupine. Svi podatci označeni su kvalitetom korištenjem zajedničkog pristupa. Skupovi podataka sadrže neke podatke o ograničenom pristupu (pregovarački ili akademski - 6010 od 95231). Ti se podatci ne prikazuju kao pojedinačne vrijednosti, već se koriste za statističke izračune.

Filtar podataka sadrži sljedeće izbore:

- godina,
- projekt / monitoring program,
- institucija,
- krstarenje,
- grupa parametara,
- parametar.

U prvoj verziji sva polja su bila popunjena svim jedinstvenim vrijednostima iz cijelog skupa podataka (sve godine, sve institucije itd.). U praksi su korisnici često birali kombinacije za koje uopće nisu bili dostupni podatci (npr. neke institucije nisu dostavile podatke za određenu godinu). Iz tog razloga implementirani su adaptivni filtri. U svakom događaju *onChange* svakog od navedenih polja, izvršava se upit baze podataka i svako polje se popunjava mogućim kombinacijama.

Kako bi se poboljšala učinkovitost, posljednje korištene vrijednosti filtara (kombinacije) pohranjuju se kao kolačić u pregledniku. Na sljedećem upitu korisnik može početi s prethodnom kombinacijom filtera, što štedi vrijeme (korisnik ne mora postavljati sva polja od početka). Ako iz nekog razloga korisnik želi započeti s novim "praznim" filtrom, postoji tipka "Reset filters" za tu svrhu.

Uz glavni filtar upita implementiran je filtar za različite faktore provjere valjanosti ili ograničenja pristupa. Prema zadanim postavkama, na grafikonu se prikazuju provjereni ili nepotvrđeni podatci. Korisnik također može uključiti sumnjive ili loše vrijednosti klikom na odgovarajući potvrdni okvir. Brojevi unutar svakoga potvrdnog okvira za svaki faktor provjere označavaju koliko je vrijednosti uključeno u svaku kategoriju.

5.5.4. Dvosmjerno povezivanje grafa i karte

Sva mjerenja prikazana su kronološki poredana na grafikonu. U slučaju da postoji više od jednog mjerenja po jednoj postaji, sve vrijednosti se označavaju na grafikonu kada korisnik napravi *hover* do pozicije postaje na karti. U slučaju da postoji više od jednog mjerenja (za danu lokaciju i vremenski raspon), jedna od funkcija grupe se koristi za izračunavanje jedne vrijednosti (srednja vrijednost u konkretnom primjeru). Broj vrijednosti korištenih za združivanje prikazan je u zagradama pored naziva postaje. Klikom na grafikon (određeni stupac ili redak), prikaz grafikona vremenskog niza prikazuje širinu svih određenih vrijednosti poredanih kronološki. Element grafa i oznaka postaje usklađeni su u boji, a vizualna povratna informacija je osigurana pri lebdenju bilo kojeg od ovih elemenata. Primjer je prikazan na slici 5.9.

5.5.5. Statistika

Osnovna statistika pruža se za cijeli vizualizirani podskup podataka. Statistika uključuje broj postaja i vrijednosti, minimalne i maksimalne vrijednosti i postaje na kojima su te vrijednosti prisutne, prosjek, standardnu devijaciju, varijancu i vremenski raspon podataka.

Ako je prikladno, korisnik može odabrati drugu vrstu grafikona odabirom samo jedne razine podataka kao prosjeka (u slučaju da imamo više od jedne vrijednosti dubine ili visine na istoj lokaciji).

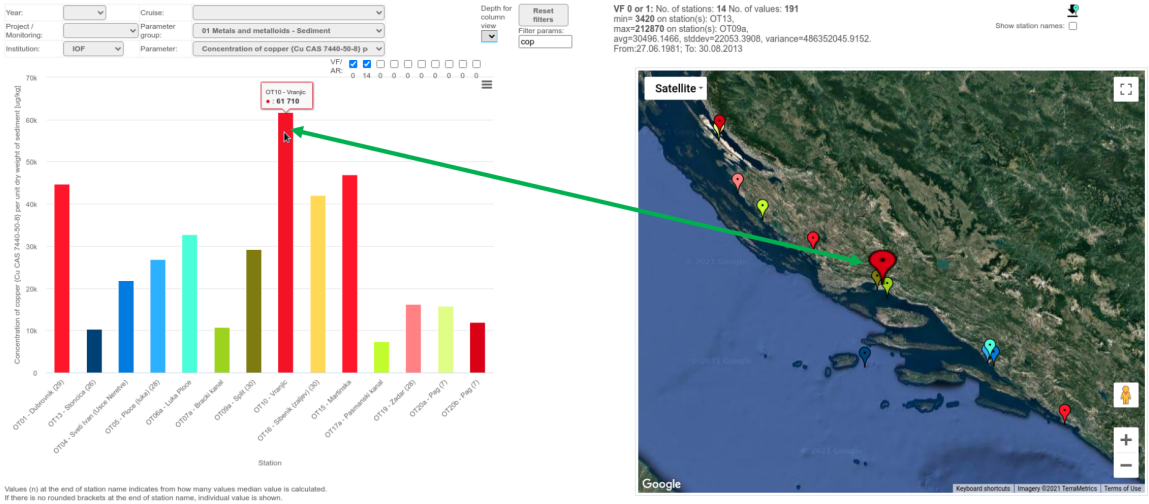

Slika 5.9: Primjer dvosmjernog povezivanja

5.5.6. Od statusa do trenda

Za svaku agregiranu vrijednost na grafu izlaznog statusa moguće je dobiti graf trenda za određenu postaju i parametar samo jednim klikom. Primjer možete pronaći na slici 5.10.

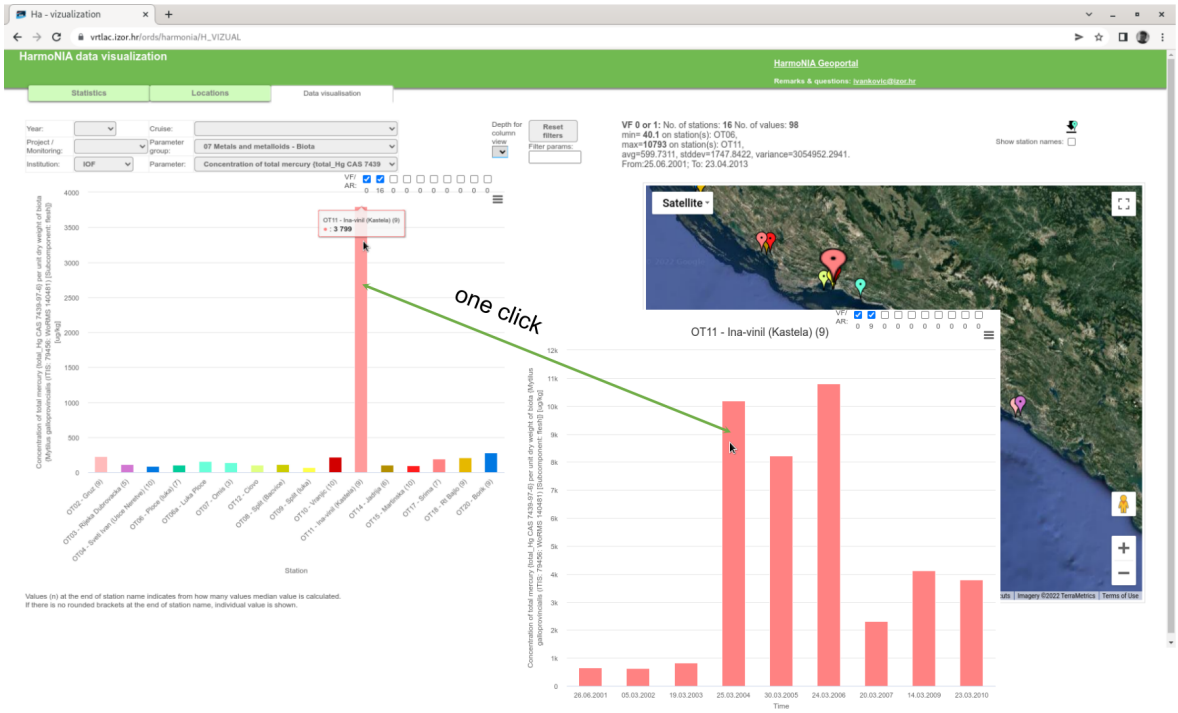

Slika 5.10: Od statusa do trenda u jednom kliku

5.5.7. Srednjak za vodeni stupac ili prikaz vrijednosti s pojedine dubine

Oceanografski podatci često imaju više od jedne dubine za dano mjerenje (slično, meteorološka mjerenja imaju različite visine). U tom slučaju se stvara linijski grafikon. Budući da različite postaje mogu imati različite dubine, a neke postaje mogu imati samo jednu dubinu, moguća je konverzija u stupac grafikona. Korisnik može odabrati prosjek svih dubina ili određenu dostupnu dubinu kako bi proizveo samo jednu vrijednost po postaji u trakastom grafikonu. Ovu vrstu grafikona je u nekim slučajevima lakše razumjeti. Primjer se može naći na slici 5.11.

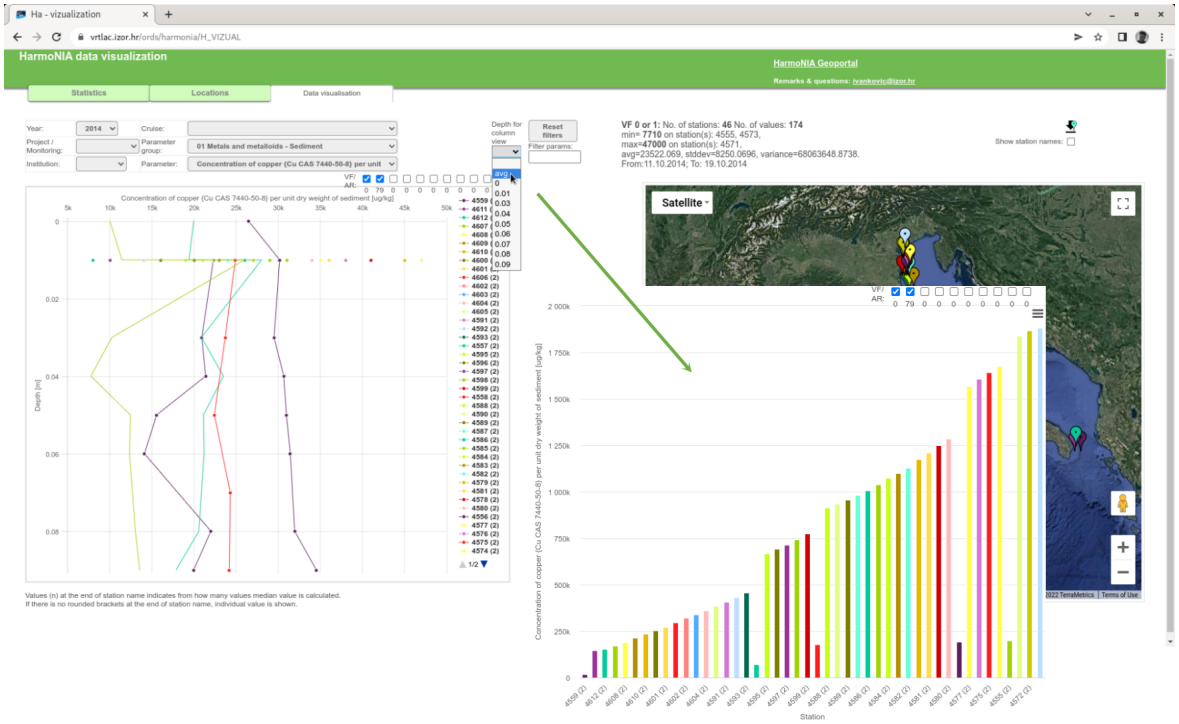

Slika 5.11: Primjer korištenja funkcije "jedna dubina"

5.6. Rezultati

Programiranje dinamičke mrežne stranice sastoji se od dvaju glavnih dijelova: Programiranje i optimizacija upita baze podataka te struktura i programiranje u JavaScriptu unutar same stranice. Vrijeme učitavanja jedna je od najkritičnijih karakteristika stranice (mrežne aplikacije). Učitavanje "prazne" stranice (samo podatkovni filtar bez podskupa podataka) traje oko dvije sekunde (mjereno na ADSL vezi ili 4G mobilnoj vezi). Učitavanje kategorija adaptivnih filtara traje nešto više od jedne sekunde, a učitavanje i vizualizacija podskupa podataka traje još dvije sekunde. Učitavanje cijele stranice sa svim komponentama (kada su korisničke postavke pohranjene u kolačić) traje oko četiri sekunde. Iako je vrijeme učitavanja duže od jedne sekunde, što je danas nekako standard, postignuta izvedba je prihvatljiva za mrežnu

stranicu s toliko elemenata i podataka. Skriptiranje (izvršenje JavaScripta na strani klijenta) traje oko tri sekunde za ovaj prosjek od četiri sekunde. Vrijeme učitavanja i performanse stranice su u istom rasponu kao i spomenuta desktop aplikacija Ocean Data View.

Tablica 5.2: Brzine prikaza mrežne stranice (milisekunde).

Br. podataka u učitanom setu	**Učitavanje**	**Obrada (*Scripting*)**	**Iscrtavanje**	**Ukupno**
166 (mali)	22 ms	1441 ms	206 ms	1669 ms
2226 (srednji)	22 ms	2896 ms	275 ms	3193 ms
24320 (veliki)	18 ms	4703 ms	76 ms	4797 ms

Kako bismo testirali kako veličina skupa podataka utječe na vrijeme učitavanja, izmjerili smo performanse na tri skupa podataka: mali, srednji i veliki. Test je proveden preko prosječne ADSL veze s Internetom (maksimalna brzina 15 Mb/sec) korištenjem stolnog računala s AMD® Ryzen 5 3500u procesorom. Kao što možemo vidjeti iz tablice 5.2, glavna komponenta ukupnog vremena učitavanja je obrada (skriptiranje). Vrijeme učitavanja za veliki skup podataka čak je kraće nego za mali skup podataka, što možemo objasniti varijacijama brzine mreže. Vrijeme potrebno za iscrtavanje također nije značajno i nije povezano s veličinom skupa podataka. Kao što smo očekivali, glavna razlika u vremenu učitavanja je radi obrade podataka s klijentske strane (skriptiranje) jer uglavnom koristimo JavaScript za obradu podataka i renderiranje grafikona i karata. U sva tri slučaja vrijeme učitavanja je dovoljno kratko za dobro korisničko iskustvo i učinkovit tijek rada.

5.6.1. Implementacija za projekt HarmoNIA

Implementacija vizualizacije podataka projekta HarmoNIA pomogla je u analizi skupa podataka projekta. U skupu podataka pronađeno je 7294 duplikata, što znači da je još 7% duplikata pronađeno u već provjerenom skupu podataka. Vizualizacija trenda također je pomogla u pronalaženju "kvazi duplikata", obično parova istih vrijednosti za isti parametar, vrijeme i postaju, ali dvaput prijavljena s različitim mjernim uređajima. Alat za vizualizaciju podataka korišten je za izradu službenih ishoda i rezultata projekta. Prema dijelu izvješća o znanstvenom projektu, "Standardni pristup i usklađeni sustav upravljanja podatcima omogućavaju jednostavnu usporedbu koncentracija kontaminanata mjerenih u različitim zemljama. Sustav vizualizacije je interaktivan i jednostavno omogućuje filtriranje i vizualizaciju željenih informacija za usporedbu prostornih i/ili vremenska varijabilnost specifične koncentracije onečišćivača među različitim postajama za praćenje."

Nakon završetka projekta HarmoNIA, sve institucije sudionice pridružile su se "HarmoNIA mreži" za daljnju promociju rezultata projekta i nastavak razvoja projektnih alata. Jedan od tih alata je alat za vizualizaciju podataka, a razvoj ovog alata se nastavlja. Kako su rezultati projekta dobro utjecali na znanstvenu zajednicu i agencije za financiranje EU-a, sada se

planira novi projekt kao prednik HarmoNIA-e.

5.6.2. Hrvatska nacionalna baza podataka monitoringa

U okviru Hrvatskog referentnog centra za more Ministarstva gospodarstva i održivog razvoja Republike Hrvatske razvijena je nacionalna monitoring baza podataka i mrežna aplikacija. Glavna je svrha baze podataka pružiti učinkovit alat za stručnjake iz mnogih institucija uključenih u praćenje mora za unos i provjeru oceanografskih mjerenja. Ova se aplikacija temelji na istim principima i kodu kao i HarmoNIA vizualizacija podataka. Razlika je u tome što je aplikacija HarmoNIA za vizualizaciju podataka i javno dostupna, dok je ova aplikacija za provjeru valjanosti podataka i autorizirana je. Aplikacija se koristi dvije godine i napravljen je dobar napredak u poboljšanju kvalitete podataka. Za neke parametre poput morskog otpada podatci su vizualizirani i potvrđeni prvi put, kategorizirani po postajama i s prostornom komponentom (slika 5.12). Aplikacija je dobro prihvaćena od korisnika i koristi se bez prethodne obuke.

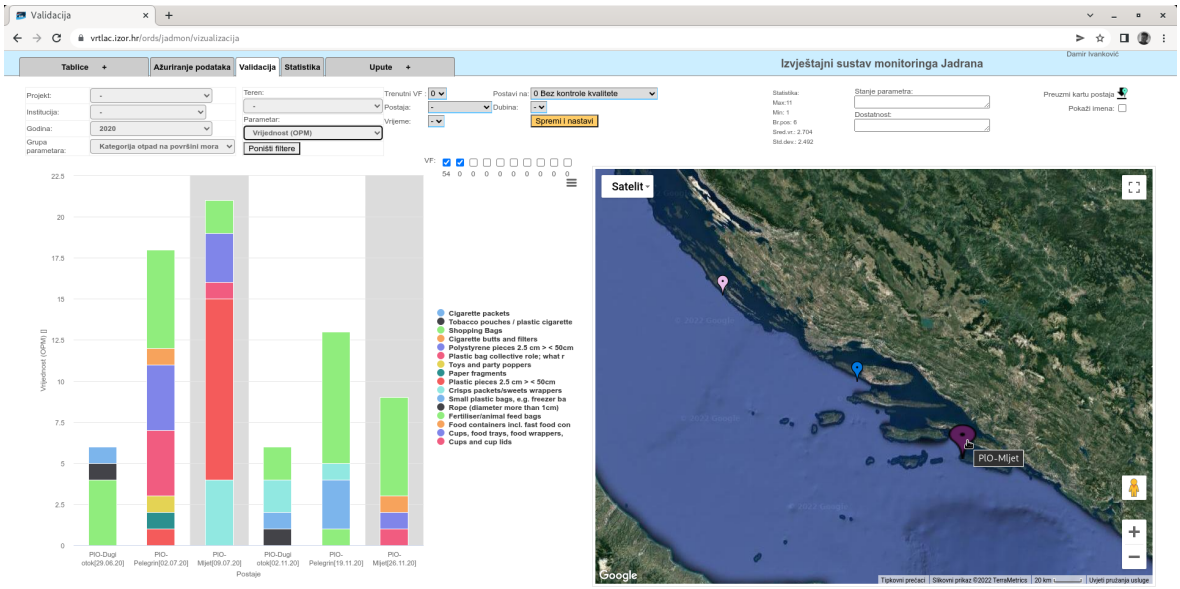

Slika 5.12: Primjer prikaza kategorija morskog otpada

5.7. Prostorno-vremenska pretraga podataka (engl. *data mining*)

Data mining je ispitivanje i analiza velikih količina podataka kako bi se identificirali smisleni obrasci i trendovi uz korištenje ljudskog znanja i intuicije [69]. Tradicionalne tehnike prostorno-vremenske pretrage podataka uključuju specijalizirane alate i prilagođene vizualizacije podataka. Primjenom predloženih principa na vizualizaciju i upravljanje podatcima

postaje moguće implicitna prostorno-vremenska pretraga podataka. Korisnik će moći identificirati različite prostorne i vremenske obrasce i trendove bez dodatne analize. Učinkovita pretraga prostorno-vremenskih podataka podrazumijeva primjenu dodatnih pravila.

- Prostorne objekte treba unaprijed klasificirati i grupirati prema različitim prostornim domenama. Prostorni upiti obično oduzimaju mnogo vremena. Prethodno dodjeljivanjem križnih tablica koje povezuju domene i određene objekte u trenutku umetanja novog prostornog objekta, buduće prostorno grupiranje bit će dovoljno brzo za dobro korisničko iskustvo (zadano vrijeme čekanja za osvježavanje mrežne stranice ispod 1 sekunde).

- Velike vremenske nizove podataka (s iste lokacije) treba grupirati i na grupiranje primijeniti osnovne statističke funkcije (minimum, maksimum, prosjek, medijan, standardna devijacija). Grupiranje treba biti hijerarhijsko i automatsko na kraju različitih razdoblja (kraj dana, mjeseca, godine).

- Prostorne i vremenske grupe trebaju biti povezane i prikazane od vrha do dna: veća područja prikazana na karti treba dalje podijeliti na manja područja ili godišnje prosječne podatke dodatno podijeliti na mjesečne i dnevne prosjeke.

Ove vrste agregiranja, u kombinaciji s dobrim prostorno-vremenskim vizualizacijama, mogu omogućiti jednostavnu analizu podataka za korisnike koji se koriste samo mrežnim preglednikom.

5.8. Zaključak

Cilj prikazanog načina vizualizacije je poboljšati upravljanje podatcima i vizualizaciju, posebno za različite parametre okoliša s prostornim i vremenskim komponentama. Iako su neka od ovih načela dobro poznata i sama po sebi razumljiva, nemaju praktičnu primjenu. Unatoč ogromnim poboljšanjima u informatici i mjernim tehnikama, podatci o okolišu još uvijek nisu u potpunosti iskorišteni. Od izvora podataka i provjere valjanosti do takozvanih informacija za donositelje odluka, velike količine podataka o okolišu se gube ili se ne koriste pravilno. Prikupljanje podataka može biti vrlo skupo, ali se plaća još veća cijena kada se zbog nedostatka znanja i razumijevanja donose loše odluke o zaštiti okoliša. Korištenje relacijskih baza podataka i interaktivnih, dvosmjerno povezanih karata i grafičkih prikaza može poboljšati kvalitetu i dostupnost podataka. Vizualizacija podataka o okolišu na Internetu također je važna jer podatke može učiniti dostupnijima široj javnosti. Interes javnosti za podatke o okolišu raste, a mnoge organizacije izvan ekoloških i znanstvenih institucija traže pouzdane i lako razumljive informacije.

Količina dostupnih informacija danas je ogromna, a za razlikovanje visokokvalitetnih podataka od "informacijske buke" potrebna nam je dobra prezentacija i vizualizacija podataka.

Postoje mnoge inicijative za poboljšanje otkrivanja i ponovne upotrebe podataka, ali malo je inicijativa za poboljšanje prezentacije podataka. Pokušavamo pridonijeti jasnom i dosljednom prikazu podataka o okolišu. Ovdje opisano rješenje omogućuje jasniji prikaz podataka o okolišu koje je puno lakše interpretirati u odnosu na postojeća rješenja opisana u poglavlju 3.

6. PRIKAZ I UPRAVLJANJE PODATCIMA U STVARNOM VREMENU

Ovo poglavlje je prevedena i proširena verzija rada s konferencije IEEE SpliTech 2021 [70]. Rad je usmeno prezentiran u sekciji "IoT - Software and Systems". Primjeri prostornih polja i naprednih vremenskih osi su prezentirani na posteru [71], na radionici Centra izvrsnosti za računalni vid 2017. godine.

Mjerenja okoliša u stvarnom vremenu obavljaju automatski mjerni sustavi koji izmjerene podatke šalju u kratkom vremenu nakon mjerenja. Dobiveni podatci postaju sve važniji jer se suočavamo s klimatskim promjenama. Oni se koriste za napajanje numeričkih modela, ali se također objavljuju na Internetu. U ovom poglavlju ističemo neke osnovne principe za objavljivanje podataka u stvarnom vremenu na mreži. Glavni cilj objave i vizualizacije podataka je pružiti korisniku intuitivan način uvida u trenutačno stanje okoliša i neke trendove. Dinamične mrežne stranice, glavni alat za prezentaciju podataka, mogu nadilaziti statične slike i pružiti opsežne interaktivne mogućnosti.

6.1. Područje istraživanja

Uz brzi razvoj elektroničkih senzora i mobilnih mreža, sada je relativno lako postaviti mjernu postaju za praćenje okoliša u stvarnom vremenu. Osim službenih mreža kojima upravljaju državne institucije, postoji i veliki broj neslužbenih mjernih postaja kojima upravljaju pojedinci ili neke nevladine organizacije. Većina mjerenja odnosi se na osnovne meteorološke parametre, uz sve veći broj ekoloških (npr. kakvoća zraka) i oceanografskih parametara. Podatci su predstavljeni na raznim mrežnim stranicama, često sa sučeljima koji nisu previše prilagođeni korisniku. Trenutačna rješenja i mrežne stranice uglavnom koriste meteograme. Prevladava prilagodljivi (responzivni) dizajn, ali nije uvijek dostupan. U nekim slučajevima korisnik donekle može vidjeti povijesne podatke, ali obično je teško pronaći ekstremne vrijednosti. Institut za oceanografiju i ribarstvo ima svoju automatsku mjernu postaju ispred zgrade instituta već više od 20 godina (uz neke prekide zbog logističkih problema). U sklopu više različitih projekata mreža je postaja proširena i sada broji sedam postaja s meteorološkim i u nekim slučajevima oceanografskim podatcima. Uz to je aktivno i devet mikrobarografskih postaja s mjerenjima tlaka zraka, od kojih je šest s prijenosom podataka

u stvarnom vremenu.

6.2. Ciljevi istraživanja

S obzirom na to da su glavni ciljni uređaji za gledanje pametni telefoni te da količina prenesenih podataka treba biti što manja potrebno je pri implementaciji primijeniti dodatna pravila. Navedimo ova pravila čija je implementacija cilj našeg istraživanja.

- Prilagodljiv dizajn i sučelje (izbjegavati desni klik i dvostruki klik).
- Prijenos podataka u pozadini (po mogućnosti u JSON formatu).
- Vizualizacija podataka na strani klijenta.
- Korištenje JavaScript biblioteka (spremljenih u predmemoriju preglednika).
- Dopuštanje i spremanje korisničkih postavki (kolačića).

6.3. Postojeća rješenja

Pljusak.com na adresi `https://pljusak.com` je stranica za objavu rezultata mjerenja mreže neovisnim meteoroloških postaja. Pri objavi podataka koristi kartografske i tablične prikaze.

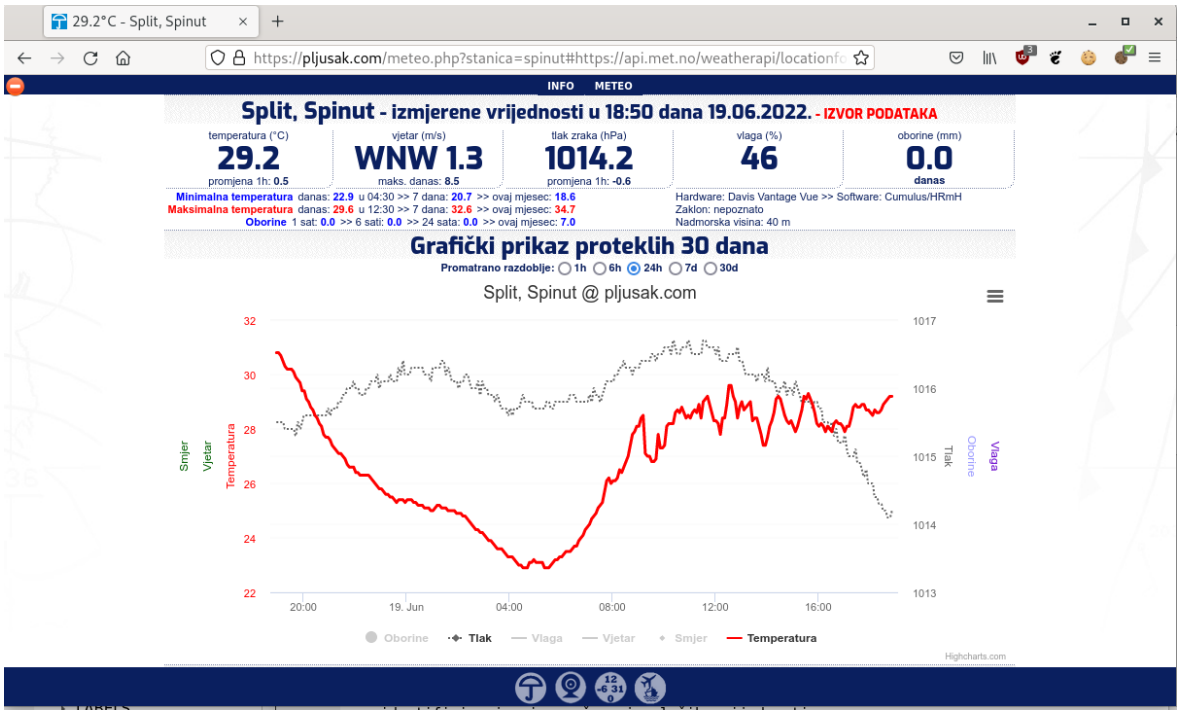

Slika 6.1: Prikaz podataka na stranici pljusak.com [72]

Za prikaz grafova koristi Highcharts JavaScript biblioteku. Prikaz nije prilagođen malim ekranima (responzivan). Podatci se učitavaju zajedno sa samom stranicom i ne postoji

dinamičko učitavanje podataka. Podatke je moguće vidjeti do 30 dana unazad na grafičkom prikazu. Na samom grafičkom prikazu biraju se parametri za vizualizaciju i uvijek su vidljive višestruke y osi sa svake strane. Odabir proizvoljnog datuma nije moguć. Prikaz podataka je vidljiv na slici 6.1.

6.4. Materijali i metode

Za bolje rezultate, podatke treba vizualizirati na strani klijenta s pomoću JavaScripta. Podskup podataka se prije toga prema korisnikovim upitima učitava s poslužitelja. Nabrojimo prednosti ovoga pristupa.

- Kratko vrijeme učitavanja (podatci u odnosu na sliku)
- Manja opterećenost poslužitelja
- Interaktivni grafikoni (prikaz vrijednosti, zumiranje)
- Kombinacija različitih korisnički definiranih parametara u istom grafikonu.

6.4.1. Dohvat podataka i asinkroni prijenos

Iako postoji dosta stranica gdje se podatci učitavaju zajedno sa samim kodom stranice, većina dinamičkih mrežnih stranica koristi neki oblik pozadinskog učitavanja podataka. Ovaj pristup ima mnoge prednosti. Osnovna stranica ima kraće vrijeme učitavanja i podatci se učitavaju prema zahtjevima korisnika, nije nužno učitati sve dostupne podatke za prikaz. JSON format koristi se za prijenos podataka jer je sintaksa izvedena iz zapisa JavaScript objekata i dopušta nizove i složene strukture podataka. JSON format je lakši za čitanje i sadrži manje znakova od ekvivalentnog XML (eXtensible Markup Language) zapisa.

Unutar mrežnog preglednika mogući su sinkroni i asinkroni zahtjevi za dohvat podataka. Međutim, općenito, asinkroni zahtjevi bi trebali biti preferirani nad sinkronim zahtjevima iz razloga izvedbe. Također, neki preglednici kao što je Chrome više ne dopuštaju sinkrone zahtjeve jer mogu značajno utjecati na korisničko iskustvo (stranica ne reagira dok se ne učitaju podatci).

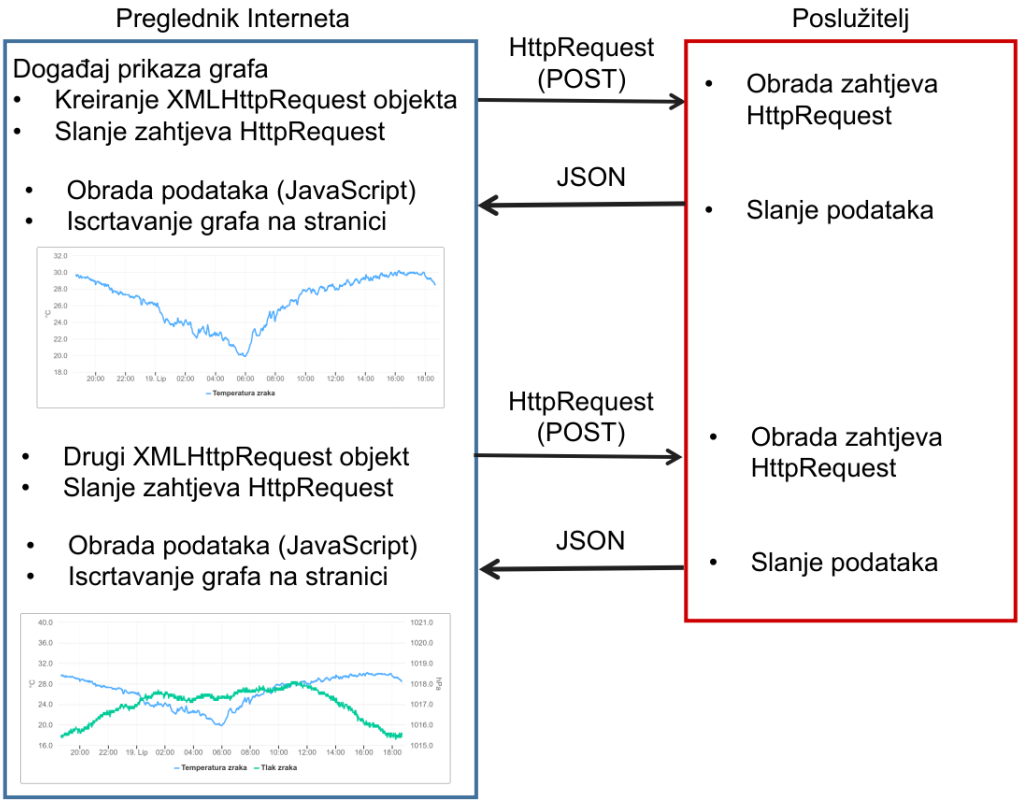

Slika 6.2: Dohvat i odrada dva seta podataka

Korištenje asinkronih zahtjeva zahtijeva dobro rukovanje događajima kako bi se izbjegle pogreške uzrokovane različitim vremenima odgovora. Kod asinkronog zahtjeva kôd se nastavlja normalno izvršavati odmah nakon slanja zahtjeva. Postoji posebna procedura koja se izvršava na kraju prijenosa podataka koja dobiva status prijenosa (je li bio uspješan). Ako se učitava više od jednog skupa podataka (korisnik je kliknuo na drugi parametar dok za prvi još nisu stigli podatci), drugi skup podataka treba zatražiti nakon što se prvi skup dohvati i nacrta. U suprotnom, različita vremena odgovora mogu uzrokovati pogreške u vizualizaciji podataka. Proces je shematski prikazan na slici 6.2.

6.4.2. Dizajn baze podataka

Tablice unutar relacijske baze trebaju osim samih mjerenih vrijednosti pohraniti i metapodatke o samoj postaji (lokacija, mjerni uređaji, parametri koji se mjere i koji se prikazuju javnosti). Središnja tablivca je MJESUST_POS_PAR u kojoj su definirane veze prema tablici postaja, tablici mjernih parametara i tablici mjernih senzora.

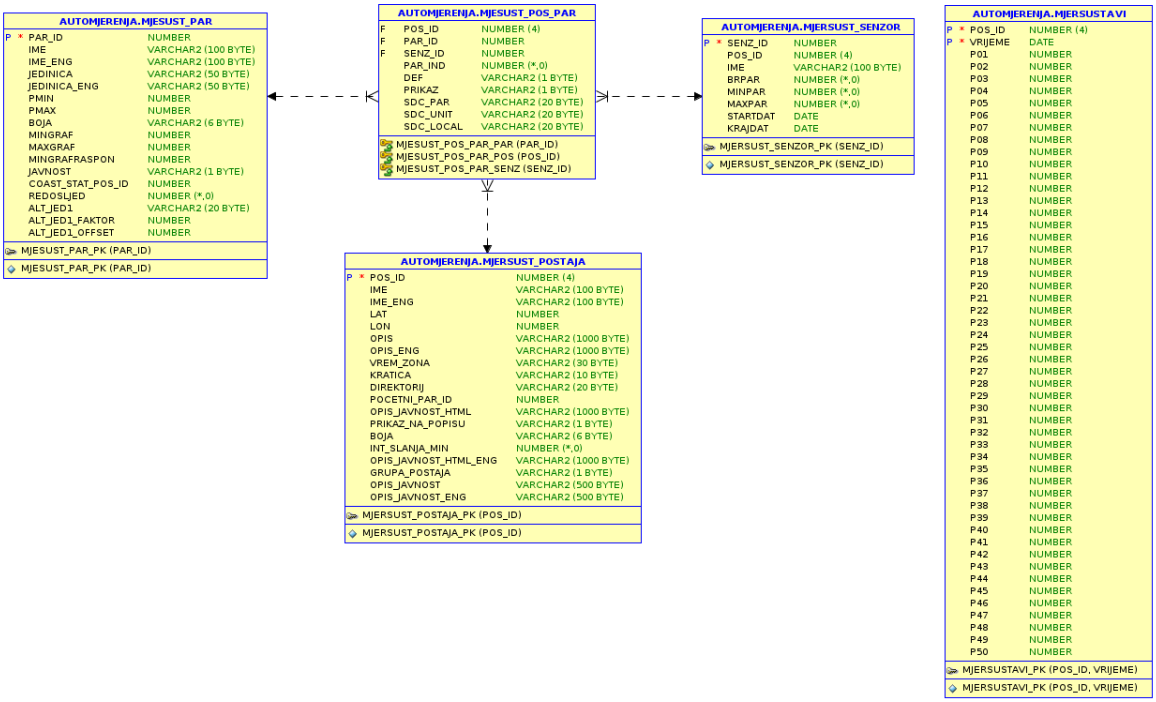

Slika 6.3: Glavne tablice u bazi podataka

I kod automatskih mjernih sustava parametri trebaju biti definirani dinamički i fleksibilno tako da se jednostavno mogu definirati i pohranjivati novi parametri ne mijenjajući strukturu baze podataka i kôd procedura koje upisuju i čitaju podatke. Istovremeno je u slučaju automatskih mjernih sustava količina pohranjenih podataka veća i dolazimo do problema velikog broja redova u tablicama gdje upis i čitanje postaju neučinkoviti (sustav koji mjeri svake minute proizvede 512.640 redova godišnje, dok sustav sa sekundnim mjerenjima proizvede još 60 puta više: 30.758.400 redova). Ovaj se problem rješava particioniranjem tablice za pohranu mjerenih vrijednosti i to prema vremenskom ključu (svaka particija tablice sadrži mjerenja za pojedinu kalendarsku godinu). Imajući ovo u vidu sustav parametrizacije kojim smo se koristili kod pohrane klasičnih oceanografskih podataka nije više praktičan jer je riječ o tvz. transponiraoj pohrani gdje se za svaki dodatni parametar kreira novi redak u tablici s mjerenom vrijednosti i referencijom na parametar i ostale metapodatke. Kako pojedina mjerna postaja može imati i više od deset mjerenih parametara, time smo problem velikog broja redaka uvećali još za red veličine. Kao rješenje ovog problema parametrizacije napravljena je tablica za pohranu mjerenih vrijednosti (MJERSUSTAVI) koja osim vremena mjerenja i referencije na mjernu postaju, sadrži 50 kolona za pohranu mjerenih vrijednosti. Ove kolone su generičkih imena p01 do p50 i u njih se upisuju mjerene vrijednosti. Poveznica s mjerenim parametrom je u metatablici MJESUST_POS_PAR gdje je za svaki parametar (par_id) definirana pozicija, odnosno indeks kolone u koju se upisuje vrijednost (par_ind). Ako je za neki parametar tu upisam broj jedan, on se upisuje u kolonu p01, ako je upisan dva, upisuje se u kolonu p02, itd. Ovako je moguće za svaku postaju upisati do 50 mjerenih

parametara, a da je za određeno vrijeme mjerenja dodan samo jedan redak u glavnu tablicu s mjerenim vrijednostima. Na slici 6.3 relacijski je dijagram tablica s metapodatcima, i desno glavna tablica za pohranu mjerenih vrijednosti.

6.4.3. Elementi sučelja i njihov dizajn

Sučelje za prikaz podataka s automatskih mjernih postaja treba sadržavati neke obavezne elemente: prikaz vremena posljednjeg mjerenja i posljednju izmjerenu vrijednost za sve dostupne parametre. Osim samih vrijednosti potrebno je grafički prikazati jedan ili više parametara. Na kraju treba postojati i navigacija na popis svih dostupnih postaja, kao i mogućnost da se pogledaju povijesni podatci s postaje. Uz grafički prikaz potrebno je dodati mogućnost odabira razdoblja koje se prikazuje na grafu. Raspored osnovnih elemenata na stranici je vidljiv na slici 6.4.

Slika 6.4: Prikaz rasporeda osnovnih elemenata na stranici

6.5. Implementacija

Klasični linijski grafikoni najprikladniji su za crtanje standardnih numeričkih vrijednosti. Uz korištenje druge y-osi, dva parametra se mogu prikazati u jednom dijagramu. Više od dva parametra (i posljedično više od dvije y-osi) može biti teško korisniku za "čitanje". Za vektorske vrijednosti sa smjerom i vrijednošću potrebna je upotreba strelica ili "ruže vjetrova" čiji se primjer može vidjeti na slici 6.5.

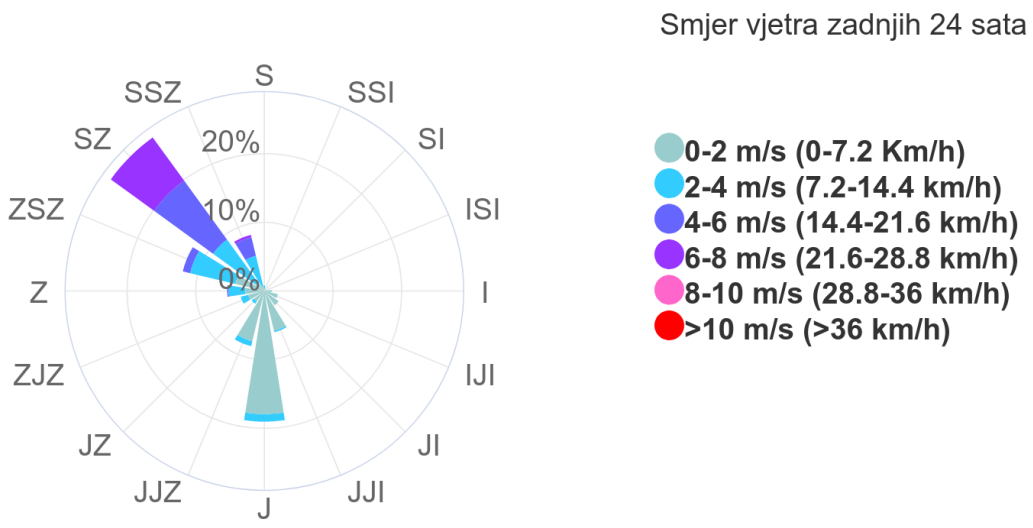

Slika 6.5: Ruža vjetrova za 24 sata sa 6 kategorija

6.5.1. Korištene tehnologije

Kako je sustav razvijan duže vremena, tehnološka podloga se u međuvremenu promijenila. Na početku je korištena Oracle baza 11.2 i Oracle aplikacijski poslužitelj 11.2 – koji je optimiziran za baze podataka, koristi se kao mrežni poslužitelj. Oracle aplikacijski poslužitelj je dosta modificirani Apache mrežni poslužitelj koji omogućava pohranjenim procedurama baze podataka da dinamički kreiraju mrežnu stranicu. Sama aplikacija pisana je u PL/SQL programskom jeziku za pripremu podataka uz korištenje i HTML-a (Hyper Text Markup Language) i JavaScripta. Nakon toga je sustav migriran na ORACLE 19.2 bazu podataka [68], standardno izdanje 2. Baza podataka je instalirana na Linux operacijski sustav (CentOs 7). Na istom poslužitelju je instaliran Apache http poslužitelj i Tomcat 9 aplikacijski poslužitelj. Pod Tomcat poslužiteljem aplikacija pokreće se Oracle REST Data Service (ORDS) za kreiranje dinamičkih mrežnih stranica iz procedura baze podataka. U ovoj arhitekturi je ubačen još jedan srednji aplikacijski sloj u modernoj troslojnoj arhitekturi za kreiranje dinamičkih mrežnih stranica. Sada je za prvi prezentacijski sloj zadužen Apache i on obavlja kriptiranje prometa, autentikaciju korisnika i razna preusmjeravanja prometa, srednji aplikacijski sloj je Tomcat, dok je zadnji podatkovni sloj sama relacijska baza podataka.

Na strani klijenta koristi se Highcharts 8, softverska biblioteka za crtanje napisana u čistom JavaScriptu kao jQuery biblioteka opće namjene. Kao format prijenosa podataka između poslužitelja i klijenta koristi se JSON [28].

6.5.2. Prilagodljiv dizajn

Prilagodljiv dizajn dobro je definiran i uključuje prilagođene css tablice stilova. Osim same veličine i pozicije elemenata, bitno je prilagoditi i upravljanje sadržajem. Na slici 6.6 prikaz

je podataka s malog ekrana.

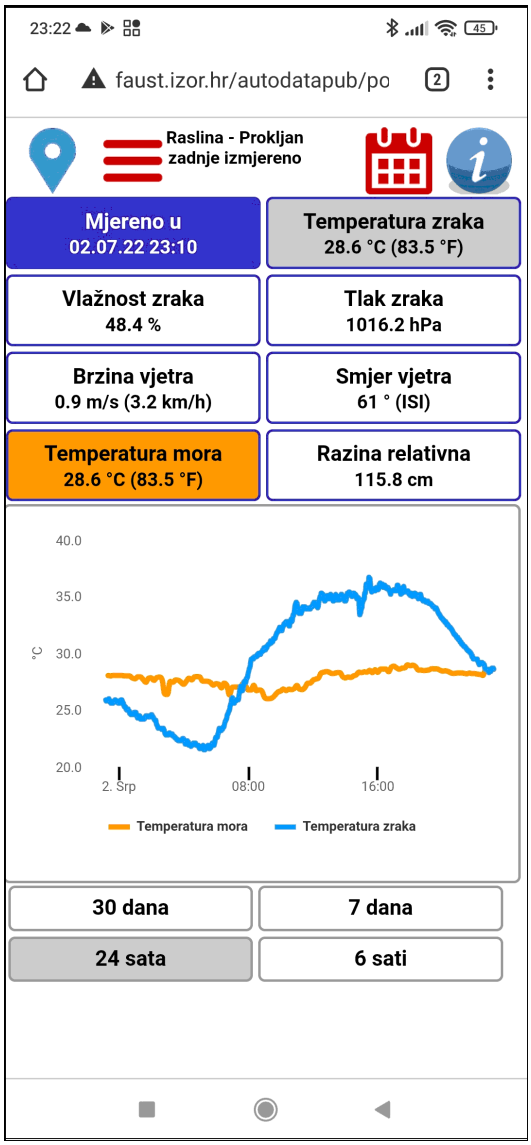

Slika 6.6: Primjer prilagodljivog dizajna

Za podatke u stvarnom vremenu potrebno je primijeniti neka dodatna načela.

- Elementi stranice trebaju biti dovoljno veliki i uvijek na istome mjestu.
- Područja koja se koriste za prikaz izmjerenih vrijednosti također se koriste za kontrolu vizualizacija podataka.
- Klikom na naziv parametara unutar jasno omeđenog područja pokreće se učitavanje podataka i iscrtavanje grafičkog prikaza za taj parametar.
- Klikom na vrijeme mjerenja otvara se kalendar s moćnošću odabira nekoga prošlog dana za koji se onda prikazuju mjerenja.

6.5.3. Navigacija i upravljanje mrežnom aplikacijom

Navigacija na svakoj mrežnoj stranici trebala bi biti jasna i intuitivna. Korisnik treba odmah shvatiti kako doći do željenog podatka, odnosno neke druge stranice. Kod pregleda na mobilnim uređajima s malim ekranima bitno je da navigacija ne zauzima previše prostora i da su poveznice dovoljno velike da ih se može odabrati prstom. Ovo sve nameće korištenje različitih simbola (slika) za elemente navigacije. Ovo je učinkovitije od dinamičkih padajućih menija jer se korisnik koristi jednim klikom manje (kod padajućeg menija prvo ga jednim klikom treba aktivirati). Određeni simboli su postali standardni za korištenje i korisnik unaprijed zna njihovo značenje i čemu služe. Na slici 6.7 prikazan je meni naše aplikacije.

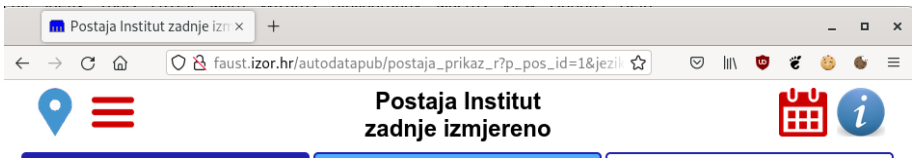

Slika 6.7: Meni na aplikaciji za prikaz rezultata automatskih mjernih postaja

Nabrojimo elemente s vrha stranice.

- Standardna oznaka (marker) za lokaciju. Ovo je poveznica na stranicu koja prikazuje točnu lokaciju postaje na karti.
- Oznaka koja se obično koristi za prikaz glavnog menija (tri horizontalne crte). Ova poveznica vodi do popisa svih postaja.
- Naziv postaje za koju su prikazani podatci.
- Standardna oznaka za kalendar gdje se poziva prikaz kalendara za odabir dana za koji se žele vidjeti podatci.
- Oznaka, odnosno malo slovo "i" koje se koristi za prikaz nekih informacija ili detalja. Odabirom ove stavke se ispisuju detaljne informacije o postaji u prostoru gdje je inače prikazan grafički prikaz.

Kada se odabere prikaz podataka za pojedini dan, onda se navigacija promijeni (slika 6.8). Sada su vidljive kontrole za kretanje kroz vrijeme (dan unazad i dan unaprijed). Desno je ikona kuće (engl. *home*) koja nas vraća na početni meni.

Slika 6.8: Meni za odabir prikaza za određeni dan

Za odabir razdoblja na grafičkom prikazu koriste se jednostavne kontrole s ispisanim trajanjem prikaza. Trenutačno razdoblje je označeno drugom bojom pozadine, a budući da su ove kontrole odmah ispod grafičkog prikaza, intuitivno je jasno na što se odnose. Kontrole su vidljive na slici 6.9.

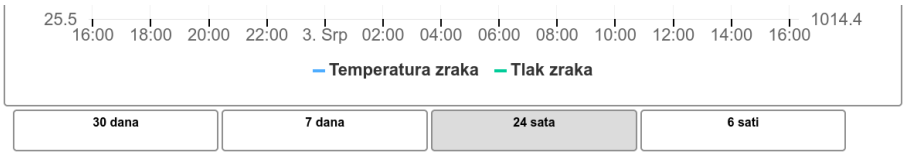

Slika 6.9: Odabir perioda prikaza na grafu

6.5.4. Prostorne komponente i kartografski prikazi

Sva mjerenja imaju određeno mjesto odakle potječu. Za prikaz mreže postaja najbolje je implementirati neku vrstu karte s mogućnošću zumiranja. Korisnik može započeti s većom regijom, zatim kliknuti na podregiju od interesa i odabrati određenu mjernu postaju na kraju. Alternativno, nazivi postaja mogu se odabrati s popisa ili neke vrste trake za pretraživanje. Treba napomenuti da korisnici koji pregledavaju stranicu s pametnih telefona mogu imati poteškoća s klikom na male oznake postaja na karti. Paralelne veće "tipke" povezane s oznakom postaje istom bojom mogu se koristiti za jednostavan odabir. Primjer je prikazan na slici 6.10.

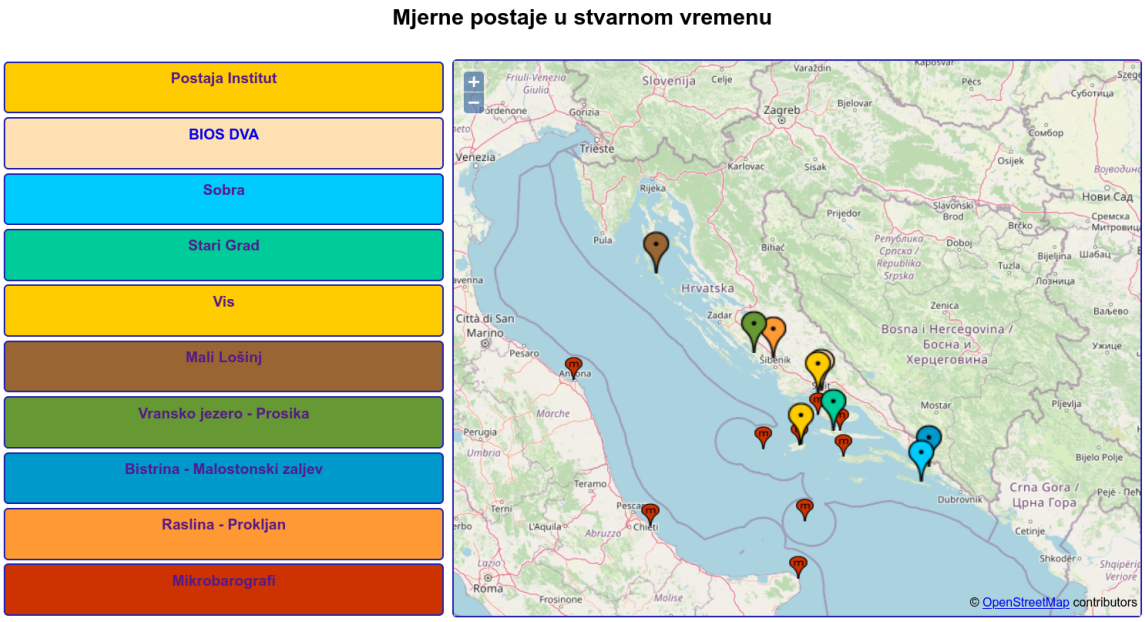

Slika 6.10: Jednostavna karta postaja

6.5.5. Organiziranje podataka

Zadana vrsta grupiranja podataka temelji se na postaji. Za danu postaju prikazuju se svi dostupni parametri, uz mogućnost dodavanja i usporedbe dvaju različitih parametara, odnosno izmjerenih vrijednosti na istom grafikonu. Vrijednosti potrebne za iscrtavanje grafikona učitavaju se na korisnički zahtjev (klik na određeni parametar) u pozadini. Primjer prikaza se može vidjeti na slci 6.11.

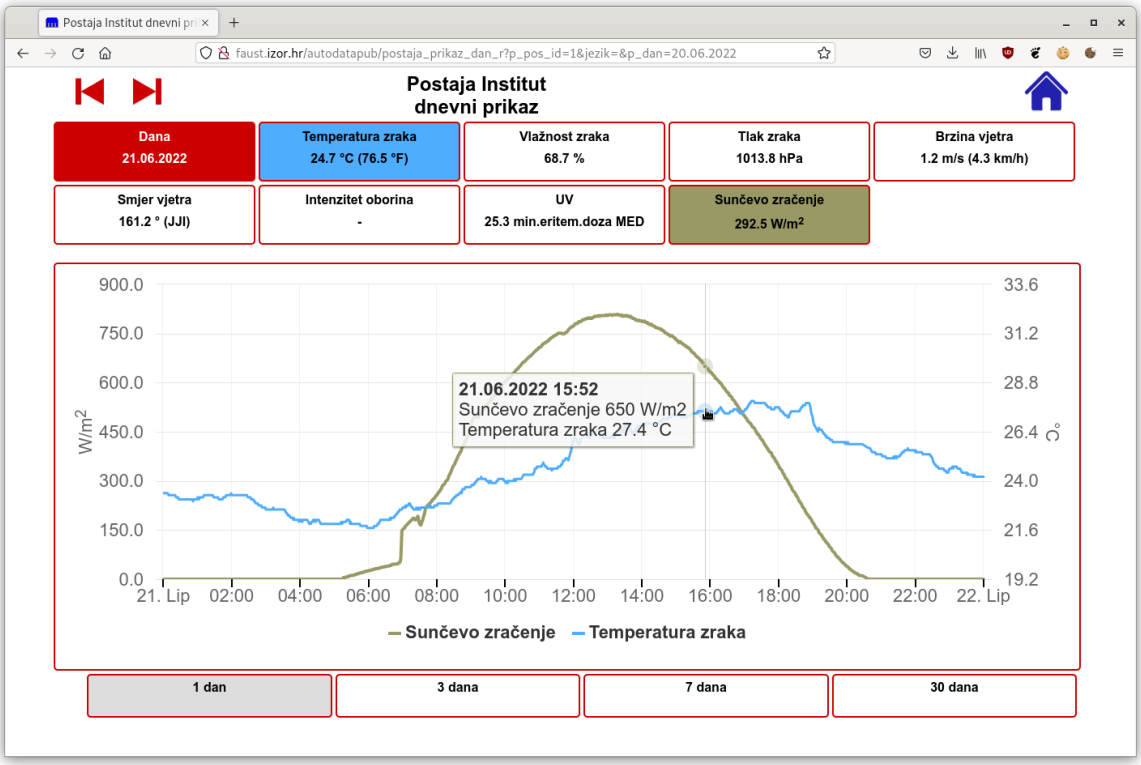

Slika 6.11: Dva parametra na grafičkom prikazu

Drugi način grupiranja podataka temelji se na parametrima. Korisnik može paralelno vidjeti sve vrijednosti za isti parametar s različitih lokacija. U ovom slučaju, graf može sadržavati više od dva niza podataka jer se koristi samo jedna zajednička os y. Vrijednosti bi trebale biti označene bojama i po mogućnosti povezane s kartom 6.12.

Korisnik bi jednostavno trebao birati razdoblje za koje se prikazuje grafički prikaz. U našem primjeru se osim standardnog razdoblja od 24 sata, može odabrati i 6 sati ili 7 ili 30 dana,

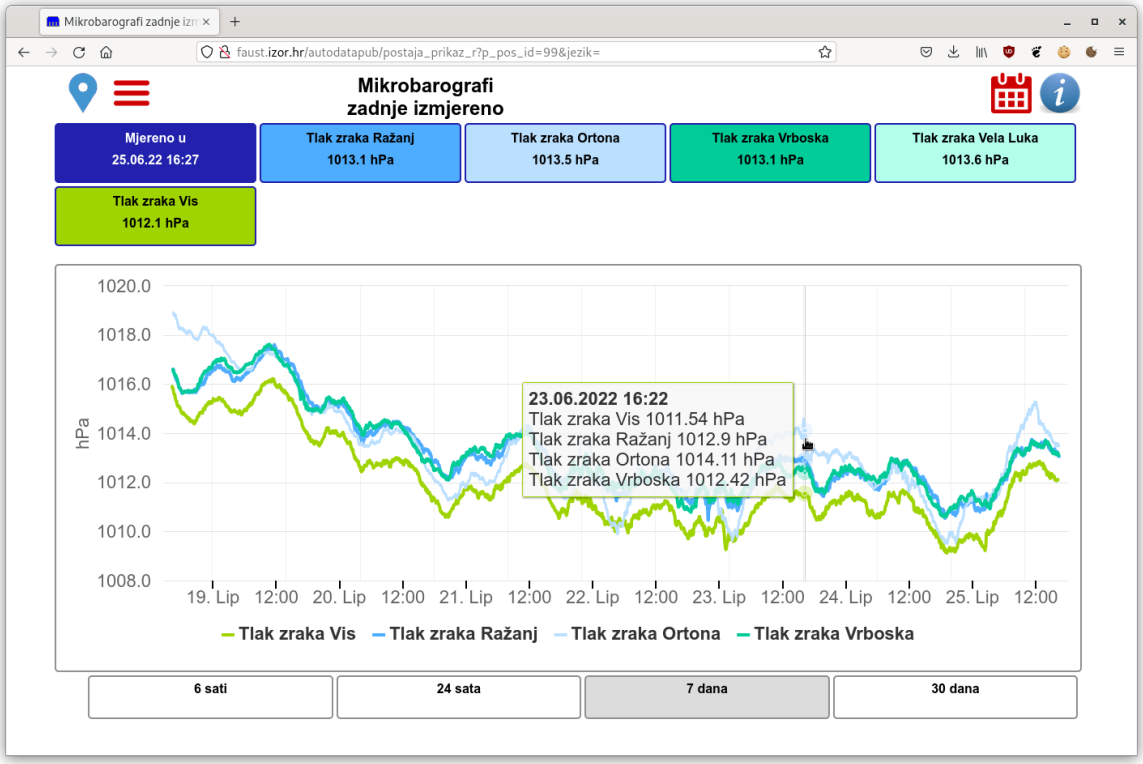

Slika 6.12: Tlak zraka s mreže mikrobarografskih postaja

6.5.6. Prikaz podataka kao prostornog sloja

Podatci s automatskih mjernih sustava mogu se prikazati i u formi prostornog sloja. Za primjer ovakvog prikaza bolje će poslužiti podatci s visokofrekfentnog para radara za mjerenje površinskih struja. Ovaj sustav kontinuirano mjeri, a rezultat je svakih pola sata polje površinskih struja te visine i smjera valova. Na slici 6.13 vidimo primjer takvog prikaza. Prostorni slojevi su zamišljeni kao statični. Automatska mjerenja se periodično ponavljaju i nužno je napraviti kontrolu odabira scena za prikaz. Moderni mrežni GIS ima obično implementirane kontrole za vremenske nizove, odnosno serije varijanti istog sloja. Problem kod standardnih kontrola je taj što ne postoji mogućnost razlikovanja scena na popisu. Uz posebne kontrole lakše je pronaći posebne i ekstremne scene. U našem prikazu je ispod standardnih kontrola za upravljanje prikazom slojeva, dodana vremenska kontrola s kalendarom i prikazom tablice scena za pojedini dan. Tablica je obojena u skladu s popunjenošću prostornog polja uz prikaz srednjeg vektora za cijelu scenu. Dodatno je indicirana prisutnost sloja smjera valova.

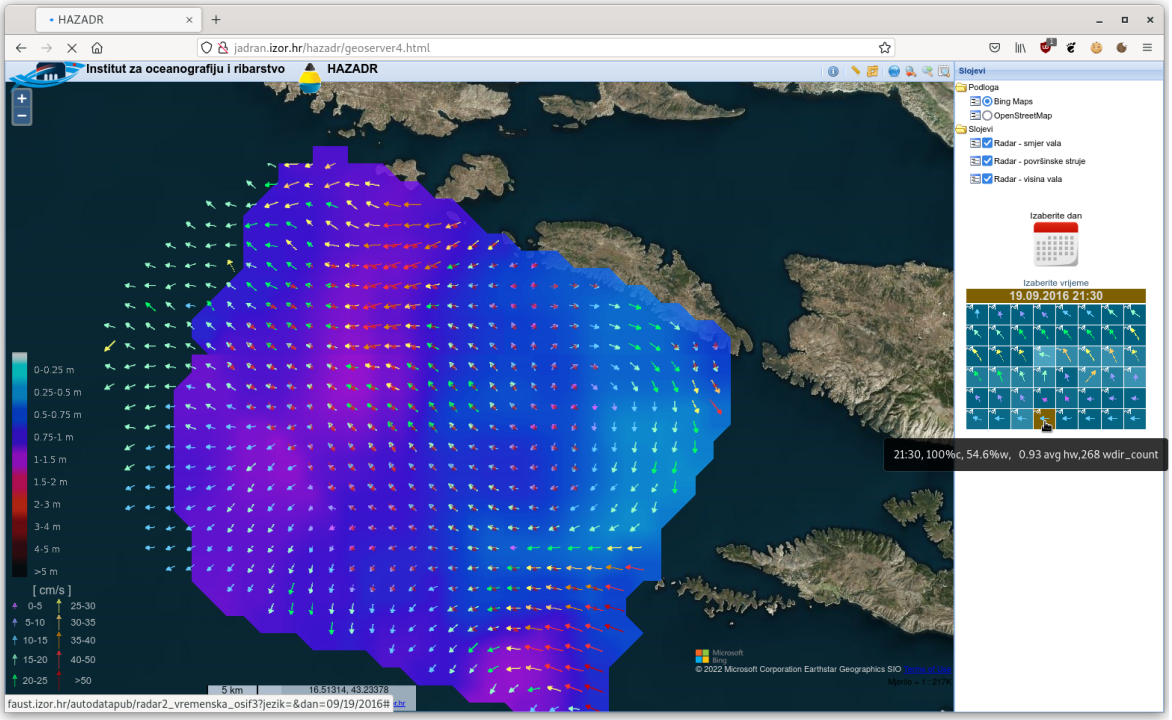

Slika 6.13: Prikaz mjerenja VF radara kao prostorni sloj

6.5.7. Upravljanje događajima

Kod automatskih mjernih sustava bitno je znati trenutačno stanje nekog parametra, odnosno posljednje dostupno mjerenje. Osim tog podatka korisnici traže određene događaje, odnosno ekstremne vrijednosti. Na pitanja tipa: "Koji je dan bio najhladniji u nekom mjesecu?", odgovor lako možemo naći uz odgovarajuću vizualizaciju podataka. Ovdje treba razlikovati "najhladniji dan" u smislu najniže prosječne temperature, od dana kada je izmjerena najniža temperatura. U svrhu lakog pronalaženja događaja i ekstrema koriste se posebne prilagođene vremenske osi. Na slici 6.14 prikazan je primjer vremenske crte u formi prilagođenoga kalendara. Raspon boja je prilagođen parametru i mjesecu u kojem je mjeren. Moguć je izbor četiriju statističkih parametara za dnevna mjerenja:

- srednja vrijednost,
- maksimum,
- minimum,
- standardna devijacija.

Kombiniranjem ovih četiriju statističkih parametara može se dobiti uvid u varijabilnost i kretanje određenog parametra unutar promatranog mjeseca.

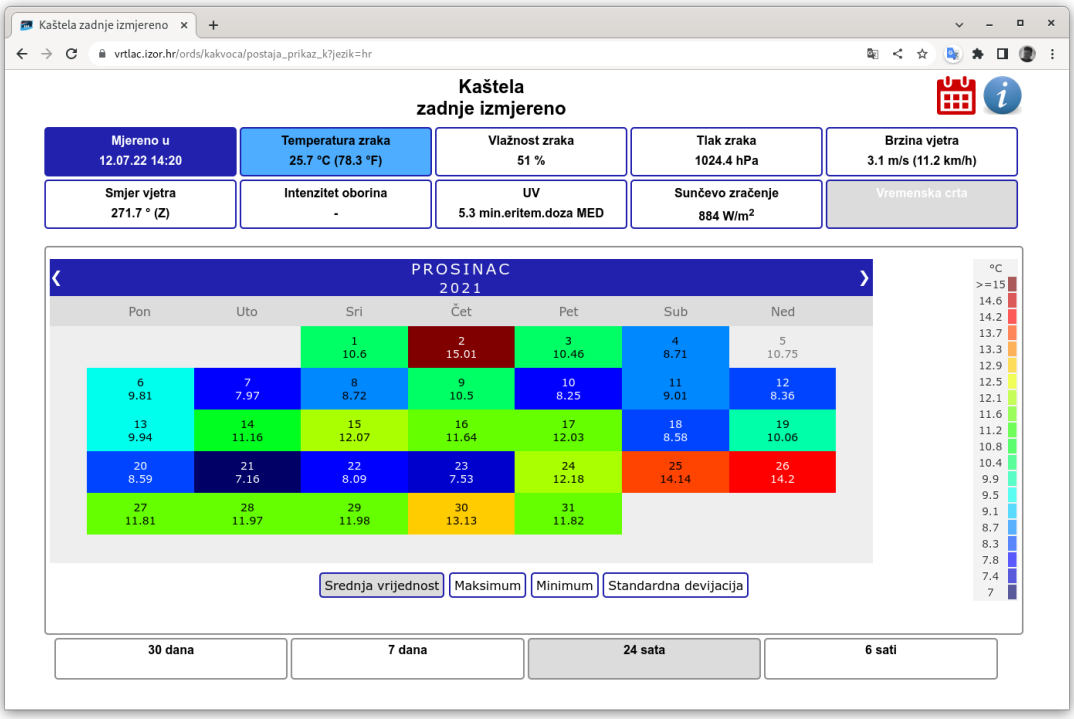

Slika 6.14: Primjer prilagođene vremenske crte na prikazu automatski mjerenih podataka

U slučaju kada imamo dodatno automatski detektirane neke događaje, kao što su vrtlozi u polju površinskih struja (slika 6.15), onda te događaje također možemo prikazati na prilagođenoj vremenskoj crti. Svaki element na ovim prilagođenim vremenskim osima poveznica je na prikaz u ovom slučaju dnevnih podataka.

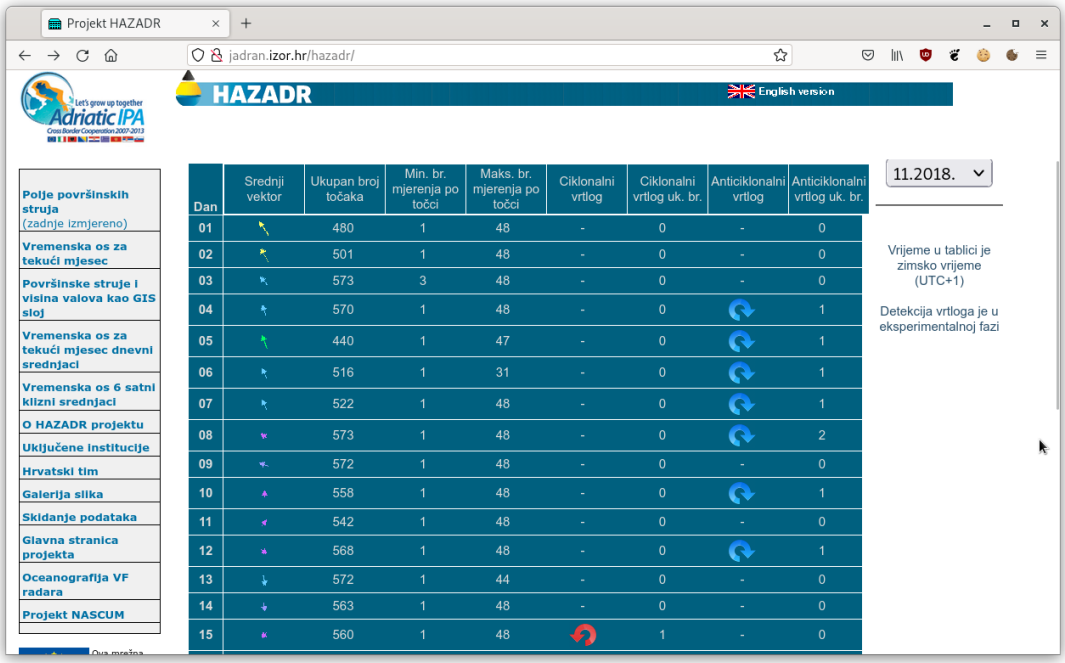

Slika 6.15: Vremenska crta s prikazom detektiranih vrtloga unutar dnevnih srednjaka polja površinskih struja

Kada želimo prikazati varijabilnost nekog parametra na manjoj vremenskoj skali, recimo za svaki sat vremena, onda mjesečne podatke oblikujemo u zbijenu tablicu s dvjema informacijama unutar svakog polja: sama srednja vrijednost kodirana bojom (i prikazana na prelazak miša) i broj koji pokazuje raspon promjena parametra za taj sat. Primjer ovakvog prikaza može se vidjeti na slici 6.16.

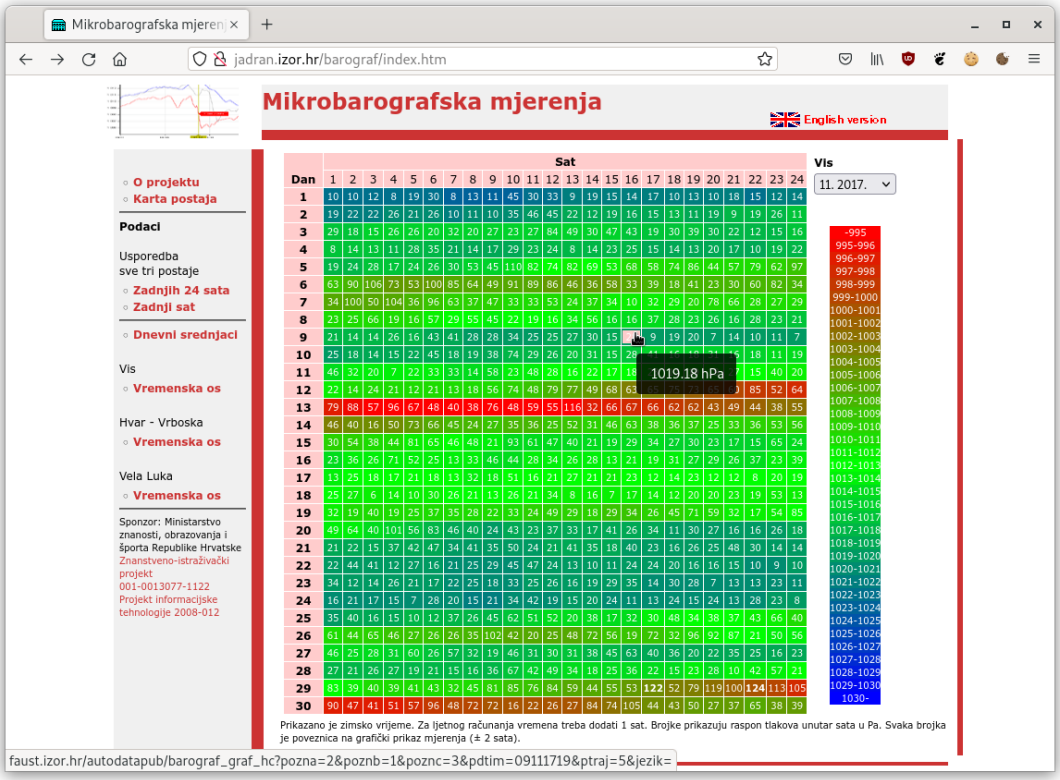

Slika 6.16: Vremenska crta sa satnim vrijednostima

6.5.8. Korisničke postavke

Većina korisnika prati podatke i mjerenja s lokalne mjerne postaje. Važno je omogućiti korisnicima da spremaju željene lokacije i skoče izravno na stranicu postaje prilikom sljedećeg posjeta, bez filtriranja postaja. Da bismo to postigli, moramo se koristiti kolačićima preglednika. Korištenje kolačića preglednika regulirano je europskom direktivom Opća uredba o zaštiti podataka (GDPR). Pohranjeni kolačići mogu sadržavati samo lokalnu numeričku identifikaciju pružatelja usluga mrežne aplikacije, postaja i nabrajanja parametara i mogu biti "Kolačići sameSite". U tom slučaju ne mogu se povezati s fizičkim osobama niti ih identificirati. U tom slučaju, ovi kolačići se mogu tretirati kao "strogo potrebni kolačići" koji ne zahtijevaju pristanak korisnika. U svakom slučaju, bolje je pitati korisnika o pohranjivanju preferencija i čak mu dati mogućnost pohranjivanja više od jedne željene lokacije/parametra.

6.5.9. Optimizacije učitavanja stranice

Razvojem komunikacijske infrastrukture i tehnologije brzina učitavanja sadržaja s Interneta znatno se povećala. Istovremeno su same mrežne stranice postale složene, uz više različitih komponenti (HTML, JavaScript, CSS). Korisnici su navikli na brz odgovor traženih servisa i kod malo duljeg čekanja skloni su odustati od traženog sadržaja. Pri kreiranju mrežne aplikacije potrebno je paziti na to da korisnik što prije dobije neku informaciju dok se u pozadini učitavaju ostali dijelovi stranice. Na slici 6.17 vidljiv je dio prikaza "Lighthouse" alata koji je dio Chrome preglednika. Ovaj alat analizira učitavanje i prati iscrtavanje, prikaz i mogućnost interakcije korisnika za vrijeme učitavanje pojedine stranice.

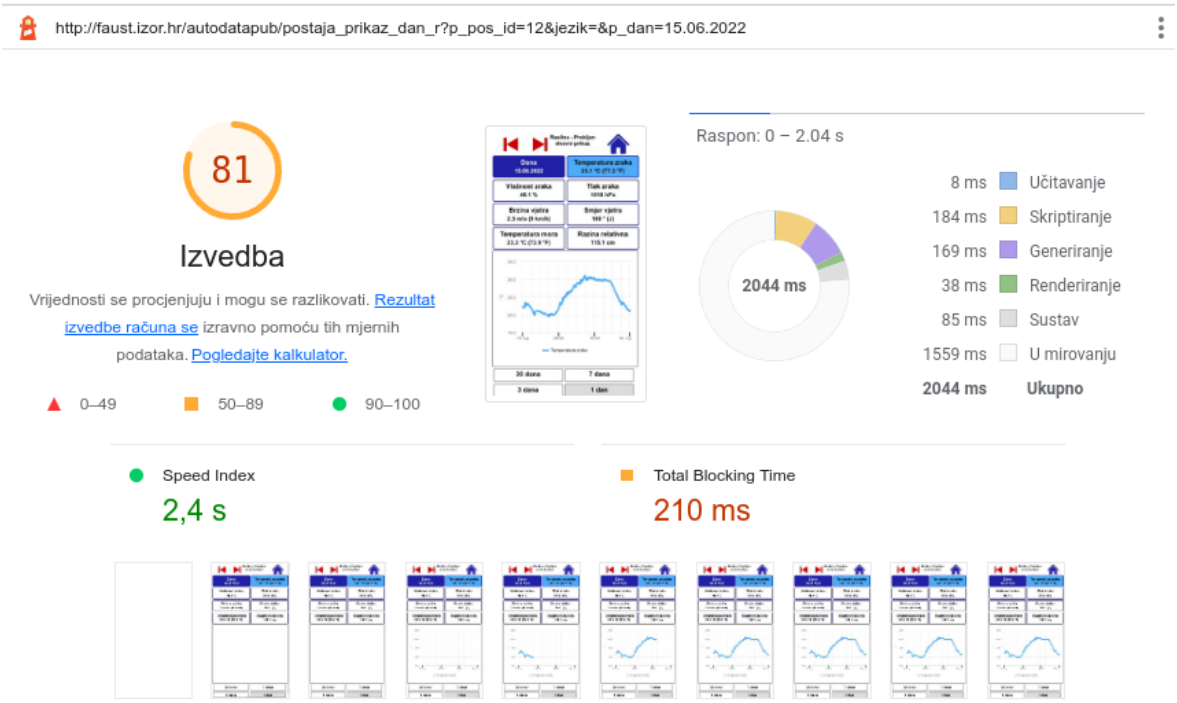

Slika 6.17: Dio prikaza "Lighthouse" alata za analizu performansa stranice preglednika Chrome

Za usporedbu stranica pljusak.com [72] putem iste konekcije na Internet i na istom računalu ima izvedbu 15 *Speed index* od 13 s i *Total Blocking Time* 1.116 ms.

Naročito su bitna dva elementa koja utječu na korisničko iskustvo: prikaz dijela stranice s nekim informacijama što ranije, i što kraće vrijeme u kojem preglednik ne reagira na korisničke akcije pri učitavanju stranice (engl. *Total Blocking Time*). Na slici je vidljivo (u dnu prikaza) da se osnovni sadržaj iscrtava vrlo brzo, nakon čega slijedi učitavanje podataka i iscrtavanje grafičkog prikaza. Isto tako preglednik je "blokiran" vrlo kratko, 210 ms, što korisnik ne uspije osjetiti kao bilo kakav "zastoj".

Da bismo postigli ovakav rezultat, bilo je potrebno primijeniti nekoliko optimizacija pri kreiranju mrežne aplikacije.

- Što više koristiti predmemoriju preglednika za "nepromjenjive" elemente mrežne stranice kao što su stilovi prikaza (CSS) i JavaScript biblioteke.
- Nakon učitavanja stranice prvo se učitava JSON s posljednjim izmjerenim podatcima s neke mjerne postaje. Podatci se zatim ispisuju na stranicu dinamički. Ovo je u većini slučajeva najbitnija informacija koja zanima korisnika.
- Zatim se učitavaju podatci za određeni parametar i za određeno razdoblje (to je obično parametar i razdoblje koje je korisnik odabrao pri prošlom posjetu).
- Na kraju se iscrtava grafički prikaz koji prikazuje kretanje vrijednosti određenog parametra tijekom određenog vremena.

6.6. Rezultati

Automatski mjerni sustavi na Institutu za oceanografiju i ribarstvo bili su i jesu dio više različitih znanstvenih projekata (NASCUM [73], HAZADR [74], ISPNDJ [75], MESSI [76], POZOR [77], CHANGE WE CARE [78], RESPONSe [79], ECOSS [80]). Prikaz podataka je integralni dio sustava, a dobra vizualizacija podataka pomaže znanstvenicima u boljem sagledavanju mjerenih parametara i pojava. Osim znanstvenika, korisnici sustava su i zainteresirani građani, koji redovito prate naše prikaze podataka s automatskih mjernih sustava. Od uspostave sustava bilježimo prosječno oko 1100 pristupa mjesečno (od srpnja 2017. do kolovoza 2022.) I od jednih i drugih dobili smo pozitivne reakcije što nas je potaklo na daljnji razvoj i optimizacije sustava. Nažalost projektno financiranje nije kontinuirano pa neki vrijedni automatski sustavi više nisu aktivni. Trenutačno nije aktivan sustav mjerenja površinskih struja i valova visokofrekventnim radarima na području između otoka Brača i Visa. Za vrijeme aktivnosti sustava (od ožujka 2014. do studenog 2019. godine) bilježili smo prosječno 9000 pristupa mjesečno. Truditi ćemo se što više zadržati i proširiti automatske mjerne sustave, kao i uspostaviti suradnju s drugim institucijama kako bismo osigurali stalan dotok ažurnih podataka.

6.7. Zaključak

Rad s podatcima u stvarnom vremenu obuhvaća široka područja inženjerstva i računalnog programiranja. Od dizajna senzora, prikupljanja podataka, prijenosa podataka, pohrane i provjere. Posebno područje je dugoročno upravljanje mjernim postajama i kalibracija senzora. Na kraju svih tih napora je "unošenje" i prezentacija podataka. Vidimo brzi razvoj, s jedne strane u senzorima i mrežama, a s druge strane u JavaScript okvirima i preglednicima i računalnim sposobnostima. Ali često je mrežna prezentacija podataka u stvarnom vremenu

zastarjela i nije intuitivna. Razlog tome je interna struktura organizacija koje vode senzorske mreže i gdje je objavljivanje podataka na mreži često marginalna aktivnost. Postoje neke specijalizirane mrežne stranice koje objavljuju podatke o okolišu, ali one su uglavnom usmjerene na različite vrste okolišnih prognoza.

Teško je pronaći dobro organiziranu mrežnu stranicu koja pruža dobar pregled podataka u stvarnom vremenu s mogućnošću pregleda i povijesnih podataka. Još je rjeđa mogućnost usporedbe modeliranih prognostičkih vrijednosti sa stvarnim izmjerenim vrijednostima.

U Institutu za oceanografiju i ribarstvo imamo dugu tradiciju mjerenja u stvarnom vremenu i objavljivanja podataka u stvarnom vremenu na mreži gdje smo ostvarili novo rješenje znatno učinkovitije od postojećih. Dizajniran je i implementiran sustav za prikaz podataka mjerenja koji omogućava upravljanje vrstom grafa i parametrima prostor-vrijeme. Optimizirani su procesi pohrane i dohvata podataka i omogućeno je lako i poluautomatsko pronalaženje zanimljivih situacija u podatcima.

Znanstvenici Instituta i suradničkih institucija na projektima lakše su i učinkovitije pronalazili zanimljive situacije. Uz to smo dobivali pozitivne povratne informacije od "običnih" korisnika (šira javnost), koji su rado posjećivali naše mrežne stranice. Prvi rezultati i mrežna stranica pokrenuti su 2000. godine. Glavni problem je pronaći sredstva za upravljanje postajama (aktivnosti su projektne bez trajno financirane usluge). Posljednji primjer mrežne vizualizacije naših podataka u stvarnom vremenu možete pronaći ovdje: `http://faust.izor.hr/autodatapub/postaje`

7. PRIKAZ REZULTATA NUMERIČKIH MODELA

Ovo poglavlje je prevedena i proširena verzija rada s IEEE konferencije Oceans 2019. u Marseilleu [81]. Rad je usmeno prezentiran u sekciji "Ocean Data Visualization, Modeling, and Information Management".

Sposobnost interaktivnog prikaza i analize rezultata prognostičkog modela AdriSC – kao i mjerenja u stvarnom vremenu na različitim lokacijama duž hrvatske obale, smatrala se ključnom za razvoj sustava ranog upozoravanja na meteocunami te je zajedno stvoreno namjensko web sučelje za model. Ovo poglavlje opisuje razvoj interaktivne mrežne aplikacije (`http://www.izor.hr/adrisc`) razvijene u svrhu vizualizacije rezultata modela i mjerenja u stvarnom vremenu.

7.1. Područje istraživanja

Sustav za prognozu meteocunamija Jadranskog mora i obale (AdriSC) koji je razvijen za operativno predviđanje meteocunamija – atmosferski generiranih destruktivnih oceanskih valova u frekvencijskom pojasu cunamija u Jadranskom moru. Izazovi koje predstavlja modeliranje meteocunamija prvo se razmatraju, zatim se detaljno prikazuje postavka AdriSC Meteotsunami Forecast sustava i na kraju se rezultati modela atmosfere i oceana ocjenjuju prema 48 senzora tlaka zraka i 19 mjerača plime i oseke za šest različitih događaja meteocunamija. Statistička analiza rezultata visokofrekventnog modela otkriva da AdriSC atmosferski i oceanski modeli mogu reproducirati događaje meteocunamija, iako njihove performanse jako variraju, ovisno o događaju i mjestu promatranja. Kvalitativna analiza rezultata visokofrekventnog modela karata ekstremne razine mora i srednjeg tlaka na razini mora pokazuje da čak i blagi pomak lokacije (reda od 1 do 10 km) atmosferskih poremećaja, odgovornih za stvaranje meteocunamija, rezultira u nesposobnosti oceanskih modela da reproduciraju opažene poplave koje su se dogodile tijekom događaja meteocunamija. Studija u sklopu razvoja AdriSC modela predstavlja prvu dostupnu temeljitu procjenu determinističkog sustava prognoze meteocunamija. Kao takav, utvrđuje da se pažljivo zamišljeni sustav modeliranja, čak i ako je nesavršen, može implementirati za reprodukciju i predviđanje događaja meteocunamija [82].

“Adriatic Sea and Coast (AdriSC)“ združeni je sustav atmosferskih i oceanografskih modela u Jadranu razvijen u okviru dvaju istraživačkih projekata Instituta za oceanografiju i

ribarstvo: (1) projekt MESSI, s ciljem istraživanja i prognoze jadranskih meteoroloških cunamija, te (2) projekt ADIOS, s ciljem boljeg razumijevanja međudjelovanja Jadrana i Jonskog mora na međugodišnjoj i dekadnoj vremenskoj skali te utjecaja na dinamiku obalnog i otvorenog dijela Jadrana.

AdriSC združeni modelarski sustav sastoji se od dvaju modula: (1) osnovni modul temelji se na COAWST modelarskom sustavu, a koji se sastoji of atmosferskog modela WRF horizontalne rezolucije 3 km iznad Jadrana i ROMS oceanografskog modela (https://www.myroms.org) horizontalne rezolucije 1 km (u plavom okviru na slici 7.1), te (2) naprednog modula koji se sastoji of atmosferskog modela WRF horizontalne rezolucije 1.5 km i ADCIRC oceanskog modela (https://adcirc.org) promjenjive horizontalne rezolucije od 10 metara u obalnom području, uvalama i lukama, do 5 km u dubokim dijelovima Jadrana (u crvenom okviru na slici 7.1).

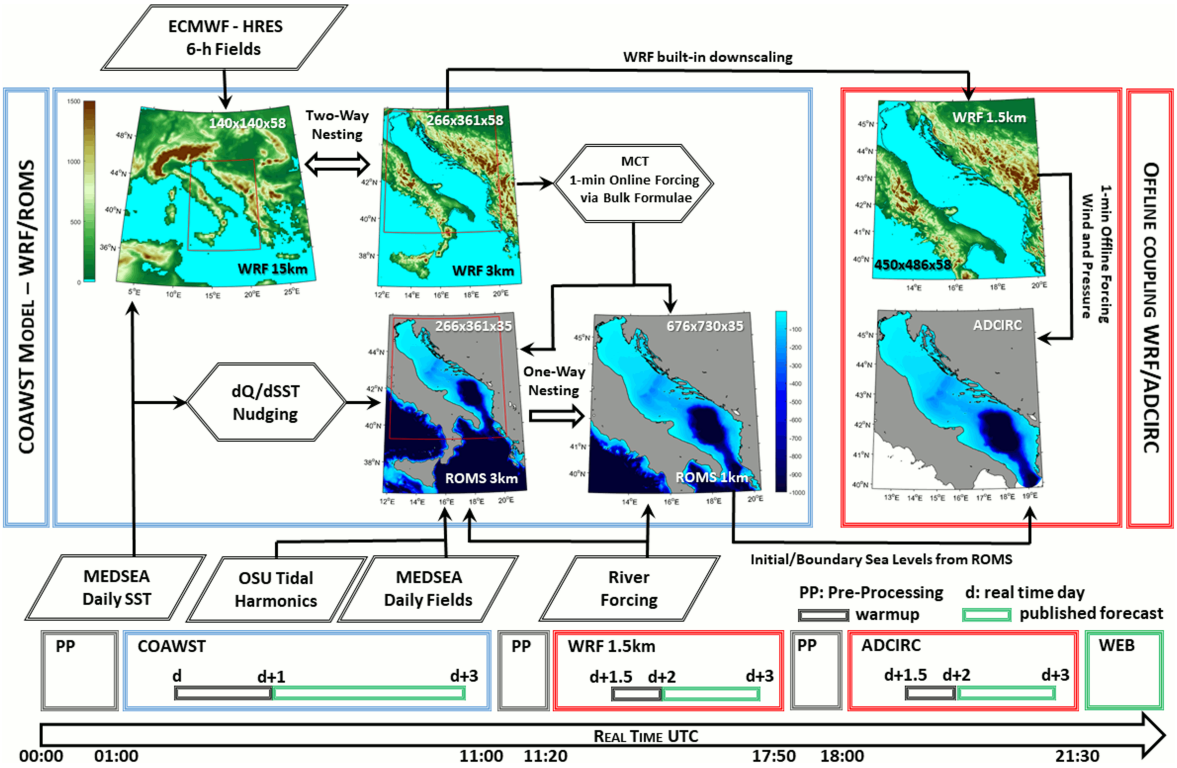

Slika 7.1: Operativna shema AdriSC prognoze meteoroloških cunamija

Na slici 7.1 gornji dio slike opisuje dijagram tijeka združivanja između pojedinačnih modela (COAWST u plavom okviru, WRF/ADCIRC u crvenom okviru), njihovih mreža i domena (uz ucrtanu topografiju kopna i batimetriju mora). Donji dio slike prikazuje izvršavanje pojedinih segmenata prognostičkog sustava u vremenu gdje process započinje u 00:00 UTC i obavlja prognozu od dana d do d+3.

7.2. Ciljevi istraživanja

Rezultate modela bilo je potrebno vizualizirati. Uz prethodna iskustva s vizualizacijom podataka s automatskih mjernih sustava, i analizu podataka, izbor je opet bio na relacijskoj bazi i aplikacijskom serveru. Dodatni motiv nam je bio razviti novi način vizualizacije, bez potrebe za unaprijed kreiranim prostornim slojevima. Osim toga, jedan od zahtjeva je bio i da se realizira prilagodljiv prikaz gdje su boje i rasponi podataka prilagođeni svakoj posebnoj sceni koju korisnik odabere, a ne svim raspoloživim podatcima. Ovo je posebno bitno kada se uzme u obzir razvedenost istočne obale Jadranskog mora gdje se na malim područjima mogu pojaviti veliki gradijenti u modeliranim parametrima.

Poslije uspostave modela i analize seta podataka koje oni generiraju, definirani su ciljevi istraživanja, odnosno zahtjevi koje naša vizualizacija treba zadovoljiti.

- Rješenje treba osigurati što jednostavnije i intuitivno korisničko sučelje. Sučelje treba biti sukladno sa standardnim sučeljima mrežnih GIS prikaza, omogućiti izbor parametara (slojeva), preklapanje skalarnih i vektorskih slojeva, zumiranje i pomake u prostoru i vremenu.

- Učitavanje i prikaz rezultata modela treba dovoljno kratko trajati za ugodno korištenje.

- Rasponi prikazanih veličina trebaju biti prilagođeni korisničkom odabiru područja. To znači da ako koristimo za prikaz 20 različitih boja, a raspon npr. razina mora je 40 cm za cijelo područje modela, onda jedna boja "pokriva" raspon od 2 cm. Ako korisnik zumira neko područje unutar kojega je oscilacija razine 10 cm, onda rezolucija prikaza postaje 0,5 cm i moguće je vidjeti finije promjene u vrijednostima prikazanog parametra za traženo područje.

7.3. Postojeća rješenja

Meteo.hr stranica Državnoga hidrometeorološkog zavoda sadrži prikaz rezultata Aladin meteorološkog modela. Prikaz je realiziran kao statična slika relativno niske rezolucije (800 puta 680 piksela) koja sadrži osnovnu kartu u pozadini preko koje je iscrtana prostorna interpolacija rezultata modela u fiksnoj rezoluciji. Prikaz nije interaktivan. Napravljena je vremenska animacija koja se sastoji od prikaza niza slika. Na slici 7.2 prikaz je temperature zraka i vjetra za splitsko područje.

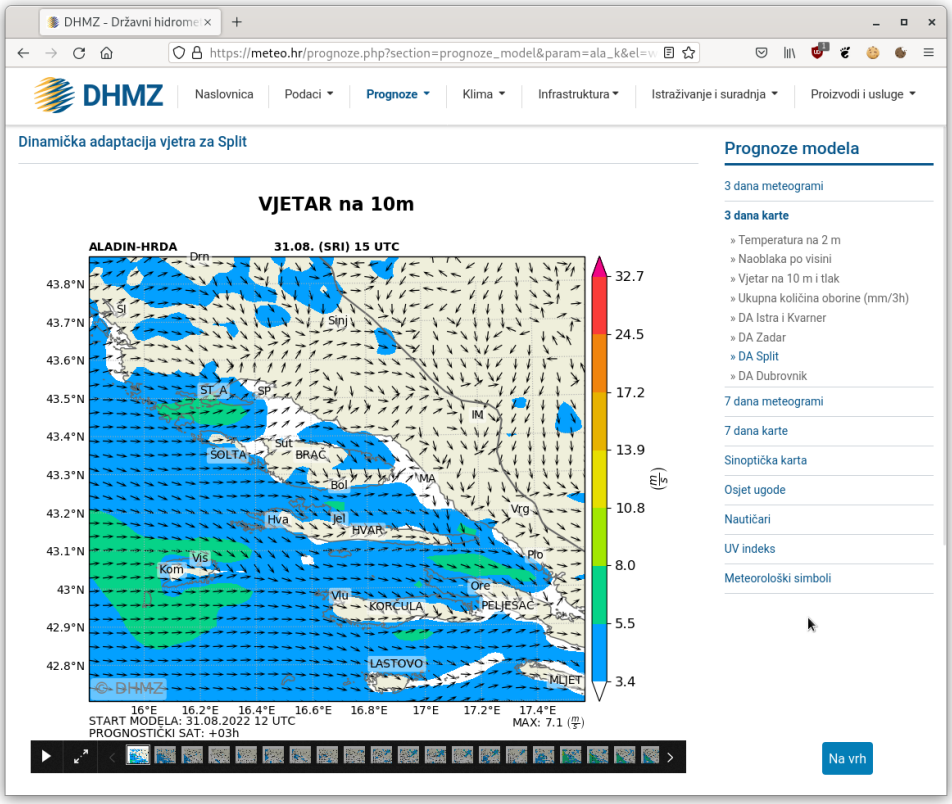

Slika 7.2: Prikaz rezultata modela sa stranice meteo.hr [83] polja

Weather Underground je komercijalna meteorološka usluga koja putem Interneta pruža informacije o vremenu u stvarnom vremenu. Weather Underground nudi vremenska izvješća za većinu velikih gradova diljem svijeta na svojoj mrežnoj stranici, kao i lokalna vremenska izvješća za novine i stranice trećih strana. Podatke prikuplja od Nacionalne meteorološke službe Sjedinjenih Američkih Država (NWS) s više od 250 000 osobnih meteoroloških postaja. Mrežna stranica je dostupna na mnogim jezicima, a pretplatnici mogu pristupiti verziji stranice bez oglasa s dodatnim značajkama uz godišnju naknadu. Stranica je fokusirana na numeričke podatke s mjernih postaja uz koje su još dostupni i prostorni slojevi meteoroloških radara (padaline), satelitskih snimaka (naoblaka), meteoroloških fronta i dinamička prezentacija vjetra. Prikaz je realiziran kao mrežna interaktivna karta (moguća su zumiranja i promjene područja prikaza). Prostorni slojevi se sastoje od unaprijed pripremljenih rasterskih slika fiksne rezolucije. Podatci s mjernih postaja iscrtani su kao oznake na karti. Na slici 7.3 prikaz je radarskog sloja i podataka o temperaturi i vjetru s mjernih postaja.

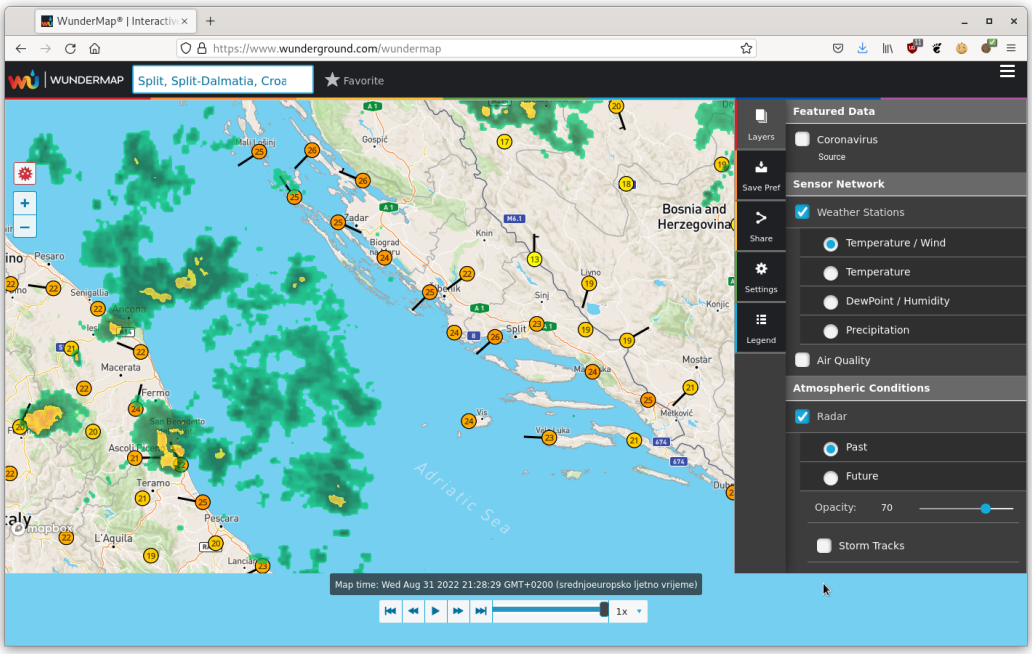

Slika 7.3: Prikaz rezultata radarskih mjerenja uz meteorološke mjerne postaje na prikazu wundermap [84]

Windy servis za prikaz vremenskih prognoza je komercijalna mrežna stranica specijalizirana za prikaz rezultata numeričkih modela. Geovizualizacija oceanografskih podataka na mreži je također moguća korištenjem "dinamičkih čestica" (engl. *dynamic particles*). J. Kim u svom radu opisuje njihovo korištenje pri vizualizaciji oceanografskih parametara na mreži [85]. Dinamičke čestice su dodani animirani elementi na kartografskom prikazu koji prikazuju dinamiku određenog parametra (vjetar, valovi, površinske struje). Ova animacija se realizira na mreži s pomoću biblioteka otvorenog koda i standarada: HTML5, WebGL, Canvas, D3, i Leaflet. Sama ideja je potekla iz potrebe za modernijim, intuitivnijim i interaktivnijim prikazima parametara koji se tijekom vremena mijenjaju u prostoru. Jedan od servisa koji se koristi ovom tehnikom je i Windy. Windy je češka tvrtka koja na mrežnoj adresi windy.com pruža globalni prikaz vremenskih prognoza. Animacije vjetra razvijene su korištenjem projekta otvorenoga koda Camerona Beccaria "earth".

Na osnovnom prikazu na karti bojom je kodirana brzina vjetra preko čega je animirano "kretanje" vjetra. Na dnu kartografskog prikaza je vremenska traka za odabir vremena prikaza. Ispod je grafički prikaz vremenske prognoze za željenu lokaciju i dodatno podatci s obližnjih meteoroloških postaja.

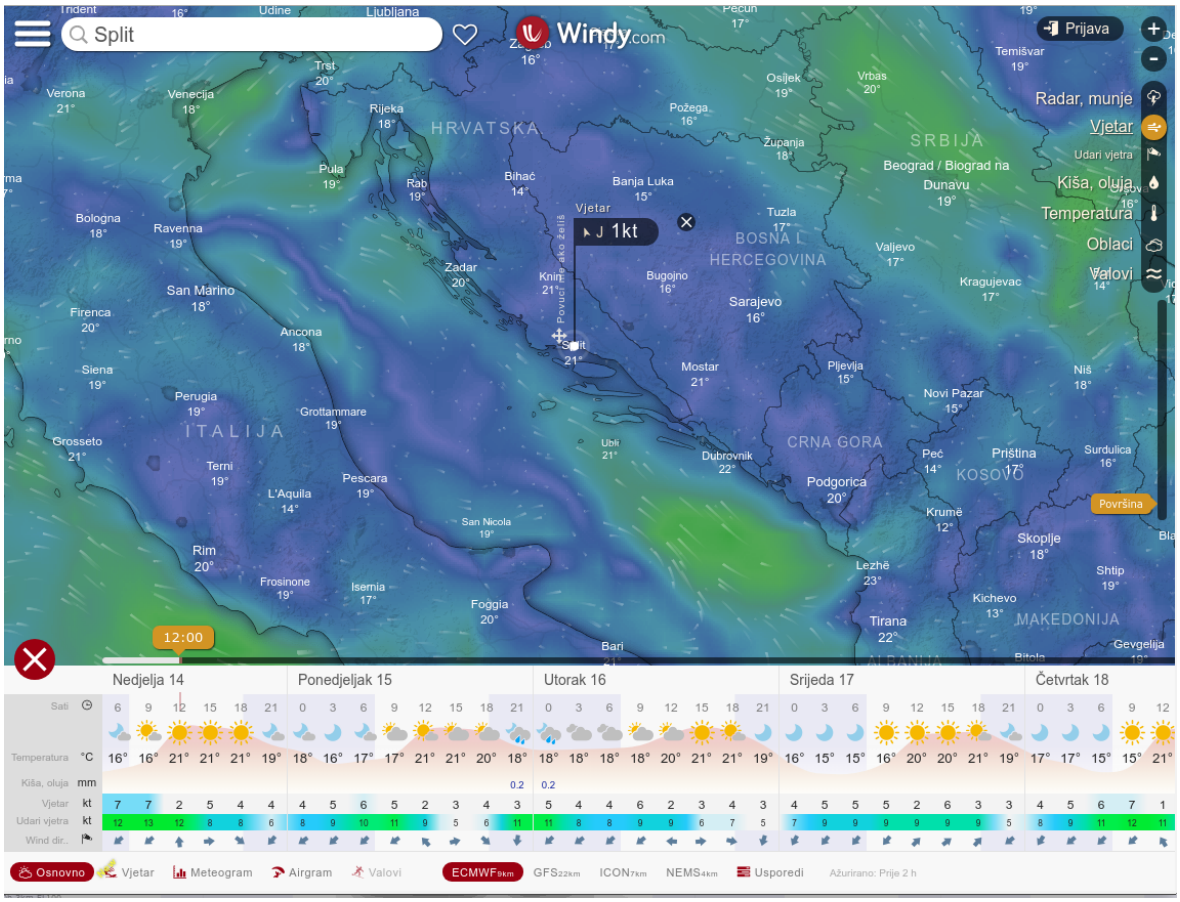

Slika 7.4: Osnovni prikaz prognoze vremena sa stranice windy.com [86]

Osim osnovnog sloja koji prikazuje brzinu vjetra, dostupni su i slojevi: radar/munje, kiša/oluja, temperatura, oblaci, valovi, valovi mrtvoga mora i temperatura mora. Osim kartografskih i prikaza prognoza, dostupni su grafički prikazi podataka s mjernih postaja. Isto tako, osim osnovne animacije vjetra, dostupna je i animacija valova.

Stranica windy.com je u potpunosti realizirana korištenjem JavaScript programskog jezika. Svi elementi na stranici su kreirani i nacrtani putem JavaScripta. Glavni JavaScript kôd stranice je komprimiran (iz koda su izbačeni nepotrebni razmaci i prekidi linija potrebni za lakše čitanje koda) i sastoji se od gotovo dvije stotine tisuća znakova. Glavni dio koda je zaštićen autorskim pravima, ali sadrži i pojedine dijelove koda (biblioteke) drugih autora prenesene uz korištenje licencije MIT. Za prikaz osnovne kartografske podloge koristi se OpenstreetMap sloj uz korištenje LeafLet biblioteke. Kod prikaza morskih parametara osnovni sloj je "iznad" sloja koji opisuje parametar (npr. temperatura mora), i time je elegantno riješen problem modelarskog sloja koji se u potpunosti ne poklapa s obalnom linijom. Na stranici postoje kontrole za podešavanje prostornog prikaza, a isto tako postoje i kontrole za odabir vremena prikaza (odabir scene). Slojevi meteoroloških parametara unaprijed su pripremljeni za različite rezolucije prikaza. Zumiranje nije ograničeno, ali pri većem zumu (prikaz malog područja) više nije vidljiv sloj parametra. Karta je i interaktivna tako da se klikom na kartu dobije numerička vrijednost iz najbližeg čvora modela za prikazani parame-

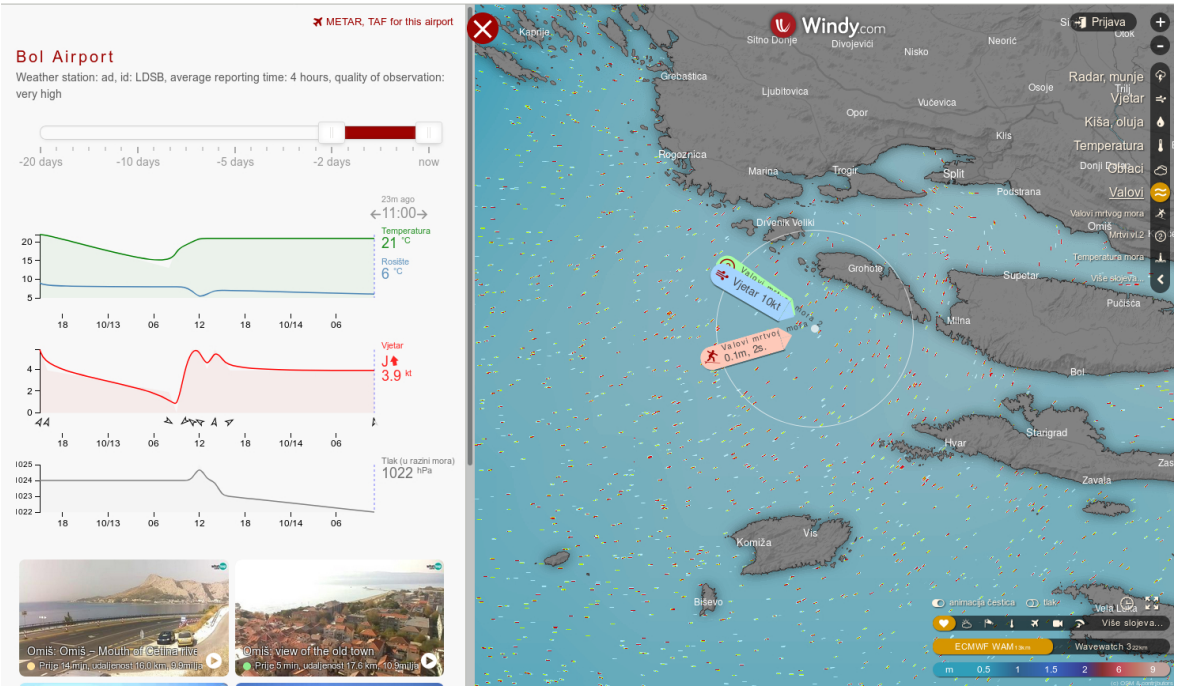

Slika 7.5: Prikaz valova i podataka s mjernih postaja sa stranice windy.com [86]

tar. Osim podataka iz modela, dostupni su i podatci s meteoroloških postaja, kao i slike s mrežnih kamera. Podatci s postaja se dinamički učitavaju korištenjem JSON formata, i zatim se vizualiziraju s klijentske strane.

Stranica koristi neke od najkompleksnijih i najnaprednijih metoda vizualizacije podataka putem JavaScripta. Korisniku su dostupne mnoge opcije i kontrole. U pozadini stranice su velike količine korištenih podataka iz numeričkih modela i iz dostupnih meteoroloških postaja. Stranica je dobar primjer što se sve može prikazati korištenjem javno dostupnih podataka. Nedostatak je taj što stranica zahtijeva određeno vrijeme navikavanja korisnika i učenje korištenja svih dostupnih kontrola. Stranica je isključivo prognostički orijentirana, odnosno nije moguće birati vrijeme izvan trenutačnog dana i dostupnih prognoza (idućih pet dana). Za mjerne postaje dostupni su podatci za prethodnih 20 dana do trenutačnog dana. Nije moguće grafički ili numerički usporediti prognozirane i mjerene vrijednosti

7.3.1. Usporedba svojstava postojećih rješenja

Opisane mrežne stranice, odnosno servisi za prikaz podataka, svakodnevno su korišteni i poznati u javnosti. Po obujmu prikaza podataka lokalni su (Meteo.hr) i globalni (Weather Underground i Windy.com). Zajedničko im je da omogućuju vizualizaciju na kartografskom prikazu prostorno-vremenskih podataka. Dodatno sva tri servisa omogućuju animacije vremenskih serija podataka.

U tablici 7.1 nabrojena su neka napredna svojstva prostornih mrežnih prikaza i njihova korelacija s opisanim postojećim rješenjima. Može se uočiti da prikaz Meteo.hr ima najmanje naprednih mogućnosti, dok je Windy.com u ovom popisu najnaprednije rješenje. Svi

Tablica 7.1: Svojstva postojećih rješenja.

Ime	**Interaktivna karta**	**Vrijednosti s proizvoljnog mjesta na karti**	**Prilagodljiv prikaz zumiranom području**	**Iscrtavanje prostornog sloja**
Meteo.hr	Ne, fiksna slika	Ne	Ne	Poslužitelj
Weather Underground	Da	Ne	Ne	Poslužitelj
Windy.com	Da	Da	Ne	Poslužitelj

opisani prikazi imaju prostorne slojeve unaprijed pripremljene u obliku slike na poslužitelju i to neke fiksne i nepromjenjive rezolucije. To omogućuje funkcionalne i "lijepe" prikaze na relativno velikim područjima, ali ne pruža mogućnost uvida u finije lokalne promjene vrijednosti nekog parametra na manjem području.

7.4. Materijali i metode za realizaciju novog rješenja

Na temelju prethodnih iskustava u vizualizaciji prostorno-vremenskih podataka odlučili smo se za korištenje relacijske baze podataka i vizualizacije na strani klijenta. Takvo rješenje smanjuje količinu prenesenih podataka jer se prenose samo numeričke vrijednosti i ne traži unaprijed pripremljene slikovne vizualizacije. Samim time može se postići neograničen broj prilagodbi u vizualizaciji, što nam je bio jedan od ciljeva.

7.4.1. Obrada i tijek podataka

Najčešći postupak koji se koristi za vizualizaciju rezultata numeričkog modela je:

- generiranje statičkih figura na strani poslužitelja za svaki parametar modela i svaku scenu (za određeno vrijeme),
- kreiranju korisničkog sučelja koje učitava prikaze za pojedini parametar i vrijeme.

Pristup predstavljen u ovoj disertaciji sasvim je drukčiji jer se oslanja na korištenje relacijske baze podataka. Glavna prednost takvog pristupa je stvaranje interaktivne vizualizacije. Pritom se koristimo prednostima baza podataka jer nam one omogućuju:

- učinkovito traženje podataka.
- izdvajanje vremenskih serija u bilo kojoj točki modela,
- generiranje različitih statistika.

Ovakav pristup nam omogućuje veću interaktivnost same aplikacije za vizualizaciju. Učitavanje značajne količine podataka zahtijeva indeksiranje i optimizaciju kako bi se izbjeglo dugotrajno učitavanje podataka, a time i loše korisničko iskustvo.

Na slici 7.6 shematski je prikazan tijek podataka, od pokretanja samih modela na ECMWF poslužiteljima do pohrane u relacijskoj bazi podataka i same vizualizacije. Prikazan je i tijek podataka s automatskih mjernih sustava.

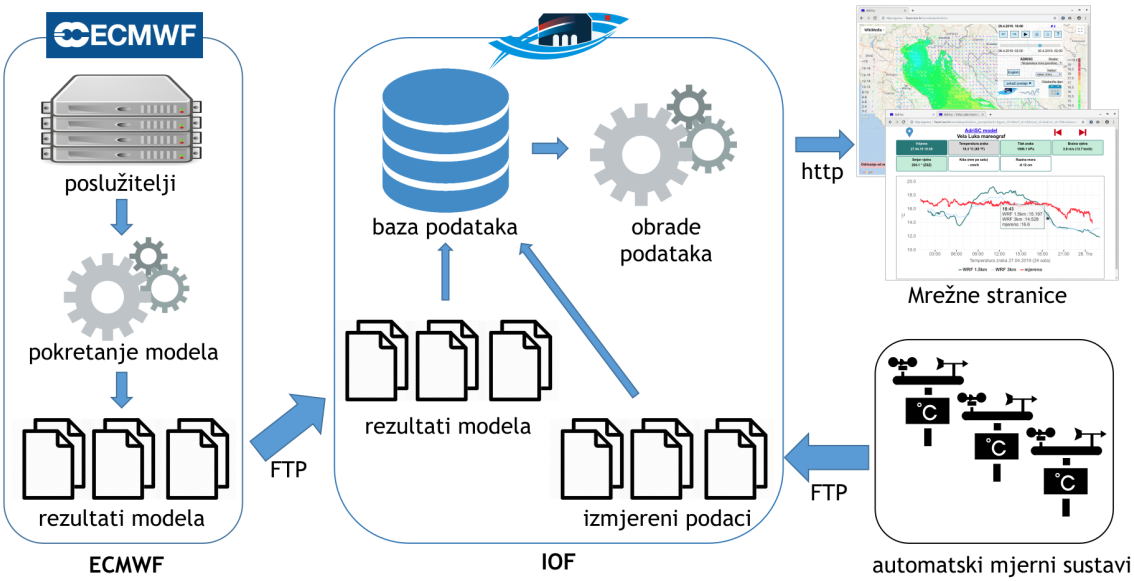

Slika 7.6: Tijek podataka

7.4.2. Dizajn baze podataka

U IOF-u se baza podataka Oracle, standardno izdanje, verzija 19.2 koristi za pohranu ekstrahiranih rezultata AdriSC modela koji se svakodnevno pohranjuju u 51 tablicu podijeljenu u sljedećih pet grupa:

- prostorne lokacije (širina i dužina) različitih mreža modela (WRF 3-km, WRF-1.5km, ROMS 1-km, ADCIRC, etc.),
- zaglavlja za svaku scenu: datum, vrijeme, vrijeme učitavanja, naziv parametra i statistika (srednja, minimalna i maksimalna),
- neobrađeni podatci za svaku scenu,
- obrađeni podatci za svaki parametar u svrhu vizualizacije - prostorno usrednjavanje, grupiranje i indeksiranje vrijednosti,
- vremenski nizovi na pojedinim modelnim "postajama".

Zbog ogromne količine podataka koji se svakodnevno generiraju i učitavaju u bazu podataka, rezultati modela stariji od 3 dana trajno se pohranjuju svakih 6 sati (umjesto svakog sata), a preostali podatci se brišu. Međutim, čak i uz ovaj postupak koji čuva samo 4 scene dnevno, procijenjena količina neobrađenih podataka o sceni mjesečno je oko 11,5

milijuna redaka za WRF 3 km, 26 milijuna redaka za ROMS 1 km i 3,9 milijuna redaka za podatke o postaji ili približno 41,4 milijuna redaka ukupno (što odgovara 496,8 milijuna redaka godišnje). S obzirom na ovu veliku količinu podataka, daljnja optimizacija, kao što je particioniranje tablice, koristi se u bazi podataka.

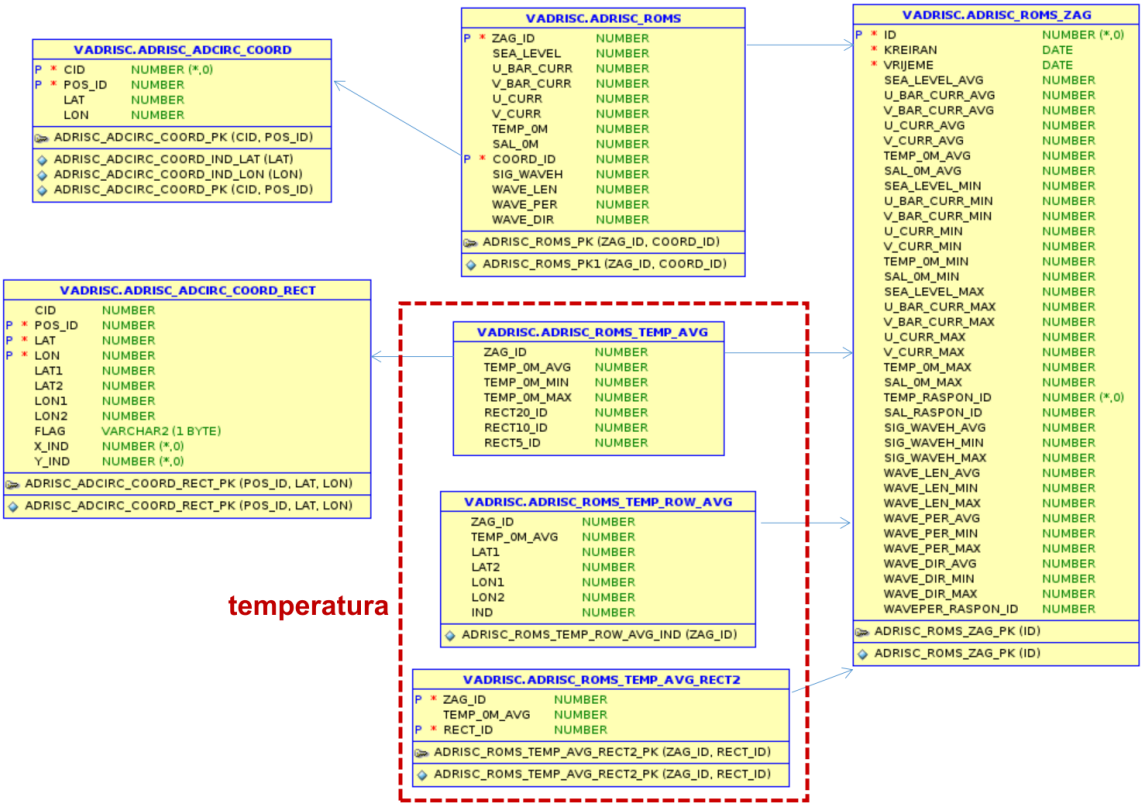

Slika 7.7: Osnovna grupa tablica

Na slici 7.7 prikazana je shema osnovnog seta tablica i njihove međusobne relacije. U crvenom okviru je set tablica za jedan od parametara (temperatura mora iz modela ROMS). Ukupno je kreirano jedanaest ovakvih grupa po tri tablice za sljedeće parametre:

1. temperatura mora (površina),
2. salinitet mora,
3. razina mora,
4. tlak zraka,
5. temperatura zraka (2 m),
6. temperatura zraka (850 mbar),
7. pokrivenost oblacima,

8. kiša (mm po satu),
9. značajna visina vala,
10. period vala,
11. duljina vala.

7.5. Implementacija

Mrežno sučelje https://www.izor.hr/adrisc oslanja se na vizualizaciju podataka temeljenu na klijentu: podatke koji se traže za vizualizaciju isporučuje poslužitelj i isporučeni podatci se „crtaju" u korisničkom pregledniku. Ovaj pristup omogućuje bolju interaktivnost jer se svaki osnovni element vizualizacije – kao što je točka na karti ili određena vrijednost u grafičkom prikazu, lako prepoznaje. Za osnovnu prostornu vizualizaciju koriste se Google map API bazirani na JavaScriptu i AJAX pozivi za dohvaćanje podataka u JSON formatu. Kako bi se optimizirala vizualizacija, prosječna polja s fiksnim rasponima prikazuju se kada je prikazano cijelo područje modela. Korisnik može povećati i zatim učitati izvornu rezoluciju modela s prilagođenim rasponom za odabrano područje. Za prikaz je dostupno ukupno 11 skalarnih slojeva i 5 vektorskih slojeva. Obje vrste slojeva mogu se uključiti i isključiti, a svaki vektorski sloj može se kombinirati s jednim od skalarnih slojeva. Osim toga, za vektorske slojeve, svaki vektor je pozicioniran u jednoj točki mreže (centrirano).

Podatci za vizualizaciju polja učitavaju se odvojeno od glavne stranice, asinkrono u pozadini.

7.5.1. Korištena tehnologija i učitavanje podataka

Oracle aplikacijski poslužitelj 11.2 – koji je optimiziran za baze podataka, koristi se kao web poslužitelj. Sustav se sastoji od dvaju dijelova: učitavanje i priprema podataka i sama vizualizacija podataka. Učitavanje je implementirano preko skripti Linux ljuske (engl. *shell*) uz korištenje vanjskih tablica i PL/SQL procedura. Vizualizacija je pisana u PL/SQL programskom jeziku za pripremu podataka uz korištenje i HTML-a (Hyper Text Markup Language) i JavaScript-a. Naknadno je sustav migriran na ORACLE 19.2 bazu podataka [68], standardno izdanje 2. U bazu podataka se podatci učitavaju etapno. Prvo se učitavaju prostorna polja morskih parametara (ROMS), zatim prostorna polja atmosferskih parametara (WRF), i na kraju podatci "virtualnih" postaja izvučenih iz modela. Virtualne postaje su rezultati modela izvučeni u lokacijama gdje postoje i stvarna mjerenja, ali u puno većoj vremenskoj rezoluciji. Same scene modela izvlače se svakih sat vremena, dok se podatci za virtualne postaje izvlače svaku minutu. Virtualne postaje su bitne za verifikaciju modela i fino praćenje i usporedbu s mjerenim rezultatima.

7.5.2. Optimizacija prikaza

Roms model za svaku scenu ima 211.140 "polja", odnosno vrijednosti za svaki od parametara (1 km rezolucija). WRF model ima 92750 vrijednosti (1,5 km rezolucija). Ovo je prevelik broj podataka za prijenos i previše zahtjevno za dinamičko renderiranje. Kako bismo smanjili broj prenesenih podataka i ubrzali iscrtavanje modela, osmisli smo način "sažimanja" podataka.

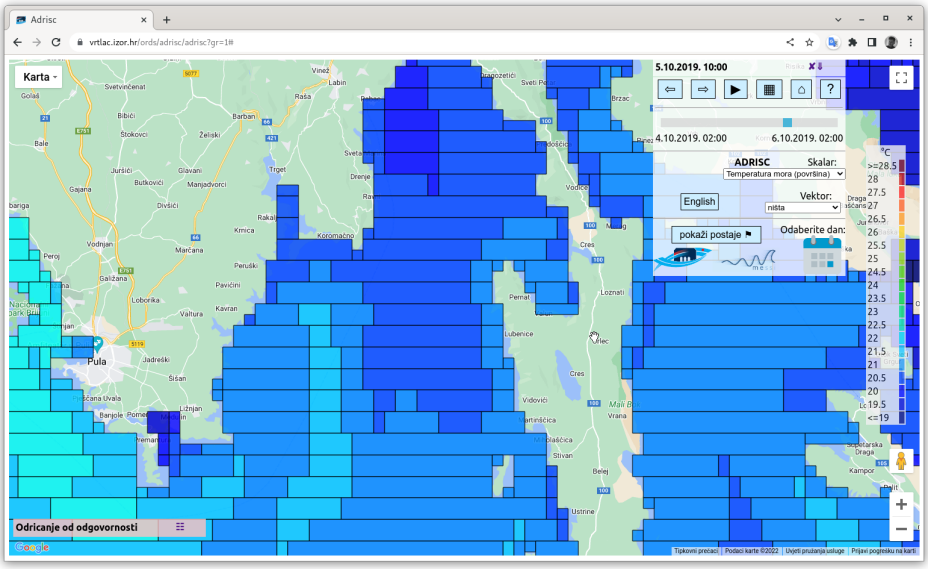

Slika 7.8: Prikaz temperature mora s vidljivom granicom polja

Sažimanje se sastoji od spajanja susjednih polja istih ili sličnih vrijednosti u veća područja. Izračunati su sezonski rasponi za pojedini parametar, podijeljeni su u kategorije i na kraju su se polja s istom kategorijom spojila u jedno.

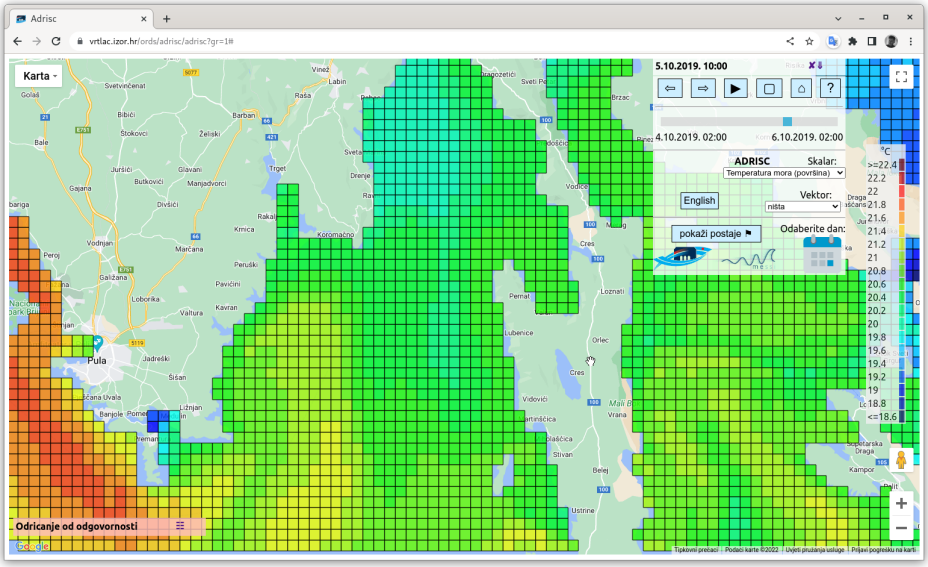

Slika 7.9: Prikaz temperature mora s pojedinačnim ćelijama

Nakon učitavanja "sirovih" rezultata modela u bazu, pokreću se procedure koje svaku scenu za pojedini parametar "sažimaju" i pohranjuju u posebne tablice. Na slici 7.8 vidljiva su polja prikaza.

Za isto zumirano područje se na slici 7.9 vide sva pojedinačna polja. Ovakav prikaz je omogućen za manja područja (veći zum) i razlikuje se od početnog i po prilagođenoj skali prikaza, za razliku od početnog prikaza koji koristi sezonsku skalu.

Ovim optimizacijama je značajno smanjen broj potrebnih elemenata za učitavanje i iscrtavanje. U tablici 7.2 dan je postotak ostatka broja polja nakon sažimanja za različite parametre (posto elemenata prikaza u odnosu na nesažeta polja). Očekivano je sažimanje bolje za parametre koji pokazuju manju prostornu varijabilnost (kao što je tlak zraka). Nakon sažimanja za sve parametre u prosjeku ostaje za iscrtavanje tek od 2 do 8 % elemenata od ukupnoga početnog broja.

Tablica 7.2: Postotci ostatka broja polja nakon sažimanja po parametrima

Parametar	Minimalno	Maksimalno	Prosječno
Temperatura mora	2,12 %	5,75 %	3,38 %
Salinitet mora	1,63 %	5,56 %	3,36 %
Razina mora	1,02 %	4,02 %	1,59 %
Visina vala	0,90 %	4,21 %	1,74 %
Temperatura zraka (2 m)	6,17 %	9,95 %	7,87 %
Temperatura zraka (850 m)	2,66 %	12,47 %	6,13 %
Tlak zraka	0,56 %	4,22 %	1,64 %

7.5.3. Učitavanje prikaza

Jedan od najvećih izazova tijekom razvoja AdriSC mrežnog sučelja bio je osigurati da se stranica učitava u razumnom vremenu.

Nakon smanjivanja broja polja sažimanjem i dalje je količina podataka za bilo koje polje modela bila oko 1 MB podataka (koje treba po zahtjevu učitati). Nakon učitavanja podataka preglednik još treba nacrtati i generirati cijelu stranicu. U praksi to znači da je uz ADSL (Asimetric Digital Subsritor Line) vezu od max 5 MB/s potrebno nešto manje od 5 sekunda za učitavanje cijele mrežne stranice. Međutim, elementi kao što su korisničke kontrole i odricanje od odgovornosti vidljivi su nakon otprilike jedne sekunde, dok pozadinska karta postaje vidljiva nakon dvije dodatne sekunde, a na kraju se prikazuje polje modela. Kao što se vidi na slici 7.10, većina vremena se troši na skriptiranje. Cijela stranica je responzivna i može se koristiti i s mobilnim uređajima – kao što su pametni telefoni ili tableti zato što su performanse postignute korištenjem mobilne 4G veze slične onima dobivenim s ADSL-om.

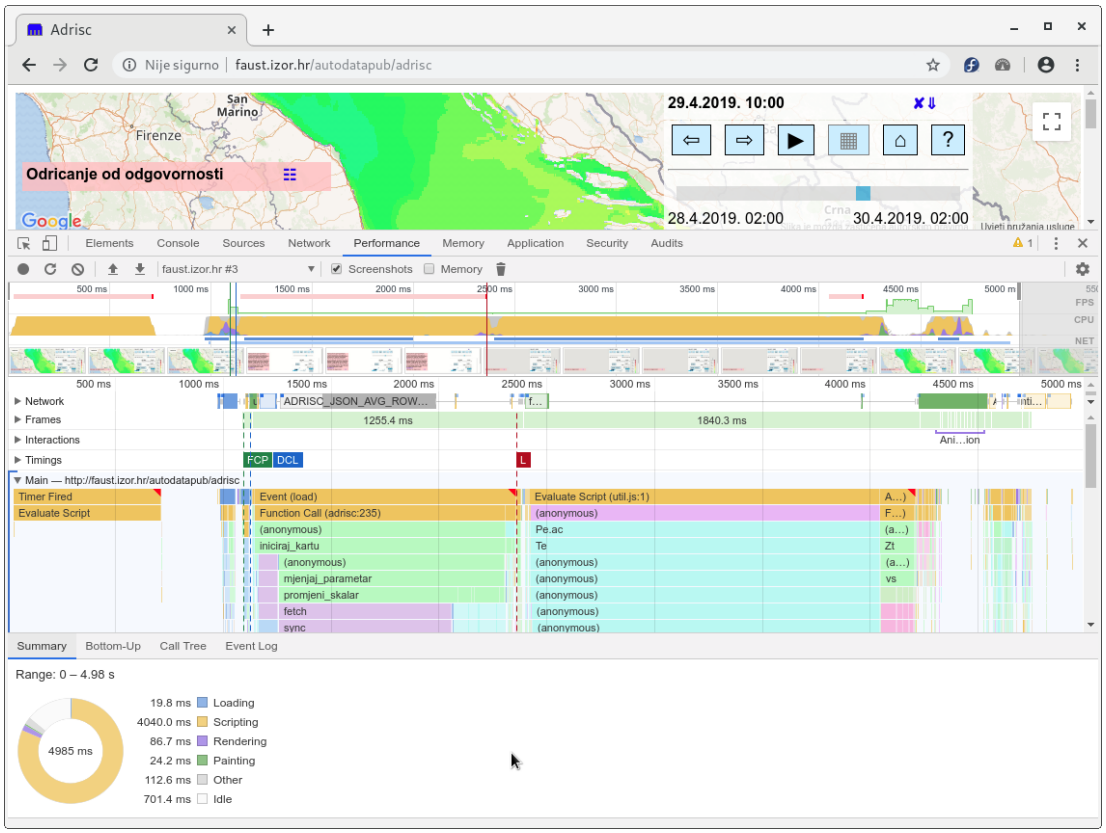

Slika 7.10: Analiza brzine učitavanja

7.5.4. Upravljanje i kontrole prikaza

Osim prethodno opisanih kontrola za slojeve, na mrežnoj stranici su dostupne i kontrole vremena. Vrijeme se može postaviti korištenjem dviju grupa kontrola: kontrola apsolutnog vremena koja se sastoji od birača dana i klizača za relativni vremenski pomak -1h i +1h ili animacije scena za posljednja dva dana rezultata prognoze. Animacija znači da se svih 48 (prognoza za sljedećih 48 sati u koracima od 1 sata) scena učitavaju jedna za drugom. Kada se učita posljednja scena, animacija se automatski zaustavlja. Konačno, kontrola zumiranja, kontrola povratka na početni prikaz karte i kontrola položaja također su dio mrežnog sučelja.

Sve ove kontrole nalaze se u području kontrola mrežne stranice koje se može sakriti. Područje odricanja od odgovornosti također se može sakriti kako bi se bolje vidjela sama karta. Ovo je posebno važno kada se koristite malim zaslonima (poput pametnih telefona). Ukupno 13 kontrola – dostupnih unutar kontrolnog područja, numerirane su i prikazane na slici 7.11. Opišimo dostupne kontrole.

1. Zaglavlje scene: datum i vrijeme trenutačne scene (na lijevoj strani) i kontrola za prikaz/sakrij (desno).

2. Prijelaz na prethodnu scenu: 6 sati ako su vizualizirani podatci stariji od 3 dana, inače svakih sat vremena.

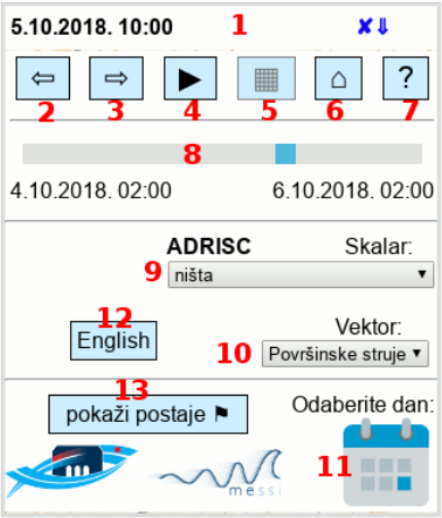

Slika 7.11: Kontrole prikaza

3. Prijelaz na sljedeću scenu: 6 sati ako su podatci vizualizirani stariji od 3 dana, inače svakih sat vremena.

4. Start/Stop animacija: automatski pomak scena, ali može biti malo nesinkroniziran u slučaju spore veze i/ili vektorskog sloja.

5. Zumirano područje više/manje pojedinosti: kada određeni korisnik zumira dovoljno malo područje, kontrola postaje aktivna i podatci pune razlučivosti učitavaju se u za to određeno područje i prikazuju s prilagođenim rasponom pri aktivaciji kontrole, deaktivacijom se vraćaju prosječna polja za cijelu domenu.

6. Početne postavke: vrati kartu na početni zum i položaj.

7. Pomoć i opis: detaljna objašnjenja o modelu i vizualizaciji.

8. Klizač scene: omogućuje promjenu scene od početka do kraja svake prognoze za 48 sati.

9. Odaberite skalarni sloj.

10. Odaberite dan prognoze prethodnog modela.

11. Promijeni jezik sučelja s engleskog na hrvatski.

7.5.5. Glavni prostorni prikaz modela

Glavna AdriSC mrežna stranica sastoji se od sedam različitih elemenata koji su prikazani i numerirani na slici 7.12.

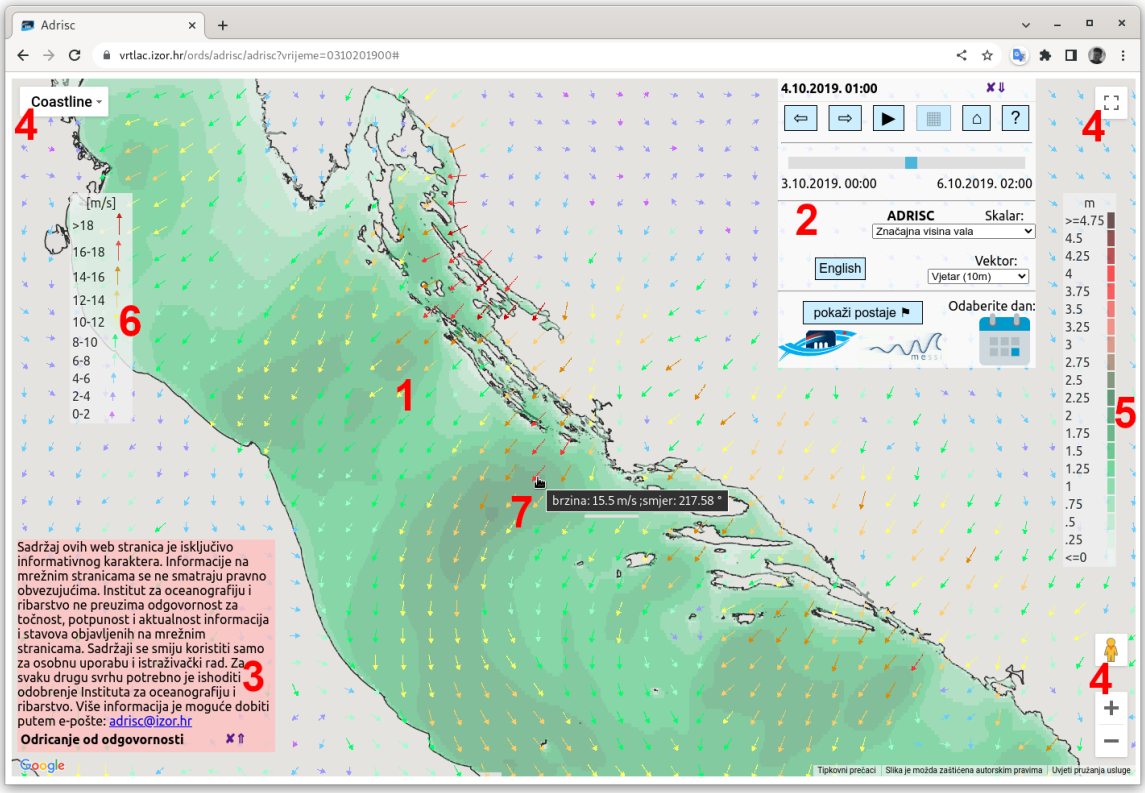

Slika 7.12: Glavni elementi prikaza

Opišimo ove elemente stranice ili kontrole.

1. Glavna karta sa skalarnim i/ili vektorskim prikazom polja.
2. Kontrolno područje (kao što je prethodno opisano).
3. Odricanje od odgovornosti (kao što je prethodno opisano).
4. Kontrole Google karte: osnovni odabir sloja, zumiranje, prikaz ulice i prikaz preko cijelog zaslona.
5. Legenda skalarnog polja.
6. Legenda vektorskog polja.
7. Vrijednost odabranog elementa modela.

Ovisno o prikazanim parametrima, dvije vrste legendi dostupne su za skalarna polja: ili legenda koristi fiksne vrijednosti (npr. pokrivenost oblakom uvijek se prikazuje između 0 % i 100 %) ili se legenda prilagođava prikazanim podatcima (npr. more i zrak temperaturne legende ovise o godišnjim dobima). Međutim, za dano razdoblje prognoze od 48 sati, legenda bilo kojeg prikazanog parametra identična je za sve dostupne scene. Osim toga, kada se učita viša rezolucija modela za zumirana područja, legenda se uvijek prilagođava

specifičnim rasponima područja za danu scenu kako bi prostorne promjene polja bile vidljivije. Konačno, klikom na bilo koju ćeliju modela (ili pokazivačem preko određene strelice vektorskog polja), prikazuje se vrijednost povezana s tom ćelijom (ili strelicom).

7.5.6. Virtualne postaje - usporedba s mjerenim vrijednostima

Provjera modela je složen i težak proces i izvan je okvira ovog rada. Međutim, kako je na IOF-u dostupna uspostavljena mreža automatskih postaja u stvarnom vremenu, a mjerenja se učitavaju u istu bazu podataka kao i AdriSC model, usporedba rezultata modela s podatcima postaje u stvarnom vremenu također je implementirana unutar mrežne stranice. U tom duhu, 1-minutni izlaz iz WRF, ROMS i ADCIRC modela na nekim unaprijed definiranim postajama – tj. lokacijama na kojima su mjerenja potencijalno dostupna (neki podatci o postajama još nisu dostupni, ali će se učitati u bliskoj budućnosti), izdvajaju se i pohranjuju u bazi podataka. Položaj postaja prikazan je na glavnoj karti s različitim oznakama kao što se vidi na slici 7.13 kada je odabrana tipka "Prikaži postaje". Ako su mjerenja u stvarnom vremenu već dostupna na određenoj postaji, prikazana oznaka na karti je veća. Koriste se sljedeće oznake: W - WRF model (meteorološke vrijednosti), R - ROMS model (oceanografske vrijednosti), A- ADCIRC model (razina mora), M- mjerenja

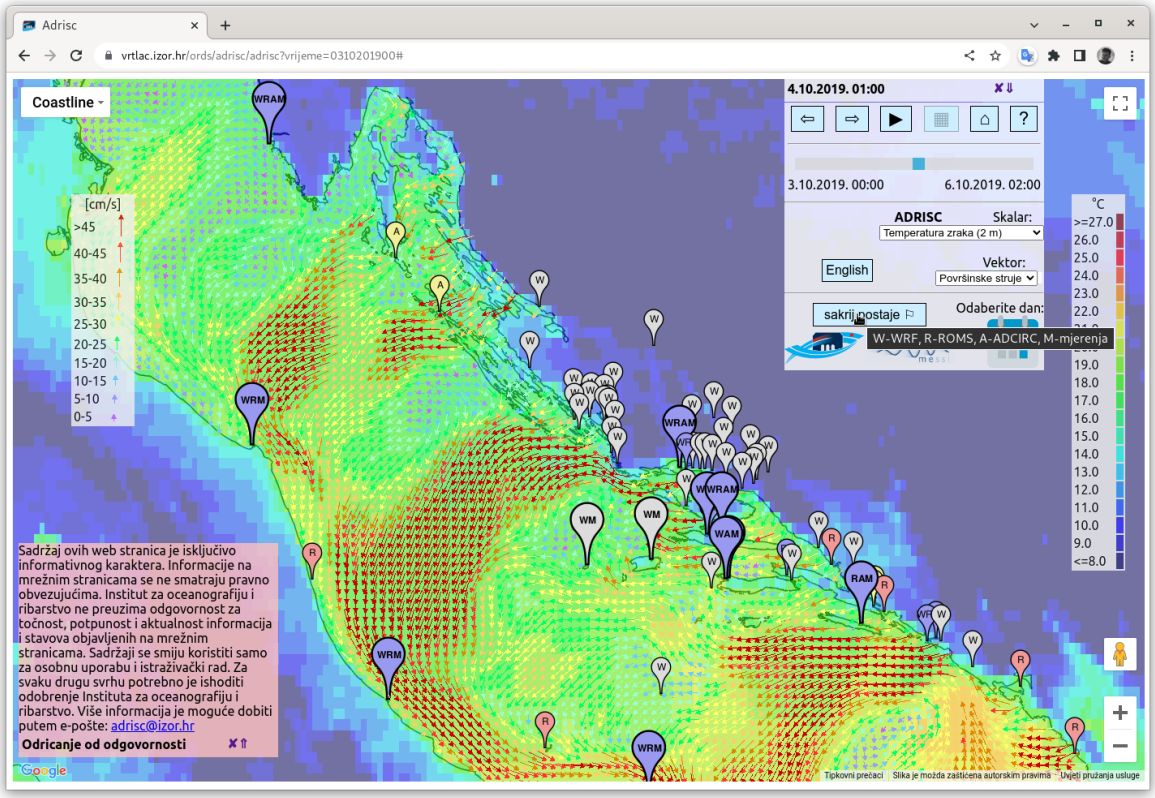

Slika 7.13: Prikaz virtualnih i automatskih mjernih postaja

Kada korisnik odabere neku postaju s karte, dobije prikaz modeliranih vrijednosti (mi-

nutne vrijednosti). Ako na istoj postaji postoje i mjerenja, prikazane su usporedno i modelirane vrijednosti. Prikaz podataka s virtualne postaje vidi se na slici 7.14.

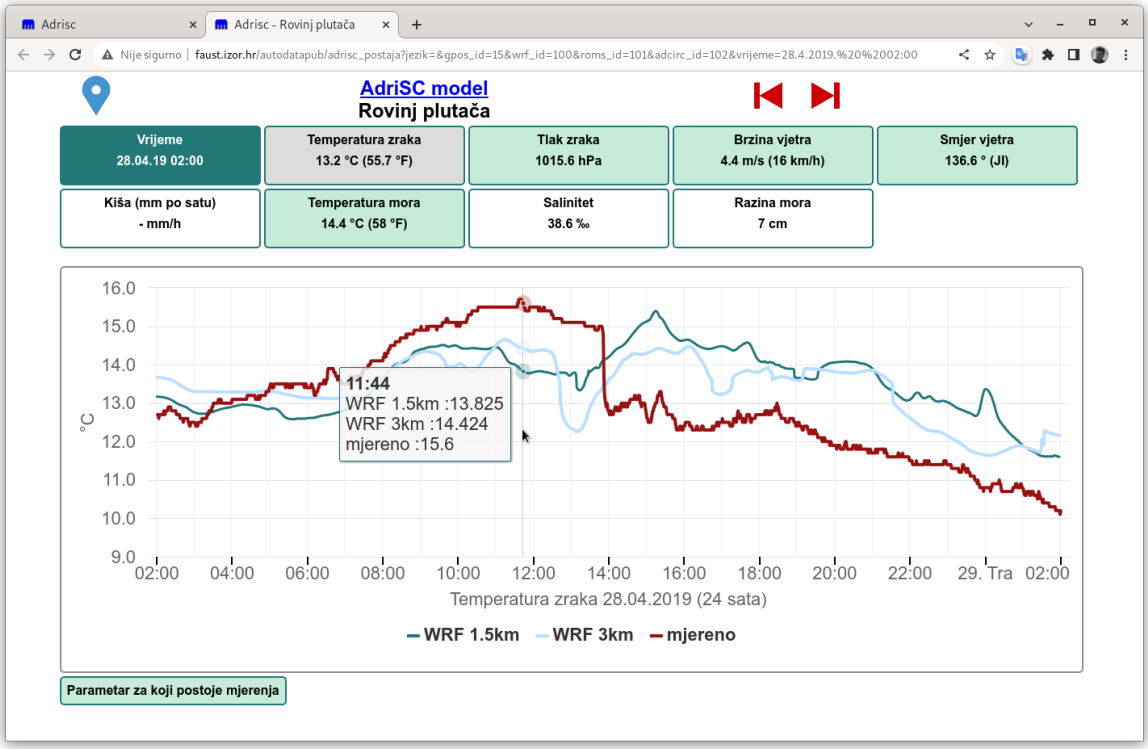

Slika 7.14: Usporedni prikaz rezultata mjerenja i modela

7.6. Zaključak

Za bolje razumijevanje okoliša razvijaju se različiti mjerni sustavi i modeli s izlazom kao mrežastim poljima vrijednosti. Za korištenje ovakvih informacija i bolje razumijevanje onoga što pokazuju, potrebna je prikladna vizualizacija. U ovom trenutku postoje dvije vrste vizualizacija koje se koriste za predstavljanje rezultata modela na Internetu: generirane statične slike i generirana georeferencirana slika koja se koristi kao rasterski sloj s mogućnošću zumiranja. Ovaj rad opisuje treću (novu) vrstu rješenja: dinamički kreirane scene na strani klijenta s pomoću JavaScripta. Korištenje ove vrste vizualizacije donosi novu mogućnost kao što je interaktivnost, uz kraće vrijeme učitavanja podataka.

Upotreba relacijske baze podataka unutar vizualizacije modela nije uobičajen postupak. Donosi neke nove mogućnosti u pogledu vizualizacije i provjere modela. Upravljanje velikom količinom podataka unutar baze podataka je izazov, ali još uvijek izvedivo.

Daljnji razvoj opisane vizualizacije uključivat će i ADCIRC rezultate visoke rezolucije za ciljana područja, kao i grafički prikaz promjene parametara tijekom vremena za bilo koju željenu točku u prostoru (najbliža točka mreže). Također tijekom vremenskog modela rezultati se mogu usporediti ne samo s podatcima automatskog mjernog sustava nego i sa svim

dostupnim oceanografskim i meteorološkim podatcima kao što su visokofrekventni radarski podatci površinskih struja, ADCP podatci i podatci s klasičnih oceanografskih krstarenja.

Trenutačno se na mrežnoj stranici modela mogu naći rezultati za razdoblje od 15. travnja 2018. do 4. listopada 2019. godine. Nakon završetka projekata nije više bilo moguće osigurati vanjske resurse za svakodnevno izvođenje modela. Nadamo se uskoro ponovno pokrenuti redovite vizualizacije i prognoze.

8. ZAKLJUČAK

Potreba za razumijevanjem okoliša iskonska je potreba ljudi koja dobiva sve veću važnost. U kontinuiranom procesu istraživanja okoliša i njegovih zakonitosti možemo izdvojiti određene komponente i faze:

- mjerenja u okolišu,
- definiranje zakonitosti i interakcija u okolišu,
- modeliranje i aproksimacija određenih okolišnih parametara,
- objektivna analiza i predviđanja stanja okoliša,
- upravljanje stanjem okoliša.

Važnu ulogu i ishodište u razumijevanju okoliša imaju razna mjerenja i praćenja okolišnih parametara. Napretkom elektronike napredovale su i tehnike mjerenja, što je dovelo do velikog povećanja u broju dostupnih mjerenja. Uočavanje promjena u okolišu, pogotovo negativnih promjena, dovelo je do potrebe da se ljudski utjecaj na okoliš smanji i takve promjene zaustave.

U oceanografiji se uz meteorologiju prikupljaju podatci o okolišu. Svi oni imaju prostornu i vremensku komponentu. Raznolikost među parametrima je velika pa kod podataka fizičke oceanografije možemo imati velike nizove koje vremenski i prostorno pokrivaju neko područje uz relativno mali broj parametara, i biološke podatke gdje svjedočimo malom broju podataka raspršenom unutar velikog broja parametara. Kako bi se svi ovi podatci ispravno pohranili, provjerili i na kraju obradili, potrebno je odgovarajuće rukovanje podatcima. Pomoć računarstva i tehnologije je pritom neizbježna. Tijekom dugog razdoblja rukovanja podatcima (više od 20 godina) i razvijanja programskih rješenja, došli smo do nekih novih spoznaja.

Utjecajem na okoliš bavi se i Direktiva 2008/56/EZ Europskog parlamenta i vijeća od 17. lipnja 2008. o uspostavljanju okvira za djelovanje Zajednice u području politike morskog okoliša (Okvirna direktiva o pomorskoj strategiji). Unutar same direktive značajnu ulogu ima sustav: "Pokretač, Pritisak, Stanje, Utjecaj, Mjera" (engl. *Driver, Presure, State, Impact, Response* - DPSIR) [87]. Međuodnosi dijelova sustava vidljivi su na slici 8.1. Cijeli ovaj

sustav temelji se na podatcima iz okoliša, odnosno znanjem izvučenom iz njih. Kako bi se mogli utvrditi stanje okoliša i pritisci na njega, posebno je bitno točno utvrditi to stanje i izvući trendove za pojedine parametre i područja.

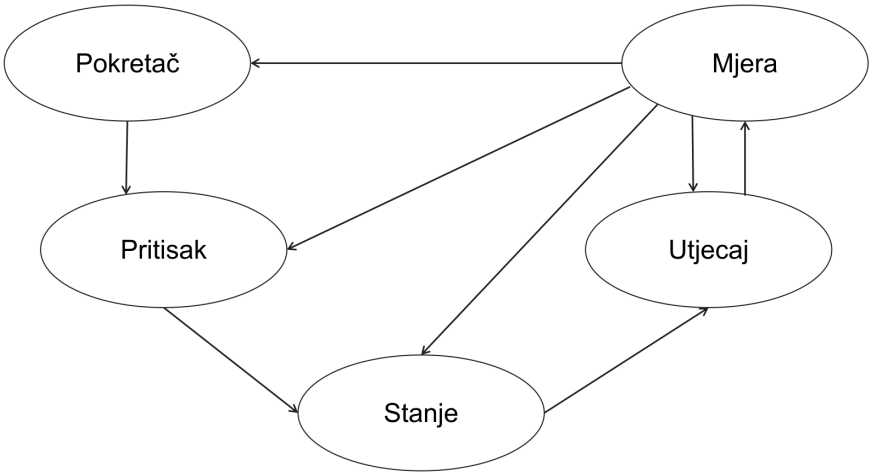

Slika 8.1: Međuodnosi u sustavu Pokretač, Pritisak, Stanje, Utjecaj, Mjera

Prostorna i vremenska komponenta podataka, kao i potreba da se što jednostavnije utvrdi stanje i trend za pojedini parametar, područje i razdoblje, doveli su do razvoja specifičnih programskih rješenja za upravljanje podatcima.

Osnovna je pretpostavka za kvalitetne podatke njihova ispravnost. Susrećemo se s puno izazova kako prostorne podatke učinkovito provjeriti. U svrhu provjere, ali i analize podataka, razvijen je sustav za prikaz i provjeru podataka s obostrano povezanom podatkovnom i prostornom komponentom u mrežnom sučelju. Ovo uključuje prikaz pojedinačnih mjerenja, identificiranje i označavanje potencijalno neispravnih vrijednosti i spremanje te informacije sa samim vrijednostima i komentarima stručnjaka za pojedini parametar. Razvijen je i implementiran sustav koji uključuje relacijsku bazu podataka dizajniranu za jednostavno dodavanje novih parametara. Optimizirani su prostorno-vremenski upiti za učinkovit dohvat podataka. Sama mrežna aplikacija je razvijena uzimajući u obzir pravila dizajna i upotrebljivosti, uz intuitivnost i minimalnu obuku za upotrebu. Način na koji je omogućena jednostavna provjera i uvid u prostorno-vremenske podatke je novost pri rukovanju okolišnim, odnosno prostorno-vremenskim podatcima. Ovo je postignuto kombinacijom filtriranja podataka na poslužitelju i interaktivnim prikazima s klijentske strane, čime je kombinirana upotreba relacijske baze za dohvat i ažuriranje s naprednim vizualizacijama. **U dosadašnjim rješenjima ove su se komponente koristile odvojeno, što je od korisnika zahtijevalo veći angažman u više koraka.**

Provjera ovog implementiranog sustava sastojala se od njegova operativnog korištenja u dvjema instancijama. Sustav je korišten za potrebe međunarodnog projekta gdje su podatci

od strane uključenih 10 institucija iz 6 zemalja Jadransko-jonske regije prikazani i provjereni. Sustav je potvrđen u rezultatima projekta, uz osnivanje mreže institucija za daljnje korištenje i razvoj sustava. Druga instancija se koristi kao službeni sustav za upis i provjeru podataka Referentnog centra za more Ministarstva gospodarstva i održivog razvoja. Ovdje ga aktivno koriste djelatnici dviju institucija zaduženih za operativni upis i provjeru podataka u sklopu nacionalnog monitoringa.

Automatski mjerni sustavi omogućuju stalan dotok podataka i vrijedan su resurs za razne procjene stanja okoliša. Količina podataka je u pravilu veća nego kod klasičnih mjerenja. Glavno svojstvo ovakvih podataka je dobra vremenska pokrivenost, odnosno riječ je o serijama podataka mjerenih na određenoj lokaciji. Kod analize velikog broja podataka uz dobru vizualizaciju je puno lakše doći do vrijedne informacije, odnosno izvući znanje iz podataka. U tu svrhu je razvijan sustav za upis i prikaze podataka s automatskih mjernih sustava. U suradnji sa znanstvenicima koji se koriste podatcima i prema njihovim potrebama razvijen je sustav za prikaz i "upravljanje događajima". Događaji su određene zanimljive pojave koje se mogu uočiti u mjerenim podatcima. Novost je da se posebnim prikazom podataka korisniku omogući jednostavan pregled kroz prostor i vrijeme, gdje on može brzo i jednostavno, bez potrebe pregledavanja svih mjerenja, uočiti zanimljive i neuobičajene pojave. Bez obzira na složene i vrijedne sustave za automatsko prikupljanje podataka o stanju okoliša, sučelja za njihovo pregledavanje (vremenski nizovi) često su rudimentarna i svode se na alate za preuzimanje podataka. Boljim prikazom i upravljanjem podatcima korisnici mogu lakše pronaći i steći uvid u veće količine mjerenih podataka.

Prikazi podataka s automatskih mjernih sustava korišteni su za potrebe brojnih znanstveno-istraživačkih projekata (NASCUM, HAZADR, ISPNDJ, MESSI, POZOR, CHANGE WE CARE, RESPONSe, ECOSS). Brojni domaći i strani znanstvenici koristili su se sustavom prikaza koji je pomogao realizaciji projekata i njihovim rezultatima.

Numeričko modeliranje omogućuje objektivnu analizu i prognoze kretanja određenih parametara. Razvojem računarstva razvijaju se i numerički modeli kako bi se što točnije mogla opisati međudjelovanja u prirodi. Rezultati numeričkih modela su prostorna polja podataka s pravilnom mrežom jednako razmaknutih točaka (čvorova). Udaljenost između čvorova je rezolucija modela. Pokrenut model za neko područje kontinuirano računa promjene parametara. Rezultati modela su vrijednosti u svakom čvoru modela izvučeni u pravilnim vremenskim razmacima i ti podatci tvore jednu scenu.

Obično se rezultati modela vizualiziraju direktno iz datoteka tako da se kreira prostorni sloj u obliku slike za svaki parametar. Za svaku scenu je potrebno unaprijed kreirati slojeve određene fiksne rezolucije. Naš pristup je bio drukčiji. Rezultati modela se učitavaju u relacijsku bazu podataka. Nakon učitavanja podatci se "sažimaju" unutar same baze radi bržeg prikaza cijelog područja s manjom rezolucijom. Sažimanje se sastoji u spajanju susjednih

čvorova s istim rasponom podataka koji se prikazuje istom bojom. Na taj način je ubrzano učitavanje prikaza za šira područja, dok se za manja područja izvlače izvorne vrijednosti, kao i na korisnički klik na neku lokaciju (vrijednost čvora). Posebnost naše mrežne aplikacije je mogućnost usporedbe rezultata modela (nekada i više vrijednosti, odnosno varijanti za isti parametar) i rezultata mjerenja automatskih mjernih sustava. Ovakav način prikaza rezultata numeričkih modela na mreži koji uključuju korištenje relacijske baze podataka je nov, te na Internetu i u literaturi ne nalazimo druge primjere. Prednosti su u mogućnosti dinamičke prilagodbe raspona prikaza za manja područja, kao i jednostavno izvlačenje vremenskih nizova u čvoru modela i usporedba s mjerenim podatcima.

Naglasimo još jednom znanstvene doprinose disertacije. **Temeljni znanstveni doprinos** ovog rada je *definicija i realizacija novih načina vizualizacije okolišnih podataka u mrežnom okruženju, usmjerenih k učinkovitijem upravljanju podatcima i izvlačenju sadržanih znanja iz istih.*. Tijekom dugogodišnjeg rada s okolišnim podatcima uočeni su određeni nedostatci u postojećim metodama koje smo znatno unaprijedili novim pristupom i ostvarenim rješenjima.

Na kraju ćemo navesti **dodatne znanstvene doprinose**.

- Novi pristup vizualizaciji okolišnih podataka prikazanom kroz arhitekturu i dizajn mrežne aplikacije s obostrano povezanom podatkovnom, vremenskom i prostornom komponentom. Omogućuju se učinkovitije provjere podataka i bolji uvid u stanje i trend od postojećih rješenja. Učinkovitost se očituje kroz interaktivan obostrano povezan grafičko kartografski prikaz podataka.

- Nova metoda prikaza podataka mjernih sustava nadzora okolišnih podataka kojom je je olakšano pronalaženje ekstremnih i zanimljivih scena i dohvat povezanih prostornih slojeva. Metoda je opisana kroz arhitekturu i dizajn mrežne aplikacije za pohranu i prikaz podataka s automatskih mjernih sustava kojom se omogućuje upravljanje događajima. Upravljanje događajima ostvaruje se vremenskim prikazom scena u koje se ugrađuju grafički elementi za otkrivene pojave.

- Realiziran je sustav za učitavanje i prikaz rezultata više numeričkih modela. Sustav koristi relacijsku bazu podataka i oslanja se isključivo na vizualizaciju na strani klijenta. Ovo omogućuje bolji prikaz detalja i usporedbe sa stvarnim mjerenjima te brži odziv sustava u odnosu na postojeća rješenja.

Budući rad biti će usmjeren na poboljšavanje i nadogradnju opisanih aplikacija i sustava i to posebno:

- Dodavanje novih vrsta vizualizacija i filtriranja podataka u obostrano povezanim podatkovnim i kartografskim prikazima.

- Integracija dodatnih vanjskih izvora podataka u sustave mrežne vizualizacije.
- Implementacija sustava u drugim institucijama i migracija na druge tehnološke platforme.

Daljnjim razvojem računarstva i komunikacijske tehnologije povećat će se količina dostupnih mjerenja, ali isto tako i brzine dohvata i prijenosa podataka, kao i procesorska snaga za napredne vizualizacije. Postojeća rješenja već koriste neke naprednije tehnike kao što su asinkroni prijenos podataka u pozadini i intenzivno korištenje JavaScripta. Iz tog razloga su dobra osnova za daljnji dugotrajniji razvoj zato što se i općenito mrežne tehnologije razvijaju u istom smjeru.

LITERATURA

[1] M. Friendly, The golden age of statistical graphics, *Statistical Science*, 502–535, 2008.

[2] A. Babum, S. Reddy i S. Agarwal, An effective approach for vizualizing big data, *International Journal of Innovations in Engineering and Technology (IJIET)*, 7, 2, 77–81, srpanj 2010.

[3] E. Olshannikova, A. Ometov i Y. Koucheryavy, Towards big data visualization for augmented reality, *Proceedings - 16th IEEE Conference on Business Informatics*, 33–37, CBI, 2014.

[4] S. Few, Eenie, meenie, minie, moe: Selecting the right graph for your message, *Perceptual Edge*, rujan 2004.

[5] S. Das, Time series analysis, 1994, economic Research Unit; Indian Statistical Institute; Kolkata-700108, prezentacija.

[6] S. Das, Time Series Analysis, Economic Research Unit; Indian Statistical Institute; Kolkata-700108; 1994, [prezentacija].

[7] M. M. Drder, Kartografska građa u kontekstu kulturne baštine, *Vjesnik bibliotekara Hrvatske*, 56, 4, 1–23, ožujak 2013.

[8] V. Maček i B. Lipovšćek, Primjena geografskog informacijskog sustava na informacijske sustave društveno političke zajednice, *Geografski informacijski sustavi, zbornik radova*, 1993.

[9] B. Hibbard, The top five problems that motivated my work [data visualisation], *IEEE Computer Graphics and Applications*, 24, 6, prosinac 2004.

[10] H. J. Miller, A measurement theory for time geography, *Geographical Analysis*, 17–45, prosinac 2004.

[11] H. Couclelis, Rethinking time geography in the information age, *Environment and Planning*, 41, 1556–1575, 2009.

[12] N. Andrienko, G. Andrienko i P. Gatalsky, Exploratory spatio-temporal visualization: an analytical review, *Journal of Visual Languages & Computing*, 14, 6, 503–541, 2003.

[13] P. Gatalsky, N. Andrienko i G. Andrienko, Interactive analysis of event data using space-time cube, *Proceedings of Eighth International Conference on Information Visualisation*, 145–152, srpanj 2004.

[14] G. Andrienko, N. Andrienko, M. Mladenov, M. Mock i C. Politz, Identifying place histories from activity traces with an eye to parameter impact, *IEEE Transactions on Visualization and Computer Graphics*, 18, 5, svibanj 2012.

[15] A. Shrestha, Visualizing Spatio-Temporal data, https://scholarworks.gsu.edu/cs_diss/92, [Disertacija, zadnji pristup 22. travnja 2019.].

[16] T. Berners-Lee, R. Cailliau, N. Pellow i A. Secret, The world wide web initiative, *CERN, http://info. cern. ch/hypertext/WWW/TheProject. html*, 1993.

[17] CERN, A short history of the Web | CERN, https://home.cern/science/computing/birth-web/short-history-web, [Zadnji pristup 17. veljače 2022.].

[18] HHI, Mareografska postaja Split, mrežna stranica, http://www.hhi.hr/tide/index/ST, [Disertacija, zadnji pristup 15. veljače 2018.].

[19] DHMZ, DHMZ Prognoza za Hrvatsku - danas, http://prognoza.hr/prognoze.php?id=hrdanas_n, [Mrežna stranica, zadnji pristup 15. veljače 2018.].

[20] Preglednik Chrome verzija 64, prikaz mrežnog prometa pri učitavanju stranice, http://prognoza.hr/prognoze.php?id=hrdanas_n, [Mrežna stranica, zadnji pristup 23. veljače 2018.].

[21] B. Mao, Z. Wu i J. Cao, A framework for online spatio-temporal data visualization based on HTML5, *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XXII ISPRS Congress*, 2012.

[22] Highcharts, Interactive javascript charts library, https://www.highcharts.com/, [Mrežna stranica, zadnji pristup 28. kolovoza 2022.].

[23] Google, Charts | Google Developers, https://developers.google.com/chart/, [Mrežna stranica, zadnji pristup 28. kolovoza 2022.].

[24] Chart.js, Charts.js, https://www.chartjs.org/docs/latest/, [Mrežna stranica, zadnji pristup 28. kolovoza 2022.].

[25] Plotly.js, Plotly javascript graphing library in JavaScript, https://plotly.com/javascript/, [Mrežna stranica, zadnji pristup 28. kolovoza 2022.].

[26] S. Alimadadi, Sequeira, S., M. A. i K. Pattabiraman, Understanding javascript event-based interactions, *In Proceedings of the 36th International Conference on Software Engineering*, 367–377, ACM, 2014.

[27] Glodssary tech, What is Highcharts — get to know on GlossaryTech, https://glossarytech.com/terms/front_end-technologies/highcharts, [Mrežna stranica, zadnji pristup 28. kolovoza 2022.].

[28] J. J. Garrett et al., Ajax: A new approach to web applications, 2005.

[29] J. Wagner, Progammable web: deset najboljih kartografskih biblioteka, https://www.programmableweb.com/news/top-10-mapping-apis-google-maps-microsoft-bing-maps-and-mapquest/analysis/2015/02/23, [Mrežna stranica, zadnji pristup 5. lipnja 2022.].

[30] S. Chilton, Openstreetmap: Just a database, or catalyst for cartographic revolution, *Proceedings of the 1-st European State of the Map*, 2011.

[31] J. Beaujardiere, Opengis® web map server implementation specification, *Open Geospatial Consortium Inc*, 15, 2006.

[32] P. P. A. Vretanos, Ogc® web feature service 2.0 interface standard–with corrigendum, version 2.0. 2., 2014.

[33] P. Baumann, Ogc® wcs 2.0 interface standard-core: Corrigendum, *Ogc Interface Standard*, 2012.

[34] Open Geospatial Consortium, Web Feature Service, https://www.ogc.org/standards/wfs, [Mrežna stranica, zadnji pristup 5. srpnja 2022.].

[35] D. Kontrec, Diplomski rad, implementacija wfs-t standarda na primjeru webgis-a rovinjskog sela.

[36] H. Klug i A. Kmoch, A smart groundwater portal: An ogc web services orchestration framework for hydrology to improve data access and visualisation in new zealand, *Computers & Geosciences*, 69, 78–86, 2014.

[37] S. Iacovella, *GeoServer Cookbook*, Packt Publishing Ltd., 2014.

[38] Geoserver, Support - Geoserver, https://geoserver.org/support/, [Mrežna stranica, zadnji pristup 28. kolovoza 2022.].

[39] J. Ružička, Comparing speed of web map service with geoserver on esri shapefile and postgis, *Geoinformatics FCE CTU*, 15, 1, 3–9, 2016.

[40] R. R. Vatsavai, S. Shekhar, T. E. Burk i S. Lime, Umn-mapserver: A high-performance, interoperable, and open source web mapping and geo-spatial analysis system, *International Conference on Geographic Information Science*, 400–417, Springer, 2006.

[41] D. J. Maguire, Arcgis: General purpose gis software system, 2008.

[42] D. B. Keon, *Automated web-based analysis and visualization of spatiotemporal data*, Oregon State University, 2012.

[43] D. Keon, B. Steinberg, H. Yeh, C. M. Pancake i D. Wright, Web-based spatiotemporal simulation modeling and visualization of tsunami inundation and potential human response, *International Journal of Geographical Information Science*, 28, 5, 987–1009, 2014.

[44] M. Kulawiak, A. Prospathopoulos, L. Perivoliotis, S. Kioroglou, A. Stepnowski et al., Interactive visualization of marine pollution monitoring and forecasting data via a web-based gis, *Computers & Geosciences*, 36, 8, 1069–1080, 2010.

[45] M. Hecher, C. Traxler, G. Hesina, A. L. Fuhrmann i D. W. Fellner, Web-based visualization platform for geospatial data., *IVAPP*, 311–316, 2015.

[46] S. Harbola i V. Coors, Geo-visualisation and visual analytics for smart cities: A survey, *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 42, 2018.

[47] DHMZ, DHMZ - Državni hidrometeorološki zavod, https://meteo.hr/, [Mrežna stranica, zadnji pristup 8. rujna 2018.].

[48] yr.no, Mrežna stranica yr prognoze norveškog meteorološkog instituta, https://www.yr.no/place/Croatia/Split-Dalmatia/Split/, [Mrežna stranica, zadnji pristup 9. rujna 2018.].

[49] EMODnet CHEMISTRY, CCDI - Marine data access, https://emodnet-chemistry.maris.nl/search, [Zadnji pristup 20. Lipnja 2022.].

[50] Copernicus, Copernicus - Marine environment monitoring, http://marine.copernicus.eu/services-portfolio/access-to-products/?option=com_csw&view=details&product_id=MEDSEA_ANALYSIS_FORECAST_PHYS_006_001, [Zadnji pristup 10. studeni 2016.].

[51] D. Ivanković, V. Dadić i M. Srdelić, Marine environmental database of the adriatic sea with application for managing and visualisation of data., *Proceedings of ENVIROSOFT 2000*, 397–406, WIT press, Southampton, Great Britain, 2000.

[52] V. Dadic i D. Ivankovic, Medas system for archiving, visualisation and validation of oceanographic data, *Proceedings of "Ocean Biodiversity Informatics": An international conference on marine biodiversity data management. V. Berghe, EW Appeltans, MJ Costallo and P. Pissierssens (Eds). Hamburg, Germany, 2004*, 29, 37–48, 2007.

[53] D. Ivankovic i V. Dadic, Web based tools for data manipulation, visualisation and validation with interactive georeferenced graphs, *EGU General Assembly Conference Abstracts*, 13082, 2009.

[54] D. Ivankovic, Sea bathing water quality on beaches in the republic of croatia-web application, *Book of Abstracts*, 113, 2010.

[55] D. Ivanković i I. Vučić, Web presentation of gis objects on institute of oceanography and fisheries using open source/free tools (openlayers&geoserver), *The Future with GIS. Croatian Information Technology Association–GIS Forum, University of Silesia, Zagreb*, 197–204, 2011.

[56] D. Ivanković, V. Dadić, L. Šerić i A. Ivanda, Web Based Spatio-Temporal Data Bidirectional Relationship Visualization - Case Study of Oceanographic Data, *Applied Sciences*, 12, 13, 2022.

[57] L. Šerić, A. Ivanda, M. Bugarić i M. Braović, Semantic Conceptual Framework for Environmental Monitoring and Surveillance - A Case Study on Forest Fire Video Monitoring and Surveillance, *Electronics*, 11, 2, 2022.

[58] QGIS project, Welcome to the QGIS Project!, https://qgis.org/en/site/, [Mrežna stranica, zadnji pristup 1. travnja 2022.].

[59] R. Schlitzer, Interactive analysis and visualization of geoscience data with ocean data view, *Computers & Geosciences*, 28, 10, 1211–1218, 2002, shareware and freeware in the Geosciences II. A special issue in honour of John Butler.

[60] S. Mieruch i R. Schlitzer, webodv–operational and ready for the community, *Bollettino di Geofisica*, 12, 119, 2021.

[61] D. Biliouris i J. Van Orshoven, Wise: Water information system for europe, issues and challenges for member states, *European conference of the Czech Presidency of the Council of the EU TOWARDS eENVIRONMENT Opportunities of SEIS and SISE: Integrating Environmental Knowledge in Europe*, Masaryk University; Brno, Czech Republic, 2009.

[62] L. Maxim, J. H. Spangenberg i M. O'Connor, An analysis of risks for biodiversity under the dpsir framework, *Ecological economics*, 69, 1, 12–23, 2009.

[63] W. Marine, Nutrients in Transitional, Coastal and Marine Waters, https://www.eea.europa.eu/data-and-maps/indicators/nutrients-in-transitional-coastal-and-4/assessment, [Mrežna stranica, zadnji pristup 24. ožujka 2022.].

[64] P. Laja, 10 Useful Findings about How People View Websites, https://cxl.com/blog/10-useful-findings-about-how-people-view-websites/, [Mrežna stranica, zadnji pristup 10. ožujka 2022.].

[65] G. Alexander i E. Jakob, Improving the user experience in data visualization web applications, 2021.

[66] Wikipedia, Help:Distinguishable Colors, https://en.wikipedia.org/wiki/Help:Distinguishable_colors, [Mrežna stranica, zadnji pristup 10. ožujka 2022.].

[67] HarmoNIA project, Harmonization and Networking for Contaminant Assessment in the Ionian and Adriatic Seas—HarmoNIA, https://harmonia.adrioninterreg.eu/, [Mrežna stranica, zadnji pristup 8. veljače 2022.].

[68] Oracle corporation, Oracle Database 19c—Get Started, https://docs.oracle.com/en/database/oracle/oracle-database/19/index, [Mrežna stranica, zadnji pristup 10. ožujka 2022.].

[69] Intergovernmental Oceanographic Commission and others, Manual of quality control procedures for validation of oceanographic data, 1993.

[70] D. Ivanković, Web publishing and visualization of real-time data, *2021 6th International Conference on Smart and Sustainable Technologies (SpliTech)*, 1–3, IEEE, 2021.

[71] D. Ivanković i L. Šerić, Operational Eddy Detection in Measurements of High-Frequency Radar Surface Sea Currents Vectors Field, https://www.fer.unizg.hr/crv/ccvw2017/program, [Radionica, popis radova, zadnji pristup 19. lipnja 2022.].

[72] Pljusak.com, Pljusak.com, Split - Spinut, https://pljusak.com/meteo.php?stanica=spinut, [Mrežna stranica, zadnji pristup 19. lipnja 2022.].

[73] NASCUM, Projekt NASCUM, https://jadran.izor.hr/nascum/, [Mrežna stranica, zadnji pristup 19. lipnja 2022.].

[74] HAZADR, HAZADR – Strengthening common reaction capacity to fight sea pollution of oil, toxic and Hazardous substances in Adriatic Sea, https://maritime-spatial-planning.ec.europa.eu/projects/hazadr-strengthening-common-reaction-capacity-fight-sea-pollution-oil-toxic-and [Mrežna stranica, zadnji pristup 19. lipnja 2022.].

[75] ISPNDJ, Istraživanje i sustavi praćenja neuobičajene dinamike Jadrana, https://jadran.izor.hr/barograf/index.htm, [Mrežna stranica, zadnji pristup 19. lipnja 2022.].

[76] MESSI, Meteotsunamis, destructive long ocean waves in the tsunami frequency band: from observations and simulations towards a warning system, https://jadran.izor.hr/~sepic/MESSI/, [Mrežna stranica, zadnji pristup 19. lipnja 2022.].

[77] POZOR, Praćenje potencijalno opasnih oscilacija razine mora i njihov doprinos poplavama obalnih područja u budućoj klimi, https://jadran.izor.hr/~sepic/POZOR/, [Mrežna stranica, zadnji pristup 19. lipnja 2022.].

[78] CHANGE WE CARE, Climate cHallenges on coAstal and traNsitional chanGing arEas: WEaving a Cross-Adriatic REsponse, https://www.italy-croatia.eu/web/changewecare, [Mrežna stranica, zadnji pristup 19. lipnja 2022.].

[79] RESPONSe, Strategies to adapt to climate change in Adriatic regions, https://www.italy-croatia.eu/web/response, [Mrežna stranica, zadnji pristup 19. lipnja 2022.].

[80] ECOSS, Ecological observing System in the Adriatic Sea: oceanographic observations for biodiversity, https://www.italy-croatia.eu/web/ecoss, [Mrežna stranica, zadnji pristup 19. lipnja 2022.].

[81] D. Ivanković, C. Denamiel i D. Jelavić, Web visualization of data from numerical models and real-time stations network in frame of adriatic sea and coast (adrisc) meteotsunami forecast, *OCEANS 2019-Marseille*, 1–5, IEEE, 2019.

[82] C. Denamiel, J. Šepić, D. Ivanković i I. Vilibić, The Adriatic Sea and Coast modelling suite: Evaluation of the meteotsunami forecast component, *Ocean Modelling*, 135, 71–93, 2019.

[83] D. D. hidrometeorološki zavod, Dhmz - državni hidrometeorološki zavod - vjetar za područje splita, https://meteo.hr/prognoze.php?section=prognoze_model&param=ala_k&el=web_uv10_SPLI_, [Mrežna stranica, zadnji pristup 31. kolovoza 2022.].

[84] W. Underground, Wundermap® | interactive weather map and radar | weather underground, https://www.wunderground.com/wundermap, [Mrežna stranica, zadnji pristup 31. kolovoza 2022.].

[85] J. Kim, Web-based geovisualization system of oceanographic information using dynamic particles and html5, *Journal of Coastal Research*, , 85 (10085), 1491–1495, 2018.

[86] Windy.com, Mrežna stranica windy.com, prikazi lokacije, valova i podataka s mjerne postaje, https://www.windy.com/43.512/16.440?42.597,16.440,7,, [Mrežna stranica, zadnji pristup 14. listopada 2018.].

[87] T. Berg, K. Fürhaupter, H. Teixeira, L. Uusitalo i N. Zampoukas, The marine strategy framework directive and the ecosystem-based approach–pitfalls and solutions, *Marine pollution bulletin*, 96, 1-2, 18–28, 2015.

Životopis

Damir Ivanković

Rođen je 21. svibnja 1969. godine u Bjelovaru, Hrvatska. Tamo je pohađao osnovnu i srednju školu i stječe zvanje Matematičko-informatički tehničar.
Nakon odsluženja vojnog roka upisuje Fakultet elektrotehnike i računarstva u Zagrebu, gdje diplomira 1. srpnja 1996. smjer računarstvo i stječe zvanje Diplomirani inženjer elektrotehnike (smjer računarska tehnika).
Od 1996. do 1999. godine zaposlen je u privatnoj firmi „Informatika sistemi“ u Zagrebu, na razvoju baze podataka i programiranju komunikacijskih protokola. Od 1999. do danas zaposlen je na Institutu za oceanografiju i ribarstvo u Splitu kao stručna osoba - voditelj baza podataka.
Na Institutu radi na razvoju baza podataka, sustava u stvarnom vremenu i mrežnih aplikacija. Bavi se i administracijom Linux poslužitelja, kao i mrežnim GIS-om.
Bio je uključen u brojne domaće i međunarodne znanstvene projekte. Pohađao je više međunarodnih radionica iz tema vezanim uz rukovanje oceanografskim podatcima u Francuskoj, Italiji, Belgiji i Ujedinjenom Kraljevstvu. Objavio je četrnaest radova u znanstvenim časopisima i prezentirao radove na više od dvadeset međunarodnih konferencija.
Trenutačno je na radnom mjestu stručnog savjetnika kao voditelj računskog centra. Oženjen je i otac troje djece.

Curriculum Vitae

Damir Ivanković

He was born on May 21, 1969 in Bjelovar, Croatia. There he attended primary and secondary school and obtained the title of Mathematical and IT technician.
After completing his military service, he entered the Faculty of Electrical Engineering and Computer Science in Zagreb, where he graduated on July 1, 1996, majoring in computer science and earning the title of Graduated Electrical Engineer (majoring in computer technology).
From 1996 to 1999, he was employed in the private company "Informatika sistemi" in Zagreb, developing a database and programming communication protocols. From 1999 to the present, he has been employed at the Institute of Oceanography and Fisheries in Split as an expert - database manager.
At the Institute, he works on the development of databases, real-time systems and network applications. He also deals with Linux server administration, as well as network GIS.
He was involved in numerous domestic and international scientific projects. He attended several international workshops on oceanographic data handling topics in France, Italy, Belgium and the United Kingdom. He published fourteen papers in scientific journals and presented papers at more than twenty international conferences.
He is currently working as an expert advisor as the manager of the computer center. He is married and the father of three children.