Razvoj i optimizacija metapodatkovne sheme za otvorene istraživačke podatke u području arheologije

Pintarić, Neven

Doctoral thesis / Disertacija

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zadar / Sveučilište u Zadru**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:162:122471

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Image not found or type unknown

Repository / Repozitorij:

University of Zadar Institutional Repository

Image not found or type unknown

SVEUČILIŠTE U ZADRU

POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ

DRUŠTVO ZNANJA I PRIJENOS INFORMACIJA

Neven Pintarić

RAZVOJ I OPTIMIZACIJA METAPODATKOVNE SHEME ZA OTVORENE ISTRAŽIVAČKE PODATKE U PODRUČJU ARHEOLOGIJE

Doktorski rad

Zadar, 2020

SVEUČILIŠTE U ZADRU

POSLIJEDIPLOMSKI SVEUČILIŠNI STUDIJ
DRUŠTVO ZNANJA I PRIJENOS INFORMACIJA

Neven Pintarić

RAZVOJ I OPTIMIZACIJA METAPODATKOVNE SHEME ZA OTVORENE ISTRAŽIVAČKE PODATKE U PODRUČJU ARHEOLOGIJE

Doktorski rad

Mentorica

izv. prof. dr. sc. Jadranka Stojanovski

Komentor

izv. prof. dr. sc. Dario Vujević

Zadar, 2020.

SVEUČILIŠTE U ZADRU
TEMELJNA DOKUMENTACIJSKA KARTICA

I. Autor i studij

Ime i prezime: Neven Pintarić

Naziv studijskog programa: Poslijediplomski sveučilišni studij Društvo znanja i prijenos informacija društvene znanosti, informacijske i komunikacijske znanosti

Mentorica: izv. prof. dr. sc. Jadranka Stojanovski

Komentor: izv. prof. dr. sc. Dario Vujević

Datum obrane: 16. lipnja 2020.

Znanstveno područje i polje u kojem je postignut doktorat znanosti: Društvene znanosti, Informacijske i komunikacijske znanosti

II. Doktorski rad

Naslov: Razvoj i optimizacija metapodatkovne sheme za otvorene istraživačke podatke u području arheologije

UDK oznaka: 004.62:902

Broj stranica: 276

Broj slika/grafičkih prikaza/tablica: 14/-/38

Broj bilježaka: 177

Broj korištenih bibliografskih jedinica i izvora: 240

Broj priloga: 39

Jezik rada: Hrvatski

III. Stručna povjerenstva

Stručno povjerenstvo za ocjenu doktorskog rada:

1. doc. dr. sc. Franjo Pehar, predsjednik
2. izv. prof. dr. sc. Dario Vujević, član
3. izv. prof. dr. sc. Boris Bosančić, član

Stručno povjerenstvo za obranu doktorskog rada:

1. doc. dr. sc. Franjo Pehar, predsjednik
2. izv. prof. dr. sc. Dario Vujević, član
3. izv. prof. dr. sc. Boris Bosančić, član

UNIVERSITY OF ZADAR
BASIC DOCUMENTATION CARD

I. Author and study

Name and surname: Neven Pintarić

Name of the study programme: Postgraduate doctoral study Knowledge Society and Information Transfer social sciences, information and communication

Mentor: Jadranka Stojanovski, Associate Professor

Co-mentor: Dario Vujević, Associate Professor

Date of the defence: 16 June 2020

Scientific area and field in which the PhD is obtained: Social Sciences, Information and Communication Science

II. Doctoral dissertation

Title: Development and Optimization Metadata Schemes for Open Research Data in Field of Archaeology

UDC mark:004.62:902

Number of pages: 276

Number of pictures/graphical representations/tables: 14/-/38

Number of notes: 176

Number of used bibliographic units and sources: 240

Number of appendices: 39

Language of the doctoral dissertation: Croatian

III. Expert committees

Expert committee for the evaluation of the doctoral dissertation:

1. Assistant Professor Franjo Pehar, Phd, chair
2. Assistant Professor Dario Vujević, Phd, member
3. Assistant Professor Boris Bosančić, Phd, member

Expert committee for the defence of the doctoral dissertation:

1. Assistant Professor Franjo Pehar, Phd, chair
2. Assistant Professor Dario Vujević, Phd, member
3. Assistant Professor Boris Bosančić, Phd, member

Izjava o akademskoj čestitosti

Ja, **Neven Pintarić,** ovime izjavljujem da je moj **doktorski** rad pod naslovom **Razvoj i optimizacija metapodatkovne sheme za otvorene istraživačke podatke u području arheologije** rezultat mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na izvore i radove navedene u bilješkama i popisu literature. Ni jedan dio mojega rada nije napisan na nedopušten način, odnosno nije prepisan iz necitiranih radova i ne krši bilo čija autorska prava.

Izjavljujem da ni jedan dio ovoga rada nije iskorišten u kojem drugom radu pri bilo kojoj drugoj visokoškolskoj, znanstvenoj, obrazovnoj ili inoj ustanovi.

Sadržaj mojega rada u potpunosti odgovara sadržaju obranjenoga i nakon obrane uređenoga rada.

Zadar, 16. lipnja 2020.

Zahvala

Zahvaljujem mentorici izv. prof. dr. sc. Jadranski Stojanovski i komentoru izv. prof. dr. sc. Dariu Vujeviću za potporu i znanstvenu komunikaciju u svim fazama izrade disertacije.

Hvala svima koji su sudjelovali u ovom istraživanju na pomoći i doprinosu rezultatima ovog rada.

Zahvaljujem svima koji su doprinijeli nastanku ovog rada, a posebno mojim najdražima, Emi, Matiji i Aniti.

SADRŽAJ

1. UVOD 1

1.1. Znanstvene spoznaje i identifikacija problema 3

1.2. Ciljevi i istraživačka pitanja 6

1.3. Metodologija istraživanja 7
1.3.1. Prva faza 7
1.3.2. Druga faza 7
1.3.2.1. Delphi metoda 8
1.3.3. Treća faza 11
1.3.4. Četvrta faza 11
1.3.5. Peta faza 12

1.4. Ograničenja u istraživanju 14

1.5. Etički aspekti istraživanja 14

2. OSNOVNI POJMOVI 15

2.1. Arheološki entitet 15

2.2. Podatak 16
2.2.1. Istraživački podatci 18
2.2.2. Arheološki podatci 19
2.2.3. Otvoreni podatci 21
2.2.4. Otvoreni istraživački podatci 22

2.3. Informacija 24

2.4. Znanje 24

2.5. Zaključno razmatranje 25

3. ZNANOST I OTVORENOST 27

3.1. Odnos znanosti i otvorenosti 27
3.1.1. Razvoj znanosti 28
3.1.2. Koncept otvorene znanosti 30
3.1.3. Stanje u zemljama Europske unije 31
3.1.3.1. Hrvatska 33
3.1.3.2. Ujedinjeno Kraljevstvo 34
3.1.3.3. Nizozemska 35

3.2. Znanstveno istraživanje, prikupljanje i dijeljenje podataka 36
3.2.1. Životni ciklus podataka 38
3.2.2. Dijeljenje i ponovna uporaba podataka 39

3.3. Zaključno razmatranje 44

4. DIGITALNO OKRUŽENJE I METAPODATCI 46

4.1. Arheologija u kontekstu digitalnog okruženja 47
4.1.1. Digitalni arheološki zapis 49
4.1.2. Digitalni repozitoriji 52
4.1.2.1. Opći funkcionalni zahtjevi istraživačkih repozitorija 53

4.2. Metapodatci 55
4.2.1. Definicija metapodataka 56
4.2.2. Klasifikacija metapodataka i razine definiranja 58
4.2.3. Metapodatkovne strukture 60
4.2.3.1. Aplikacijski profil 61
4.2.3.2. Model domene 63
4.2.4. Metapodatkovne sheme u arheologiji 65
4.2.4.1. Dublin Core (DC) 66
4.2.4.2. The Digital Archaeological Record (tDAR) 67
4.2.4.3. Archaeology Data Service (ADS) 69
4.2.4.3.1. Pregled metapodatkovnih elemenata sadržajnih stavki 70
4.2.4.4. MAPPA Open Data Metadata (MOD) 74
4.2.4.5. Connecting Archaeology and Architecture in Europeana (CARARE) 75
4.2.5. Dodatni metapodatci iz istraživanja i standarda 78

4.3. Pretraživanje 81
4.3.1. Korisnik 84
4.3.2. Sučelje 85
4.3.3. Web prostor 86

4.4. Prepoznatljivost i jednoznačnost u digitalnom okruženju 88
4.4.1. Značajni trajni identifikatori 90
4.4.1.1. Uniform Resource Names (URN) 91
4.4.1.2. Handle sustav 91
4.4.1.3. Digital Object Identifier (DOI) 93
4.4.1.4. European Persistent Identifier Consortium (ePIC) 94
4.4.1.5. Archival Resource Key (ARK) 95
4.4.2. Identifikacija elemenata usporedbe 96

4.5. Zaključno razmatranje 97

5. ISTRAŽIVAČKI DIO 102

5.1. Relevantni metapodatkovni elementi 102
5.1.1. Elementi povijesti istraživanja 103
5.1.2. Elementi projekta 104
5.1.3. Elementi osnovne strukture 106
5.1.4. Elementi konteksta 109
5.1.5. Elementi sadržajnih stavki 110
5.1.6. Zaključno razmatranje 113

5.2. Važni metapodatkovni elementi za stručnjake iz područja 114
5.2.1. I. iteracija 115
5.2.1.1. Mjerni instrument 116
5.2.1.2. Stručna skupina 118
5.2.1.3. Kriteriji u I. iteraciji 119

5.2.1.4. Rezultati I. iteracije 120
5.2.2. II. iteracija 124
5.2.2.1. Mjerni instrument 125
5.2.2.2. Stručna skupina 126
5.2.2.3. Kriteriji II. iteracije 127
5.2.2.4. Rezultati II. iteracije 127
5.2.3. III. iteracija 129
5.2.3.1. Mjerni instrument 129
5.2.3.2. Stručna skupina 129
5.2.3.3. Kriteriji III. iteracije 130
5.2.3.4. Rezultati III. iteracije 132
5.2.4. Zaključno razmatranje 134

5.3. Modeliranje aplikacijskog profila 137
5.3.1. Funkcionalni zahtjevi 137
5.3.2. Modeliranje domene 139
5.3.3. Metapodatkovni elementi aplikacijskog profila 143
5.3.4. Aplikacijski profil označen i opisan putem XML 147
5.3.4.1. XML dokument 148
5.3.4.2. XML Schema 150
5.3.5. Zaključno razmatranje 158

5.4. Prepoznatljivost i jednoznačnost u aplikacijskom profilu 160
5.4.1. Usporedba i odabir trajnog identifikatora 161
5.4.2. Zaključno razmatranje 163

5.5. Mapiranje istraživačkih baza i aplikacijskog profila 164
5.5.1. Opis postojećih istraživačkih baza podataka iz područja arheologije 165
5.5.2. Mapiranje atributa baza podataka i metapodatkovnih elemenata aplikacijskog profila 169
5.5.3. Zaključno razmatranje 171

5.6. Korisnička percepcija razvijenog aplikacijskog profila 173
5.6.1. Uzorak 174
5.6.2. Mjerni instrument i provedba istraživanja 175
5.6.3. Rezultati istraživanja 178
5.6.3.1. Demografski podatci 178
5.6.3.2. Digitalne kompetencije ispitanika 179
5.6.3.3. Važni elementi za ispitanike 182
5.6.3.4. Procjena elemenata aplikacijskog profila od strane ispitanika 185
5.6.3.5. Analiza elementa aplikacijskog profila u stvarnom okruženju 187
5.6.4. Zaključno razmatranje 191

6. ZAKLJUČAK 196

6.1. Znanstveni doprinos 200

6.2. Smjernice za daljnja istraživanja 200

7. LITERATURA I KORIŠTENI IZVORI 202

SAŽETAK 218

Summary **219**

PRILOZI 221
Prilog 1. Metapodatkovni elementi entiteta Povijesti istraživanja 221
Prilog 2. Metapodatkovni elementi entiteta Projekt 222
Prilog 3. Metapodatkovni elementi entiteta Osnovne strukture 224
Prilog 4. Metapodatkovni elementi entiteta Kontekst 230
Prilog 5. Metapodatkovni elementi entiteta Dokumenti i tekstovi 231
Prilog 6. Metapodatkovni elementi entiteta Publikacije 232
Prilog 7. Metapodatkovni elementi entiteta Tablice 233
Prilog 8. Metapodatkovni elementi entiteta Baze podataka 233
Prilog 9. Metapodatkovni elementi entiteta Vektorska grafika 234
Prilog 10. Metapodatkovni elementi entiteta Rasterska grafika 235
Prilog 11. Metapodatkovni elementi entiteta Digitalni video 236
Prilog 12. Metapodatkovni elementi entiteta Digitalni zvuk 237
Prilog 13. Metapodatkovni elementi entiteta Prostorna istraživanja 238
Prilog 14. Metapodatkovni elementi entiteta Istraživanja bespilotnim letjelicama 239
Prilog 15. Metapodatkovni elementi entiteta Geofizička istraživanja 240
Prilog 16. Metapodatkovni elementi entiteta Istraživanje podmorja 241
Prilog 17. Metapodatkovni elementi entiteta Lasersko skeniranje 242
Prilog 18. Metapodatkovni elementi entiteta Kronološka istraživanja 244
Prilog 19. Metapodatkovni elementi entiteta CAD 246
Prilog 20. Metapodatkovni elementi entiteta 3D Model 251
Prilog 21. Digitalna kompetencija - 1.1. Pregledati, pretražiti i filtrirati podatke, informacije i digitalni sadržaj 253
Prilog 22. Digitalna kompetencija - 1.2. Vrjednovati podatke, informacije i digitalni sadržaj 254
Prilog 23. Digitalna kompetencija - 1.3. Upravljati podatcima, informacijama i digitalnim sadržajem 255
Prilog 24. Digitalna kompetencija - 2.2. Dijeliti podatke, informacije i sadržaj putem digitalne tehnologije 256
Prilog 25. Digitalna kompetencija - 2.4. Surađivati putem digitalne tehnologije 257
Prilog 26. Digitalna kompetencija - 3.1. Razviti digitalni sadržaj 258
Prilog 27. Digitalna kompetencija - 3.2. Integrirati i ponovno razviti digitalni sadržaj 259
Prilog 28. Digitalna kompetencija - 3.3. Uvažavati te primijeniti autorska prava i dozvole 260
Prilog 29. Digitalna kompetencija - 5.1. Prepoznati potrebe i pronalaziti tehnološka rješenja 261
Prilog 30. Digitalni objekt, podatci i metapodatkovni elementi 262
Prilog 31. Rezultati procjene aplikacijskog profila od strane korisnika 263
Prilog 32. Rezultati o važnosti elemenata – 1. situacija 264
Prilog 33. Rezultati o važnosti elemenata – 2. situacija 265
Prilog 34. Rezultati o važnosti elemenata – 3. situacija 266
Prilog 35. Rezultati o važnosti elemenata – 4. situacija 267
Prilog 36. Rezultati o važnosti elemenata – 5. situacija 268
Prilog 37. Popis oznaka i kratica 269
Prilog 38. Popis slika 273
Prilog 39. Popis tablica 274

ŽIVOTOPIS AUTORA 275

Author's Biography **275**

1. UVOD

Većina današnjih istraživača i praktičara slažu se kako učinkovito stjecanje i razmjena znanja ima presudnu ulogu u razvoju ljudskog društva i ekonomiji pojedinih država. Društvo i ekonomija utemeljeni na znanju iskazuju sve veću potrebu za interdisciplinarnim pristupima u istraživanju. Slijedom toga, potreba dijeljenja podataka, informacija i znanja te njihova otvorenost, postali su imperativ napretka. Načela otvorenosti odnose se na to da svatko može slobodno pristupiti, uporabiti, mijenjati i dijeliti u bilo koju svrhu predmet od interesa (Open Knowledge, 2015).

Kultura otvorenosti u znanosti gradi se od ranih devedesetih kroz pokret otvorenog pristupa znanstvenim publikacijama. Postepeno je taj pokret prerastao u inicijative otvorene znanosti, kojoj je cilj dijeljenje rezultata istraživanja sa širokim krugom korisnika odmah nakon potvrđivanja, odobrenja ili ispunjenja zakonske regulative. Pored publikacija, otvorena znanost podrazumijeva dijeljenje cjelokupnog istraživačkog procesa, pri čemu se prvenstveno misli na otvorene istraživačke podatke i otvoreni kod.

Važnost pristupa, razmjene i ponovne uporabe istraživačkih podataka, kao i njihove otvorenosti, istaknuta je u mnogim dokumentima, npr. deklaracijama (npr. Berlinska deklaracija iz 2003), smjernicama (npr. Organizacije za ekonomsku suradnju i razvoj iz 2007), izvještajima (npr. izvještaj The Royal Society iz 2012) i dr. Europska komisija preporukama (Europska komisija, 2012), (Europska komisija, 2018) predlaže svojim članica usvajanje politika kojima će se osigurati javna dostupnost, svrhovitost i mogućnost ponovne uporabe istraživačkih podataka koji nastaju u okviru istraživanja financiranih javnim sredstvima. Svrha tih preporuka je učinkovitije korištenje sredstava koja se ulažu u znanost te poticanje inovativnosti u cilju boljitka društva i bržeg razvoja gospodarstva.

Otvorenost u kontekstu znanstvenih istraživanja ne podrazumijeva samo razmjenu informacija, već i dijeljenje podataka, rezultata, metoda i alata koji su potrebni za razumijevanje, validaciju i primjenu informacija (Resnik, 2006). Dijeljenje se ne odnosi samo na znanstvene publikacije, već i na izvorne podatke, digitalnu reprezentaciju, grafičke materijale kao i multimedijalne materijale (Fecher i Friesike, 2013). Razloge za

dijeljenje i ponovnu uporabu publikacija, istraživačkih podataka i dr. možemo tražiti u kreiranju novih resursa za obrazovanje, poticanju znanstvene rasprave, suradnji između stvaratelja podataka, povećanju transparentnosti i odgovornosti, smanjenju troškova, povećanju utjecaja i vidljivosti istraživanja, osiguranju boljeg pristupa podatcima, ubrzanju pronalazaka te kreiranju novih usluga i proizvoda.

Primjena digitalne tehnologije[1] u području humanističkih znanosti ima značajne učinke na pripadajuće discipline, omogućavajući im nove pristupe i metode u istraživanju ljudskog društva (npr. digitalna humanistika, digitalna arheologija). Discipline iz područja humanističkih znanosti kao što su arheologija, zooarhelogija, povijest, i dr., temelje se na prikupljanju i analizi različitih vrsta podataka, opisujući i interpretirajući npr. različite antičke zapise, životinjske kosti kao i različite izrađevine pronađene u tlu.

Arheologija je disciplina čija je praksa snažno ovisna o podatcima i informacijama koje su stvorili istraživači, a koje su dostupne kroz duže vremensko razdoblje u svrhu ponovne uporabe i analize (Jeffrey, 2012). Kako bi ti podatci bili raspoloživi što širem krugu istraživača, studenata i zainteresiranih osoba potrebno je korištenjem novih digitalnih tehnologija uspostaviti nove načine diseminacije istraživačkih podataka.

[1] Digitalna tehnologija je skupni pojam za bilo koji proizvod koji se može primijeniti za kreiranje, pregled, distribuciju, modificiranje, pohranjivanje, dohvat, prijenos i zaprimanje podataka u digitalnom obliku.

1.1. Znanstvene spoznaje i identifikacija problema

U akademskom okruženju u području arheologije još uvijek su većinom zastupljeni tradicionalni načini objave i razmjene istraživačkih podataka putem knjiga i znanstvenih članaka, kao i neobjavljeni izvještaji i druge vrste publikacija. U njima su sadržane interpretacije istraživanja kao i odabrani skupovi istraživačkih podataka, najčešće predstavljeni kao tablice, grafički prikazi i sl. Tijekom arheoloških istraživanja pronalaze se velike količine arheoloških entiteta[2], a time i istraživačkih podataka, koji ne mogu biti uključeni u tradicionalne načine publiciranja. Arhivirani arheološki entiteti izvor su njihovih interpretacija, kao i jedino sredstvo budućih reinterpretacija. Ustaljena dobra praksa je stoga arhiviranje pojedinih arheoloških entiteta za ponovnu uporabu u dužem vremenskom periodu. Arheološki dokumenti i pojedini arheološki entiteti pohranjuju se uglavnom na fizičkim lokacijama, npr. u muzejima.

Arheološki podatci nastaju opažanjima i mjerenjima arheološkog entiteta i njegovog konteksta. Podatci mogu nastati tijekom istraživanja ili pri aktivnostima analize poslije istraživanja pojedinog arheološkog entiteta. Uporabom digitalnih tehnologija stvaraju se velike količine različitih digitalnih podataka i dokumentacije, a pojedine studije ukazuju na problem nepostojanja odgovarajućih alata za njihovu diseminaciju (Kansa, Kansa i Schultz, 2007). Pored toga, među istraživačima ne postoji konsenzus o standardima zapisa arheoloških entiteta i povezanih istraživanja, što rezultira izgradnjom zasebnih i nestandardiziranih digitalnih repozitorija s različitim podatkovnim modelom.

Znanstvena istraživanja u području otvorenih istraživačkih podataka ukazuju na sve veću primjenu otvorenih istraživačkih podataka i digitalnih repozitorija u području arheologije. Tako možemo istaknuti primjere Ujedinjenog Kraljevstva i njihovog sustava *Archaeology Data Service* i Italije sa sustavom *Sistema Informativo Territoriale Archelogico Di Roma* te projektom *Metodologie applicate all predittivita del potenziale archeologico*. Navedenim sustavima i projektima države nastoje osigurati veću dostupnost arheoloških digitalnih resursa (npr. istraživačkih podataka, izvještaja, fotografija, prostornih podataka i dr.).

[2] U okviru ovog rada pod arheološkim entitetom podrazumijevamo nešto što samostalno postoji, što možemo jednoznačno odrediti, identificirati i razlikovati, a proizlazi iz arheoloških istraživanja vezanih uz izrađevine, ekofakte i materijalnu kulturu. Opširniji je opis je naveden u nastavku rada.

Objavljivanje otvorenih istraživačkih podataka zahtijeva promišljanje o odabiru podataka na početku procesa kao i definiranje pravila privatnosti i povjerljivosti pri čemu sam proces objave podataka mora biti dobro definiran i standardiziran dio svakodnevnih procedura i rutina, a u svrhu ponovne uporabe potrebno je provoditi nadzor nad objavljenim podatcima (Zuiderwijk *et al.*, 2014). Upravljanje istraživačkim podatcima tijekom životnog ciklusa podataka je jedan od važnijih segmenata u okviru sveobuhvatnog i cjelovitog istraživačkog procesa.

Najvažniji dionici životnog ciklusa otvorenih istraživačkih podataka su istraživači koji prikupljaju, analiziraju i dijele podatke te rade na njihovom očuvanju i arhiviranju, kao i istraživači-korisnici koji pronalaze podatke, preuzimaju podatke, prosuđuju njihovu vrijednost te ih ponovno koriste u vlastitim istraživanjima. Kritičnim fazama možemo smatrati pripremu podataka za objavu i dijeljenje, kao i pronalaženje istih pri čemu ključnu ulogu imaju metapodatci. Potvrdu važnosti metapodataka za otvorene istraživačke podatke ističe britansko udruženje znanstvenika The Royal Society (The Royal Society, 2012), koje ukazuje na nužnost opisivanja istraživačkih podataka metapodatcima kako bi bili raspoloživi drugim korisnicima. Objava samo sirovih podataka, bez pratećih metapodataka, odražava siromašan i nerazumljiv znanstveni proces (Watson, 2015), a dostupnost istraživačkih podataka kroz dulje vremensko razdoblje uvelike ovisi o dostupnosti odgovarajućih metapodataka (Fegraus *et al.*, 2005).

Metapodatke možemo općenito opisati kao strukturirane podatke o entitetima koji podržavaju pretraživanje, upravljanje, uporabu resursa u zajednici kao i međusobno povezivanje resursa. Postoje različiti standardi i sheme metapodataka za opisivanje istraživačkih podataka, pri čemu je većina specijalizirana za opisivanje vrlo specifičnih podataka. Najčešće se koristi specijalizirana shema, namijenjena uskom području, zatvorene naravi koja ne omogućava širu primjenu i olakšani pristup zapisima. Još uvijek ne postoje opće prihvaćeni standardi i sheme, što rezultira otežanom razmjenom podataka i pronalaženjem podataka u svrhu daljnjeg istraživanja.

Usmjerenje prema otvorenoj znanosti i istraživačkim podatcima te razvoj novih digitalnih tehnologija omogućava dostupnost podataka kao i njihovu samostalnu pretragu velikom broju istraživača, studenata i zainteresiranih dionika. Realizacija otvorenih istraživačkih podataka temelji se na primjeni digitalne tehnologije, a njihova uporaba u velikoj je ovisnosti o kreiranju potrebnih metapodatkovnih shema i izgradnji

istraživačkih repozitorija te sustava za pretraživanja. Istraživanjem raspoložive literature i sadržaja u kontekstu otvorenih istraživačkih podataka, utvrđeno je da su najzastupljenije sljedeće metapodatkovne sheme: *Dublin Core, The Digital Archaeological Record, Archeaology Data Service, MAPPA Open Data Metadata i Connecting Archeology and Architecture in Europeana*. Prethodne metapodatkovne sheme različitih su struktura, složenosti, zahtjevnosti i namjene.

Otvoreni istraživački podatci imaju potencijal za mnoga unaprjeđenja, a proces njihovog učinkovitog stvaranja još je uvijek složena i nedovoljno istražena aktivnost. Nedostatak standardnih procesa publiciranja, nejasna, nedostatna i restriktivna pravila uporabe, nedovoljan broj objavljenih skupova podataka, nestandardizirani načini upravljanja istraživačkim podatcima i značajni troškovi, samo su neki od problema koji se javljaju u području otvorenosti. Otvaranje istraživačkih podataka često se prezentira kao nešto što je jednostavno ostvariti, međutim, postojeća znanstvena istraživanja ukazuju na složenost procesa koji je potrebno dobro razumjeti te odgovarajuće provoditi kako bi podatci bili dostupni i spremni za ponovnu uporabu. Prije kreiranja sustava otvorenih istraživačkih podataka potrebno je odlučiti o odgovarajućoj metapodatkovnoj shemi kojom se opisuju skupovi podataka te dobro definirati procedure i procese koji se koriste za njihovu objavu. Dobro opisani otvoreni istraživački podatci utjecat će na lakoću njihovog pronalaženja i mogućnosti ponovne uporabe za nova istraživanja, a slijedom toga i na dobrobit šire javnosti.

Hrvatska je bogata arheološkim podatcima, a u sklopu novih projekata i istraživanja svakodnevno se stvaraju novi podatci. Još uvijek ne postoje razvijeni modeli sustava upravljanja podatcima i informacijama koji osiguravaju dostupnost, povezivanje te ponovnu uporabu otvorenih istraživačkih podataka iz ovog područja. Identificirane su pojedine aktivnosti u svrhu ostvarenja otvorenosti u području istraživačkih podataka, međutim one su tek u začecima i još uvijek ne osiguravaju dostupnost istraživačkih podataka. U svrhu izgradnje novih informacijskih sustava za potporu istraživanjima te učinkovitu znanstvenu komunikaciju u području arheologije, kao i omogućavanje dostupnosti podataka širem krugu potencijalnih korisnika, nužno je provesti istraživanje o metapodatkovnim shemama te definirati uspostaviti efektivnu metapodatkovnu shemu za otvorene istraživačke podatke.

1.2. Ciljevi i istraživačka pitanja

Ciljevi ovog istraživanja su:

- Identificirati i vrjednovati postojeće sheme metapodataka u području arheologije te utvrditi njihovu prikladnost za otvorene istraživačke podatke;
- Preispitati elemente metapodatkovnih shema iz područja arheologije u kontekstu otvorenih istraživačkih podataka;
- Na temelju istraživanja razviti konkretni aplikacijski profil za organizaciju istraživačkih podataka u području arheologije;
- Utvrditi korisnost i prikladnost razvijenog aplikacijskog profila kod šireg kruga korisnika.

U svrhu postizanja ciljeva razvijena su sljedeća **istraživačka pitanja:**

RQ1. Koji su elementi iz postojećih metapodatkovnih shema i znanstvenih istraživanja iz područja arheologije relevantni za kontekst otvorenih istraživačkih podataka?

RQ2. Koji su elementi iz postojećih metapodatkovnih shema i iz relevantnih znanstvenih istraživanja važni za opisivanje i pretraživanje arheoloških entiteta za stručnjake iz područja arheologije u Hrvatskoj u kontekstu otvorenih istraživačkih podataka?

RQ3. Na koji se način u okviru razvijenog aplikacijskog profila osigurava prepoznatljivost i jednoznačnost zapisa arheološkog entiteta u digitalnom okruženju?

RQ4. U kojoj mjeri postojeće istraživačke baze podataka iz područja arheologije odgovaraju razvijenom aplikacijskom profilu?

RQ5. Kakva je korisnička percepcija razvijenog aplikacijskog profila s obzirom na prepoznavanje ili neprepoznavanje korisnosti pojedinog metapodatkovnog elementa u okviru stvarnog okruženja (npr. pretraživanja)?

1.3. Metodologija istraživanja

Istraživanje za potrebe ovog rada podijeljeno je u pet faza. Svaka je faza opisana u nastavku rada. U okviru pojedine faze opisane su znanstvene metode i tehnološka rješenja te koja se postavljena istraživačka pitanja u njoj rješavaju.

1.3.1. Prva faza

U prvoj fazi primijenit će se metode analize (npr. identificirati, raščlaniti, razlikovati, usporediti), sinteze (npr. povezati) i vrjednovanja (npr. kritički prosuditi) iz znanstvene literature kako bi se spoznali pojmovi, trenutačni dosezi i zahtjevi vezani uz: otvorenost u području znanosti, otvorene istraživačke podatke u području arheologije, vrste arheoloških podataka, opću funkcionalnost istraživačkih repozitorija, metapodatkovne sheme u području arheologije i njihove elemente te trajne identifikatore u svrhu donošenja kvalitativnog suda o uočenim pojmovima.

Ova faza istraživanja obuhvaća znanstvene članke iz časopisa, ostale znanstvene publikacije kao i izvještaje koje se odnose na problematiku otvorenih istraživačkih podataka.

Radovi su analizirani s ciljem razumijevanja i utvrđivanja fenomena vezanih u tematiku ovog rada. Fenomene možemo opisati kao skup ponašanja nekog entiteta koji je u interesu istraživača ili zajednice, a razumijevanje kao znanje koje omogućava predviđanje ponašanja pojedinih aspekata fenomena (Hevner i Chatterjee, 2010). Fenomene možemo opisati i kao konstrukte, apstrakciju iz mnoštva detalja koje nam pomažu u razumijevanju i vizualizaciji (Carlile i Christensen, 2005).

1.3.2. Druga faza

Druga faza sastoji se od tri podfaze. Prva je podfaza povezana uz identificiranje važnih entiteta i metapodatkovnih elemenata iz područja arheologije u svrhu primjene u praćenju istraživačkog životnog ciklusa. Identifikacija elemenata provesti će se na temelju utvrđenih metapodatkovnih shema i standarda, s ciljem identifikacije elemenata koji se odnose na istraživački sadržaj, te moguće pojavne oblike u kontekstu otvorenosti. Prvom podfazom daje se odgovor na prvo istraživačko pitanje (*RQ1)*. Utvrđeni elementi

su temelj za drugu podfazu. U njoj će se uz pomoć hrvatskih stručnjaka u području arheologije provesti istraživanje metapodatkovnih elemenata važnih za opisivanje i pretraživanje otvorenih istraživačkih podataka. Ishod ove faze bit će definirani elementi koji će se primijeniti za izradu aplikacijskog profila. Za utvrđivanje važnih metapodatkovnih elemenata primijenit će se Delphi metoda. Ova je metoda odabrana s obzirom na mali broj istraživanja o metapodatkovnim elementima, načinu pretraživanja podataka u digitalnom okruženju u području arheologije te nužnosti osiguravanja objektivnih informacija. U slijedećem pod poglavlju je opisana Delphi metoda.

Treća podfaza odnosi se na izradu aplikacijskog profila. Aplikacijski profil je metapodatkovna shema koja je u okviru ovog rada namijenjena primjeni u području arheologije u kontekstu otvorenih istraživačkih podataka, a sam aplikacijski profil sastoji se od metapodatkovnih elemenata.

U središtu ovog dijela istraživanja su korisnici, npr. stručnjaci iz područja kao i širi krug korisnika. S obzirom na usmjerenost na korisnika, izrada aplikacijskog profila u okviru ovog rada temelji se na metodološkom okviru DCMI „Singapore Framework“, te objavljenim studijama (Malta i Baptista, 2013), (Ochiai, Nagamori i Sugimoto, 2014) i (Malta i Baptista, 2017). Daljnji koraci u izradi aplikacijskog profila odnose se na identificiranje i opisivanje funkcionalnih zahtjeva, definiranje modela domene te identifikaciju i opise elemenata. Model domene bit će definiran korištenjem modela Funkcionalnih zahtjeva bibliografskih zapisa (FRBR). Ovaj je model odabran s obzirom na njegovu usmjerenost na korisnike te omogućavanje generičkih zadataka koji se odnose na pronalazak, identifikaciju, odabir i pristup resursu od interesa. Aplikacijski profil bit će prikazan u obliku tablice gdje će za svaki metapodatkovni element biti navedeno: oznaka, ime, definicija, obveznost, pojavnost, tip podataka i primjer.

Aplikacijski profil biti će izražen korištenjem XML sheme. Za novo definiranu shemu napraviti će se validacija kako bi se osigurala njezina ispravnost.

1.3.2.1. Delphi metoda

Delphi metoda je znanstvena tehnika za predviđanje i pripomoć u donošenju odluka na temelju mišljenja stručnjaka iz određenog područja i ostvarenja konsenzusa. U novije vrijeme pojedina istraživanja ukazuju na to da se radi o tehnici koja eliminira obavezno traženje i postizanje konsenzusa, tako da se ova tehnika može opisati i kao

tehnika društvenog istraživanja čiji je cilj dobivanje stvarnog mišljenja grupe stručnjaka (Landeta, 2006).

Kao metoda korisna je u studijama u kojima postoji mala količina podataka i informacija (Jaana *et al.*, 2011), nije u ovisnosti od statističkog uzorka (Okoli i Pawlowski, 2004) i omogućava troškovno prihvatljivo istraživanje (Goluchowicz i Blind, 2011). Delphi metoda je vrlo prikladna za istraživanja vezana uz definiranje i stvaranje teorije, multidisciplinarna istraživanja, a posebno u analizi budućih trendova (Worrell, Gangi i Bush, 2013). Nju je moguće primijeniti u svrhu: razvoja teorijskih pretpostavki, gdje pomaže u inicijalnom identificiranju čimbenika od interesa i generiranje prijedloga; proširenja empirijskih promatranja na temelju kojih je utemeljena inicijalna teorija; usklađenja mišljenja stručnjaka; definiranja konstrukta i potvrđivanja njihove vrijednosti (Okoli i Pawlowski, 2004).

Ovu metodu možemo opisati kao visoko formaliziranu metodu komunikacije između istraživača i panela stručnjaka, koja je pripremljena tako da se dobije maksimalna količina objektivnih informacija (Iden, Tessem i Päivärinta, 2011). Objektivne informacije postižu se pomoću iterativnog i strukturiranog procesa oglašavanja, pročišćivanja i agregiranja mišljenja i pogleda grupa stručnjaka (van Deursen, Buchanan i Duff, 2013). U kontekstu strukturiranog procesa važni su sljedeći elementi: povratna informacija o doprinosu, procjena ili pogled skupine stručnjaka, prilika da pojedinac može promijeniti svoju procjenu te osiguravanje anonimnosti individualnih stručnjaka (Okoli i Pawlowski, 2004).

Općenito se Delphi istraživanje sastoji od četiri faze: a) sastavljanje panela stručnjaka, b) protok ideja c) sužavanje i d) vrjednovanje i rangiranje, a operativno se provodi specifikacijom istraživačkih pitanja, određivanjem skupina stručnjaka te analizama i interpretacijama (Worrell, Gangi i Bush, 2013).

Kroz razvoj metode dolazilo se do niza modifikacija. Modifikacije koje su bitne za ovaj rad vezane su uz: protok ideja (umjesto protoka ideja o činiteljima i problemu, činitelji se uzimaju iz postojećih istraživanja, literature, metodoloških okvira koji su relevantni za problem) te odabir i sastav skupina stručnjaka.

Postupak odabira stručnjaka prema (Okoli i Pawlowski, 2004) obuhvaća određivanje kvalificiranih stručnjaka koji imaju duboko razumijevanje područja i daju učinkoviti doprinos. Stručnjaci moraju biti visoko kvalificirani s potpunim

razumijevanjem i znanjem iz područja istraživanja. Za postupak odabira stručnjaka u istraživanju Idena i suradnika primijenjeni su kriteriji duge karijere u području kao i postojeća pozicija (Iden, Tessem and Päivärinta, 2011). Opsežnim pregledom istraživanja povezanih uz Delphi metodu Worrell i suradnici navode da se broj stručnjaka u istraživanjima kreće od 10 do 30 po istraživanju. Zauzimaju stav da bi manji broj stručnjaka dolazio u obzir samo u slučajevima u kojima stručnjaci pokazuju duboko razumijevanje područja istraživanja, te ako postoje uvjeti da je nekoliko stručnjaka sposobno doprinijeti rješenju problema (Worrell, Gangi and Bush, 2013). Postotak stručnjaka koji mora ostati u postupku istraživanja, mora biti iznad 70% po pojedinom krugu koji je proveden (van Deursen, Buchanan i Duff, 2013).

U fazi sužavanja cilj je dobivanje kvantitativnih podataka kao i klasifikacija čimbenika u kategorije temeljem prethodnih upitnika i dobivenih rezultata (preporuka, mogućih alternativa). U ovoj fazi uzimaju se u obzir samo čimbenici koje je identificiralo najmanje 50% ispitanika (Iden, Tessem i Päivärinta, 2011). Ovaj kriterij biti će primijenjen tijekom istraživanja.

Kroz fazu vrjednovanje i rangiranje želi se postići konsenzus ili dobiti grupno mišljenje stručnjaka o relevantnim činiteljima. Istraživanja uporabljaju različite metode za mjerenje ostvarenja konsenzusa. Postojeće metrike su: Kendallov koeficijent, interkvartilni interval (Ramos, Arezes i Alfonso, 2016), mjere centralne tendencije (Thangaratinam i Redman, 2005), Kappa statistika (Holey *et al.*, 2007), mjere ordinalne disperzije temeljem Shannonove Entropije (Tastle i Wierman, 2007), neizrazita logika (Li, 2013) i geometrijski koncepti (Rahem i Darrah, 2018). Za utvrđivanje konsenzusa u istraživanju se koristi Tastle &Wiermanova mjera ordinalne disperzije.

U svrhu osiguravanja vjerodostojnosti istraživanja primjenom Delphi metode, u obzir je potrebno provesti i uzeti u obzir sljedeće: kontekst istraživanja, ciljeve i postupak istraživanja; odrediti način definiranja i nizanja pitanja te dobivanja odgovora, zajedno s kvantitativnim pokazateljima kao i statističkim indikatorima; utemeljiti tumačenje kvalitativnih rezultata na dobivenim argumentima; detaljno opisati proces koji je doveo do rezultata i razloga primijenjene tehnike i postupaka te primijeniti objektivne kriterije koji osiguravaju kvalitetu procesa i dobivenih odgovora od stručnjaka (Landeta i Barrutia, 2011).

Provedbom Delphi istraživanja bit će identificirani važni metapodatkovni elementi kod stručnjaka u području, a ovaj dio istraživanja nam daje odgovor na drugo istraživačko pitanje (RQ2). Identificirani metapodatkovni elementi temelj su za aplikacijski profil.

1.3.3. Treća faza

Trajna, stabilna i prihvaćena adresa digitalnog objekta (digitalnog arheološkog zapisa) od presudne je važnosti za istraživače, ali i za vjerodostojnost digitalnih repozitorija. Ona omogućava jednoznačnost zapisa, njegovu identifikaciju na pouzdan i siguran način te osigurava trajni i kontinuirani pristup tijekom vremena u digitalnom okruženju. Trajni identifikatori (engl. *Persistent Identifier* ili *PID*) važni su za otvorene istraživačke podatke i sadržani su u FAIR principima: *Findable, Accessible, Interoperable and Reproducible*. U okvirima treće faze na temelju dostupne literature identificirat će se mogući trajni identifikatori u području kojeg pokriva ovaj rad, identificirati će se elementi za usporedbu, provesti usporedba te odabrati prikladan trajni identifikator koji se može primijeniti za skup podataka i na definirani aplikaciji profil u kontekstu otvorenih istraživačkih podataka. Bit će naznačena primjena trajnog identifikatora u okviru aplikacijskog profila. Trećom se fazom daje odgovor na treće istraživačko pitanje (RQ3).

1.3.4. Četvrta faza

Kroz postojeća arheološka istraživanja i projekte kreiraju se baze podataka[3] različitih namjena i struktura (npr. relacijske, nerelacijske). Jedna od namjena aplikacijskog profila je omogućavanje dostupnosti i ponovnog korištenja arheoloških istraživačkih podataka u digitalnom okruženju. U okviru ove faze analizirat će se i opisati u kojoj mjeri postojeće baze podataka iz arheoloških projekata, kao što su *Tranzicija i*

[3]Bazu podatka možemo pojednostavljeno opisati kao organizirani, strukturirani i svrhoviti skup povezanih podatka o sustavima, entitetima i događajima, odnosno aspektima iz stvarnog svijeta.

tradicija u pećini Vlakno: Prijelaz iz paleolitika u razdoblje mezolitika na području sjeverne Dalmacije i *Utvrda u Zemuniku Donjem u srednjem i novom vijeku* odgovaraju aplikacijskom profilu. Analiza će biti napravljena mapiranjem elemenata iz aplikacijskog profila s atributima iz baze podataka navedenih projekata, s obzirom na semantiku pojedinog elementa i u kontekstu osiguravanja podataka za aplikacijski profil (jednosmjerna povezanost). Mapiranje će biti prikazano kroz tablicu. Pojedinom atributu iz baze podataka bit će tijekom mapiranja pridružena oznaka + ukoliko međusobno semantički odgovaraju, a bez oznake ukoliko ne odgovaraju. Po izvršenoj analizi bit će sastavljen skupni popis elemenata i atributa koji se pojavljuju u bazama podataka i aplikacijskom profilu. Četvrtom fazom daje se odgovor na četvrto istraživačko pitanje (RQ4).

1.3.5. Peta faza

Najčešći pristupi u evaluaciji metapodataka odnose se na utvrđivanje jesu li oni odgovarajući, ispravni i u skladu s normama. U novije vrijeme prisutni su trendovi koji su usmjereni na korisnika i njegovu percepciju korisnosti metapodataka. Na razini korisnika istraživanja su povezana uz informacijsko sučelje, navigacijsku strukturu, informacijsku arhitekturu, kao i evaluaciju elemenata od strane korisnika.

Kroz ovu fazu će se preispitati, vrjednovati i kritički prosuditi kakva je korisnička percepcija s obzirom na korisnost elemenata definiranog aplikacijskog profila u pretraživanju arheoloških entiteta i raspon mogućnosti koje elementi aplikacijskog profila osiguravaju za zadovoljavanje korisničke potrebe. Istraživanje će se provesti na prigodnom uzorku studenata putem anketnog istraživanja.

Kako nam je u okviru ovog dijela istraživanja važno dobiti što detaljnije informacije o interpretaciji i razumijevanju perspektive korisnika, a kako bi prikupili informacije za moguće unaprjeđenje aplikacijskog profila, radit će se s grupama na temelju mjernog instrumenta. Predviđene su dvije grupe: jedna će obuhvatiti studente[4] prve godine preddiplomskog studija arheologije, a druga će obuhvatiti studente

[4] Termin student koji ima rodno značenje koristi se neutralno i odnosi se jednako na muški i ženski spol.

arheologije završne godine diplomskog studija. Planirani broj sudionika po pojedinoj grupi je 10 +/- 2.

Ovaj dio istraživanja sastoji se od provedbe četiriju podfaza. Prva se podfaza odnosi na dobivanje demografskih podataka i podataka o digitalnoj kompetenciji ispitanika iz grupa, što će biti napravljeno kroz mjerni instrument o demografskim podatcima, i procjeni digitalnih kompetencija ispitanika s obzirom na metodološki okvir Digitalnih kompetencija (DigComp). U okviru istraživanja koristi se inačica br. 2 metodološkog okvira, definirana i opisana kroz izvještaj (Vuorikari *et al.*, 2016). Druga se podfaza odnosi na identificiranje elemenata za koje ispitanici smatraju da su im korisni za pretraživanje arheološkog entiteta u digitalnom okruženju i u kontekstu otvorenih istraživačkih podataka. U ovom dijelu ispitanici će samostalno vlastitim riječima opisati ključni skup elemenata. Treća je podfaza usmjerena na prosudbu relevantnosti elemenata koje su definirali stručnjaci za potrebe izrade aplikacijskog profila. Ispitanicima će biti prezentirani elementi aplikacijskog profila i Likertova skala s 5 razina za važnost svakog elementa. Neće im biti na raspolaganju opisi elemenata, a ispitanici će napraviti prosudbu na temelju dosadašnjeg znanja i iskustva. Cilj je utvrditi varijabilnost procjene na razini svih korisnika. Četvrta je podfaza usmjerena na utvrđivanje korisnosti relevantnosti elemenata aplikacijskog profila u kontekstu pronalaženja arheoloških entiteta, njihovu identifikaciju temeljem opisnih elemenata, odabir elementa koji odgovara korisničkim potrebama ili postavljenom zadatku te na utvrđivanju elemenata koji su bitni za ponovnu uporabu. Unaprijed će biti pripremljen jednostavni digitalni repozitorij s podatcima o arheološkim entitetima i osnovnim sučeljem za pretraživanje koji sadrže elemente aplikacijskog profila u svrhu demonstriranja pretraživanja. Sudionici istraživanja će biti upoznati s metapodatkovnim elementima i načinom pretraživanja. Bit će pripremljeno pet situacija pretraživanja iz područja arheologije. Za svako pretraživanje od strane ispitanika bit će označeni elementi koji su potrebni za pronalazak, identifikaciju, odabir i ponovnu uporabu digitalnog objekta. Ispitanicima će biti ostavljena mogućnost navođenja opažanja o elementima koji su značajni, a nisu navedeni ili stvaraju poteškoće u identifikaciji, odabiru ili ponovnoj uporabi. Tijekom ovog dijela istraživanja, sve što neće biti obuhvaćeno kroz mjerni instrument bit će zapisano, kodirano i interpretirano. Za opisivanje podataka korist će se deskriptivna statistika, a za utvrđivanje statistički

značajnih razlika neparametrijski χ^2 test. Petom fazom daje se odgovor na peto istraživačko pitane (*RQ5).*

1.4. Ograničenja u istraživanju

Ograničenja koja postoje u ovom radu povezana su uz elemente i pojedine funkcionalnosti digitalnih repozitorija, mjerni instrument te korisničku skupinu. Tijekom analize u obzir nisu uzeti elementi kojima bi se mogli opisati događaji i aktivnosti koji se mogu povezati uz arheološke entitete ili prostor na kojem su pronađeni. Također u obzir nisu uzeti elementi kojima se može napraviti proširenje funkcionalnosti digitalnog repozitorija u kontekstu stvaranja alata za znanstveno-istraživačke aktivnosti (npr. kreiranje istraživačkih kolekcija kojima bi se stvorili novi alati istraživanja, tehničke karakteristike). U okviru mjernog instrumenta korištena je ordinalna mjerna skala te je moguće da pojedine vrijednosti nisu dovoljno dobro obuhvaćene.

Kako je odabrana samo jedna korisnička skupina s prigodnim uzorkom mogućnost uopćavanja rezultata korisničke percepcije aplikacijskog profila ovog istraživanja je ograničena, ali rezultati mogu poslužiti kao inicijalni pokazatelji postupanja i promišljanja šireg kruga korisnika o temi iz predmeta istraživanja.

1.5. Etički aspekti istraživanja

Pri istraživanju vodilo se računa o etičnosti istraživanja kako bi se osiguralo da niti jedna strana koja je sudjelovala u istraživanju nije oštećena i nema neželjenih posljedica. Kod provođenja istraživanja sudionicima je objašnjena priroda istraživanja te koji se podatci prikupljaju. Sudionici su sudjelovali u istraživanju dobrovoljno, a svakome je sudioniku osigurana anonimnost i tajnost Za istraživanje sa studentima dobivena je suglasnost Etičkog povjerenstva Sveučilišta u Zadru.

2. OSNOVNI POJMOVI

Arheologija je područje znanosti u kojem se primarno razumijevanje prošlih društava i društvenih događaja provodi putem analize materijalnih ostataka i istraživanjem podataka iz dokumentacije različitih vrsta arheoloških istraživanja. Interpretacija materijalnih ostataka i dokumentacije najčešće zahtijeva interdisciplinarnost s drugim područjima (npr. biologija, geologija). Pronađeni i arhivirani arheološki nalazi izvori su istraživačkih interpretacija, kao i jedino sredstvo budućih reinterpretacija.

Koncepti kao što su podatak, informacija i znanje smatraju se temeljnim konceptima informacijskih znanosti, a njihovo značenje uvelike ovisi o kontekstu te ne postoje jedinstvene i globalno prihvaćene definicije. Podatak, informacija i znanje međusobno su povezani, a njihova se povezanost ogleda u sekvencijalnom poretku i logičkoj hijerarhiji (Zins, 2007).

2.1. Arheološki entitet

Općenito pod pojmom entiteta u području informacijskih znanosti podrazumijevamo sve što se može jednoznačno identificirati, odrediti i razlikovati. Entitet može biti svaki realni ali i apstraktni objekt[5]. Svaki entitet ima svoje atribute (obilježja) i vrijednosti atributa.

U okvirima arheoloških istraživanja na nalazištima se pronalaze materijalni ostatci kao što su: izrađevina, ekofakt i tvorevina. Arheološko nalazište je pojedina lokacija na kojoj postoji fizička evidencija ljudskih aktivnosti. Izrađevina je materijalni objekt ili modifikacija objekta koji je napravljen od strane pojedinaca, grupe ili ljudskog društva. Primjeri izrađevina su: keramika, metalni objekti (npr. oružje, nakit), koštane strjelice, amfore itd. Ekofakt je organski materijal biljnog ili životinjskog svijeta koji ima arheološki značaj. Primjeri ekofakta su: životinjske kosti, pepeo, vulkanski kamen, drveni ugljen, sjemenke itd. Tvorevina je skup jedne ili više kontekstualnih reprezentacija ljudskih aktivnosti koje nisu prenosive i općenito imaju vertikalnu karakteristiku u

[5] Objekt je bilo koji dio zamislivog ili moguće spoznajnog svijeta (Greenberg, 2003).

odnosu na stratigrafiju. Primjeri tvorevina su npr. zidovi, jarci, odvodi, ognjišta, ukopi, jame itd.

Svaki arheološki entitet ima atribute. Definiranje atributa za arheološke entitete je prvi korak u njihovoj analizi i interpretaciji. Istraživači uzimaju u obzir one atribute za koje vjeruju da su važni za razumijevanje istraživanja. Atributi arheološkog entiteta uspostavljaju se temeljem plana istraživanja i u ovisnosti od istraživačkih ciljeva (Muckle, 2006). Pojedina istraživanja pokazuju da su atributi arheoloških entiteta povezani npr. uz njihovu namjenu, način izrade, sastav, dimenzija, a opisujemo ih kroz tehnološku, funkcionalnu, morfološku i stilističku kategoriju (Banning, 2002). Kako bi se korištenjem atributa mogla provoditi daljnja istraživanja (npr. klasifikacija, tipologija) atributi moraju biti objektivni i mjerljivi (Sutton, 2016).

Atributi su reprezentirani kroz varijable i mogu imati različite vrijednosti ili stanja. Tijekom istraživanja identificirane su dvije podjele atributa.

Prva podjela atributa odnosi se na pripadanje atributa *kontekstualnoj* ili *specifičnoj* klasi (Richards i Ryan, 1985). Kontekstualni atributi su oni koji su kreirani iz konteksta arheološkog entiteta (npr. njegovog okruženja, stratigrafske jedinice, pridruženost itd.). Specifični atributi su izvedeni iz fizičkih ili kemijskih svojstava pojedinog arheološkog entiteta (npr. boja, veličina, dekoracija itd.).

Druga podjela atributa odnosi se na pripadanje atributa *kvantitativnoj* ili *kvalitativnoj* klasi (Sutton, 2016). U okvire kvantitativnih atributa pripadaju npr. dužina, širina, visina, težina kao i sve ostale karakteristike koje mogu biti izražene numeričkim vrijednostima i mjerenjima. Kvantitativnim atributima najčešće se opisuju nalazište, izrađevine, ekofakti i tvorevine. Kvalitativnim atributima opisuje se postojanje ili nepostojanje opisnih karakteristika ili svojstava npr. iz čega je izrađevina napravljena, sačuvanost nalaza i sl.

2.2. Podatak

U temelju riječi podatak je termin „*data*“ koji proizlazi iz latinske riječi „*datum*“, a čije je izvorno značenje „*stvari koje su nam dane*“. Znanstvene studije koriste različite pristupe podatcima, a slijedom toga nude i različite opise i definicije podataka. Kratki pregled različitih opisa podataka prisutnih u objavljenoj literaturi dan je u Tablici 1. Uz

svaki opis je izdvojen konstrukt opisa kako bi nam omogućio bolje razumijevanje i vizualizaciju samog pojma podatak i ukazao na različitost pristupa. U Tablicu 1. uključene su i definicije koje su navedene u rječniku opće prihvaćenog standarda Sustava i programskog inženjerstva (ISO/IEC/IEEE, 2010).

Tablica 1.: Opisi i konstrukti podataka iz literature

Izvor	Opis	Konstrukt
(Martin i Powell, 1992)	opisuju podatke kao sirov[6] materijal organizacijskog života kojeg čine npr. brojevi, riječi i simboli koji su povezani uz događaje i procese	izvornost
(Avison i Fitzgerald, 1998)	podatci su nestrukturirane činjenice	nestrukturirane činjenice
(Clare i Loucopoulos, 1987)	podatci su prikupljene činjenice nastale temeljem opažanja ili zapisivanja vezano uz objekte, događaje i ljude	nastali opažanjem ili zapisivanjem
(Introna, 1993)	podatci su sami po sebi beznačajni, mora im se dati svrsishodni oblik i kontekst kako bi imali vrijednost	kontekst i svrsishodni oblik
(Hox i Boeije, 2005)	prikupljeni podatci mogu biti korišteni i u druge svrhe u odnosu na primarnu namjenu ili od drugih istraživača	sekundarnost
(ISO/IEC/IEEE, 2010)	opisuje podatke na četiri načina: prvi opis podatke razmatra kao činjenice, koncepte ili instrukcije koje su prikladne za komunikaciju, interpretaciju ili procesiranje od strane ljudi ili strojeva; drugi opis usmjerava nas da su podatci vrijednosti nastale mjerenjima ili pokazatelji stanja (indikatori); treći opis podatke razmatra kao oblik reprezentacije informacija kojima se bave informacijski sustavi i korisnici; četvrti opis podatke opisuje kao ponovno protumačive reprezentacije informacija u formaliziranom obliku prikladnom za komunikaciju, tumačenje ili procesiranje	činjenice; mjerenje ili pokazatelji stanja; oblik reprezentacije; komunikacija; ponovno protumačiva reprezentacija

Iz prethodno navedenih opisa i izdvojenih konstrukata možemo zaključiti sljedeće o podatcima: mogu biti izvorni ili sekundarni; oni su nestrukturirane činjenice; nastaju

[6] Engleska riječ raw označava nešto što je izvorno, nije prošlo postupak obrade.

mjerenjima, pokazateljima stanja, opažanjem i zapisivanjem; u svrhu komunikacije i procesiranja mogu ih koristiti ljudi i strojevi; oblik su predočavanja informacija; imaju odliku ponovne uporabe i protumačive reprezentacije, a kako bi nam dali vrijednost moraju imati svrsishodni oblik i kontekst.

2.2.1. Istraživački podatci

Kao i kod samog pojma podatak, za istraživačke podatke ne postoji opće prihvaćena definicija (Luzi *et al.*, 2012). U nastavku je dan pregled postojećih definicija i opisa što su to istraživački podatci.

Izvještaj Europske komisije ukazuje da su istraživački podatci svi podatci koji proizlaze iz istraživanja, a iz perspektive znanstvenika uključuju podatke nastale eksperimentom, studijom ili mjerenjem, uključujući metapodatke i detalje nastale obradom podataka (Europska komisija, 2013). Prema OECD-u istraživačke podatke možemo opisati kao činjenične zapise (numerički rezultati, tekstualni zapisi, slike i zvukovi) koji se koriste kao primarni izvori za znanstvena istraživanja te su prihvaćeni od strane akademske zajednice u svrhu validacije istraživačkih pronalazaka (OECD, 2007).

Istraživačke podatke možemo opisati i kao digitalne podatke koji su rezultat znanstveno-istraživačkog procesa. Ovaj proces uključuje sve faze istraživanja od generiranja podataka do publiciranja rezultata istraživanja. Digitalni istraživački podatci mogu biti različite vrste (npr. numerički ili kvantitativni, opisni ili kvalitativni, sirovi ili analizirani, eksperimentalni ili promatrački), agregiranosti, formata (npr. csv, txt) te kreirani različitim metodama.

Istraživačke podatke možemo klasificirati na različite načine. Jednostavna klasifikacija je po znanstvenim disciplinama (npr. podatci prirodnih znanosti, podatci društvenih znanosti) ili načinima prikupljanja (npr. podatci prikupljeni upitnicima, podatci prikupljeni promatranjem). U analiziranju postojanja različitih klasifikacija istraživačkih podataka Willis i suradnici (2012) navode nekoliko različitih klasifikacija istraživačkih podataka. Kao primjere ističu klasifikaciju Nacionalnog odbora za znanost Sjedinjenih Američkih Država te klasifikaciju Kotanija i Lidea. Ovo nam istraživanje ukazuje da istraživačke podatke možemo klasificirati u: promatračke, eksperimentalne i

simulacijske. Eksperimentalni i simulacijski istraživački podatci proizlaze iz dobro definiranih sustava, modela i moguće ih je ponoviti ukoliko su dokumentirane procedure, varijable i metode. Promatrački podatci ne mogu biti ponovno prikupljeni ili verificirani, oni su vremenski i lokacijski ovisni. Za promatračke podatke vrlo važan je kontekst (npr. vrijeme, lokacija, metode) u kojem su prikupljeni.

Istraživačke podatke možemo podijeliti s obzirom na njihovu ulogu na sljedeće četiri vrste podataka: *primarne* (podatci nastali direktnim radom istraživača), *metapodatke* (sekundarni podatci primarnih koji opisuju njihovu prirodu), *operativne* (podatci koji nisu nastali procesima čija je svrha bila generiranje podataka) i *izvedene* (nastali procesiranjem prethodnih vrsta podataka) (Floridi, 2005).

Istraživački podatci su infrastruktura znanosti te se njihovom ponovnom analizom omogućava ponovno vrjednovanje ili ispravljanje prethodnih rezultata, a u interdisciplinarnoj okolini mogu pomoći za nova i različita istraživanja (ESF, 2008).

2.2.2. Arheološki podatci

Arheološki podatci pripadaju u skupinu istraživačkih podataka jer su rezultat znanstvenog istraživanja. Nastaju opažanjima, mjerenjima i teoretskim tumačenjem te su namijenjeni za postavljanje hipoteza i njihovo potvrđivanje ili davanje odgovora na istraživačka pitanja kod širokog kruga istraživača. Pojedina istraživanja ukazuju na potrebu integracije arheoloških podataka u svrhu kreiranja naracije ili priče o prošlim vremenima (Khazraee i Khoo, 2011). Općenito arheološki podatci sadrže podatke o nalazištima, izrađevinama, ekofaktima, značajkama i njihovoj kontekstualnoj povezanosti, fotografijama, kulturnim normama i vrijednosti, zemljovidima, povijesnim tekstovima itd. (Wise i Miller, 1997). Nadalje, svi arheološki podatci imaju povijesnu, znanstvenu, umjetničku, društvenu, emocionalnu kao i ekonomsku vrijednost (Bingwu, 2015). Prema važnosti i vrijednosno poredani, arheološki podatci su: podatci nastali iskapanjem, GIS[7] podatci, skupine podataka materijalne ili biološke analize, podatci terenskih pregleda i oni dobiveni geofizičkim metodama ili metodama zračne arheologije (Selhofer i Geser, 2015).

[7] geoinformacijski sustav, http://www.enciklopedija.hr/Natuknica.aspx?ID=21696

Strategije dokumentiranja i kreiranja zapisa u arheologiji najčešće su prilagođene individualnim istraživanjima. Provodi se individualno promatranje i evidentiranje podataka kroz opise (npr. proračunske tablice), tako da u odnosu na volumen arheološke podatke smještamo u skupinu[8] „malih podataka“ (Selhofer i Geser, 2015).

S obzirom na to da je arheologija ovisna o ulaznim podatcima iz više različitih disciplina npr. zoologije, botanike, geologije i dr., arheološki podatci mogu biti kompleksni (Kansa, 2007). Podatci su također pohranjeni ili strukturirani u različitim formama npr. kvantitativno, kvalitativno, grafički, strukturirano ili slobodnog formata (Khazraee i Khoo, 2011). Novija istraživanja pokazuju da je većina postojećih arheoloških podataka nastala iz iskapanja i terenskog rada nejasno arhivirana, raspršena po različitim lokacijama, nekompletna, nekonzistentna te im je otežan ili nemoguć pristup (De Roo, De Mayer i Bourgeios, 2015), (Selhofer i Geser, 2015).

Kako bi se osiguralo korištenje podataka od strane široke zajednice, skupovi podataka moraju imati određenu kvalitetu i dokumentaciju (Kansa, 2012) te moraju biti kreirani sukladno standardima (Lake, 2012).

Primarno, arheološki podatci nastaju opažanjima i mjerenjima arheološkog entiteta i njegovog konteksta (Banning, 2002), (Richards i Ryan, 1985). Arheološki podatci ne nastaju odabirom iz skupa postojećih podataka, nego nastaju temeljem konstrukta i odlučivanjem o načinu na koji se vide i razumiju[9]. Njihov su temelj teorija, empirija i dosadašnja znanstvena istraživanja. Arheološki podatci mogu sadržavati npr. kategoriju arheološkog entiteta, gustoću entiteta na mjestu istraživanja, udaljenost u odnosu na drugo mjesto istraživanja, prostorne podatke, metodološke informacije i sl. Istraživanja pokazuju da se uvijek radi uzorkovanje i odlučivanje koja se vrsta podataka prikuplja ili zanemaruje u odnosu na ciljeve istraživanja ili moguće kasnije potrebe istraživača (Banning, 2002). Nadalje, kod terenskog istraživanja npr. iskapanja dolazi i

[8] Skupine podataka koje postoje su: veliki podatci (engl. Big data), mali podatci (engl. Small Data) i „Dark Data“. Big Data su podatci koji nastaju temeljem automatiziranog prikupljanja putem različitih senzora, instrumenata. Njihova osnovna karakteristika je veliki volumen, veći od terabajta. Mali podatci su karakteristični za pojedinačna istraživanja. Pojmom „Dark Data“ označavaju se istraživački podatci koje je teško locirati i nije im moguće pristupiti.

[9] U našem okruženju postoji ogromni broj objektivnih činjenica (podataka) koje mogu biti mjerene ili opažene te prikupljene. Postoji razlika između velikog broja činjenica i činjenica koje selektiramo te mi pridajemo pažnju. Mali broj činjenica koje su u našem interesu možemo imenovati sa engl. capta od latinskog izraza capere (hrv. uzeti) (Checkland i Holwell, 2011). U području arheologije činjenice (objekte) od interesa možemo razmatrati i kao capta podatke (engl. Capta Data) (Chippindale, 2000).

do nepovratnog gubitka pojedinih istraživačkih podataka (Kansa, Kansa i Schultz, 2007) zbog različitih postdepozicijskih činitelja, različitih metoda istraživanja, vandalizma, uništavanja arheoloških nalazišta kao i samih procesa istraživanja.

Arheolozi su u prošlosti često koristili grafičke metode za evidentiranje arheoloških entiteta i njihove pozicije na nalazištu, pojednostavljenje opisa i strukture arheološkog entiteta. U današnje vrijeme osim grafičkih metoda koriste se i fotografija, video, animacija, zvuk kako bi se dao prikaz arheoloških entiteta, ali i prikazao njihov odnos u odnosu na okruženje, vrijeme i prostor. Grafičke metode nisu u funkciji realističkog ili umjetničkog prikazivanja onoga što arheolog vidi, već tehnički crteži prezentiraju odabrani skup podataka za koje arheolog smatra da su važni (npr. može se dati prikaz oblika, dimenzija, dekoracije, detalja itd.). Prilikom izrade takvih grafičkih prikaza primjenjuju se pravila vezana uz njihov prikaz (Banning, 2002).

Za arheologiju su bitne prostorne relacije između objekata na samom istraživačkom mjestu, kao i konceptualne relacije (Gkrous i Nikolaidou, 2011). Zbog važnosti okružja, kontekstualni[10] podatci su neophodni za dokumentiranje kao i kasniju interpretaciju (Ixchel *et al.*, 2013).

2.2.3. Otvoreni podatci

Tijekom proteklog razdoblja otvoreni podatci imaju svoje izvorište u praksi - istraživačkim projektima[11] i inicijativama otvorenog koda.

Za neki skup podataka može se reći da pripada skupu **otvorenih podataka** (OP) ukoliko ispunjava sljedeće kriterije: podatcima se može tehnički i slobodno pristupiti online, objavljeni su u formatu koje je moguće strojno čitati, moguće ih je pretraživati te je dozvoljena njihova ponovna uporaba u druge svrhe. Pojedina istraživanja ukazuju da je termin OP neutralan u odnosu na sadržaj podataka te daje samo tehnički i pravni okvir (Heimstädt, Saunderson i Heath, 2014).

[10] U okviru arheologije svaka razina, struktura otkrivena kroz iskapanje imenuje se kontekstom. Svaki kontekst tijekom istraživanja je opisan i njemu su pridruženi pronađeni arheološki entiteti.
[11] Primjeri iz ovog područja su Robert King Merton koji je 40-ih istaknuo važnost dostupnosti rezultata istraživanja svima kao i uporaba otvorenih podataka u Human Genome Projektu u razdoblju 90-ih.

Prošireni skup svojstava OP navodi The Royal Society u izvještaju „*Science as an open enterprise*“ te ukazuje na sljedeće osobine koje podatci moraju imati, a da bi se smatrali OP (The Royal Society, 2012):

- dostupni – biti na takvoj lokaciji da ih je jednostavno pronaći i u formi koja se može koristiti
- procjenjivi - pripremljeni u obliku na temelju kojeg se može procijeniti njihova svrsishodnost
- razumljivi - sveobuhvatni za one koji žele istraživati i u obliku u kojem se može napraviti procjena o njihovoj komunikacijskoj vrijednosti
- uporabljivi - u formatu u kojem ih ostali mogu koristiti.

U svijetu postoje različite razine korištenja digitalne tehnologije, a ta se činjenica posebno odražava na područje otvorenih podataka. Standardni model OP (inicijative OP, podatkovni portali, tehničko posredovanje u korištenju skupova podataka) je nastao na temelju prakse i iskustva razvijenih država i različit je u odnosu na države u razvoju. Tako podatci u državama u razvoju pripadaju skupu OP ukoliko im se generalno može pristupiti online, strojno su čitljivi, nalaze u slobodnom formatu te se pravno mogu ponovno uporabiti (Davies, Perini i Alonso, 2013).

Pojedina istraživanja daju prijedlog univerzalnih načela kojih se potrebno pridržavati kod otvorenih podataka. Načela se odnose na uvažavanje privatnosti i sigurnosti, prikupljanje podataka na ishodištu, podatci moraju imati i osigurati vrijednost, trebaju biti dostupni širokom krugu korisnika te biti strojno čitljivi (Davies, Perini i Alonso, 2013).

Postoje različite vrste OP npr. otvoreni podatci tijela vlasti, otvoreni istraživački podatci, otvoreni podatci kulture i baštine i otvoreni podatci zaštite okoliša. U fokusu ovog istraživanja su otvoreni istraživački podatci.

2.2.4. Otvoreni istraživački podatci

Otvorene istraživačke podatke možemo opisati kao podatke koji su nastali kao rezultat znanstvenih istraživanja, može im se slobodno pristupiti u digitalnom okruženju, objavljeni su u formatu koji je moguće strojno čitati te je dozvoljena njihova ponovna uporaba. Pampel i Dallmeier-Tiessen (2014) smatraju da su otvoreni istraživački podatci

oni podatci koji su javno i online dostupni internetu te je svakom korisniku dozvoljeno preuzimanje, kopiranje, analiza, ponovna obrada, uporaba putem različite programske podrške ili njihovo korištenje u bilo koju svrhu bez financijskih, pravnih ili tehničkih ograničenja.

Osnovne karakteristike koje otvoreni istraživački podatci moraju ispuniti kako bi mogli postojati, biti pronađeni i ponovno uporabljeni od ostalih istraživača navedene su u FAIR načelima. FAIR načela imaju petnaest načela organiziranih u četiri skupine (Wilkinson *et al.*, 2016).

Prva skupina se odnosi na pronalazak podataka[12]. Podatke treba biti moguće pronaći, bilo od strane čovjeka ili strojeva. U tom procesu presudnu važnost imaju metapodatci, uključujući trajne identifikatore, od kojih se jedan svakako odnosi na same podatke. Podatci su opisani sa opsežnim setom metapodataka koji osiguravaju kvalitetno pretraživanje ili indeksiranje.

Druga skupina se odnosi na pristup podatcima i način pristupa. Ostvaruje se korištenjem standardiziranog protokola i identifikatora za pristup podatcima i metapodatcima, pri čemu je protokol u otvorenom formatu, besplatno dostupan i može se univerzalno primijeniti te omogućava postupke autorizacije i autentikacije. Kako bi se osiguralo da adresirani podatci ukazuju na sadržaj, uvijek moraju biti dostupni metapodatci koji opisuju njihov status.

Treća skupina se odnosi na interoperabilnost i korištenje podataka u svrhu integracije, pri čemu se koriste formalni i široko primjenjivi jezici za reprezentaciju znanja, rječnici te kvalificirane reference do drugih podataka.

Četvrta skupina se odnosi na optimizaciju i ponovnu uporabu podataka. Kako bi se ovo ostvarilo potrebno je podatke opisati većim setom točnih i relevantnih metapodataka. Metapodatci sadrže dozvolu o načinu pristupa podatcima i njihovom korištenju, izvor podataka i način citiranja. Podatci i metapodatci trebaju biti definirani prema standardima.

[12] Podatci se u okviru FAIR načela odnose na podatke o digitalnom objektu.

2.3. Informacija

U korijenu riječi informacija je termin *inform* koji proizlazi iz latinskog glagola *informatio*, a odnosi se na davanje oblika. U sveobuhvatnom istraživanju o konceptualizaciji pojma informacije koje je uključivalo 45 vodećih znanstvenika iz područja informacijskih znanosti Zins navodi 40 različitih definicija informacije (Zins, 2007). Temeljem tih definicija možemo sintetizirati da je informacija: poruka koja ima svrsishodni oblik; sadrži organizirane podatke, o ljudima, aktivnostima i događajima, a podatci koje sadrži informacija moraju biti svrsishodni i osigurati smisleno značenje drugim korisnicima. Zins predlaže slijedeću definiciju informacije: *„informacija je skup znakova, koji predstavljaju empirijsko znanje“* (Zins, 2007:480). Temeljem informacija ostvaruje se komunikacija, a sama informacija ovisi o kontekstu i interpretaciji.

Informaciju možemo razmatrati u materijalnom i nematerijalnom obliku (Buckland, 1991). Ako je u nematerijalnom obliku, vezana je uz znanje i proces u svrhu informiranja. Informacija u materijalnom obliku odnosi se na reprezentaciju informacije kao stvari u obliku podataka i dokumenata te na njezin postupak obrade.

2.4. Znanje

Jedan od osnovnih ciljeva arheologije je povećanje znanja o prošlosti kroz istraživanje arheoloških entiteta. Znanje je pojam više razine u odnosu na informaciju. Uobičajeno je stajalište da je znanje produkt sinteze kod osobe pojedinca (Zins, 2007). Zins nudi slijedeću definiciju: *„Znanje je skup znakova koji predstavljaju značenje (ili sadržaj) misli za koje pojedinac opravdano vjeruje da su istinite.“* (Zins, 2007)

Znanje može biti podijeljeno u osnovne dvije grupe: eksplicitno i implicitno znanje. Eksplicitno znanje može biti artikulirano, kodirano, verbalizirano i može mu se pristupiti. Ono je izraženo kroz znakove, riječi ili brojeve, a može biti pohranjeno u knjigama, računalnim zapisima i arhivima te dijeljeno bez obzira na prostor i vrijeme. Implicitno znanje je u potpunosti vezano za osobnost pojedinca, teško ga je formalizirati i o njemu komunicirati s drugima jer ga karakteriziraju subjektivni stavovi, intuicija, predosjećaji i sl.

U istraživanju o konceptualizaciji arheološkog znanja Darvill ukazuje na osnovne karakteristike o znanju i navodi da znanje nastaje na temelju iskustva, proizlazi iz

promišljanja i razvija se međudjelovanjem (Darvill, 2007). Ovo ukazuje na različitu strukturu znanja utemeljenu na: percepciji koja ima pogled prema van, memoriji (pamćenju) koja predstavlja pogled unatrag, introspekciji koja sagledava iznutra i razmišljanju koji teži van postojećih iskustvenih granica.

Na temelju analize istraživačkih radova o stvaranju znanja u području arheologije Mount uspostavlja četiri razine arheološkog znanja u obliku piramide (Mount, 2004). Na najnižoj razini hijerarhija započinje s podatcima. Stavljanjem u kontekst podatci prelaze u višu razinu tj. u informacije. Omogućavanjem da se informacija koristi, pridodaje joj se značenje, informacija se transformira u usporedbi s drugim informacijama ili se uspostavlja povezanost s drugim informacijama, čime se dolazi na razinu znanja. Na najvišu razinu hijerarhije znanja postavljena je mudrost.

2.5. Zaključno razmatranje

S obzirom na dani pregled postojećih definicija i njihovu različitost, a uzimajući u obzir glavne značajke koje smo kod svakoga pojma izdvojili/utvrdili, u ovome ćemo radu primijeniti sljedeće definicije i opise.

Arheološki entitet je stvarni objekt koji samostalno postoji, kojeg možemo jednoznačno odrediti, identificirati i razlikovati, a proizlazi iz arheoloških istraživanja vezanih uz izrađevine, ekofakte i tvorevine, koji su pronađeni na nalazištu. Svaki od arheoloških entiteta ima atribute koji su neophodni za daljnje analize, istraživanja i interpretacije. Svaki od atributa ima vrijednosti ili stanja.

Pod podatkom smatramo činjenice od interesa i vrijedne za prikupljanje; koje su izvorne ili sekundarne, nastale mjerenjima, pokazateljima stanja, opažanjem ili zapisivanjem; koristimo ih u komunikaciji s ljudima ili procesiranju sa strojevima; osnovica su informacije; možemo ih ponovno uporabiti; a kako bi nam dali potpunu vrijednost moraju imati svrsishodni oblik i kontekst.

Istraživački podatci su činjenični zapisi (npr. numerički rezultati, tekstualni zapisi, slike, video zapisi i zvukovi) koji se koriste kao primarni izvori za znanstvena istraživanja te su prihvaćeni od strane akademske zajednice u svrhu validacije istraživačkih pronalazaka. Možemo ih klasificirati kao: promatračke podatke, eksperimentalne podatke i simulacijske podatke, ali i definirati kao digitalne podatke.

Arheološki podatci pripadaju u skupinu istraživačkih podataka. Oni su promatračke činjenice od interesa o arheološkim entitetima i njihovim atributima. Pripadaju skupini „malih podatka“, a mogu biti pohranjeni i predstavljeni u različitim oblicima. Najčešće su prikupljeni na razini pojedinog projekta te im je otežan pristup. Kod arheoloških podataka možemo istaknuti značaj kontekstualnih podatka.

Otvorene istraživačke podatke možemo opisati kao podatke koji su nastali kao rezultat znanstvenih istraživanja, objavljeni su u formatu koji je moguće strojno čitati ili su čitljivi od strane ljudi, može im se slobodno pristupiti u digitalnom okruženju, procjenjivi su, razumljivi, pretraživi te je dozvoljena njihova ponovna uporaba. FAIR načela daju smjernice za ostvarenje otvorenih istraživačkih podataka.

U kontekstu piramide znanja u području arheologije, otvoreni istraživački podatci pozicionirani su na prvoj razini hijerarhije, tj. oni su temelj za informacije i znanje.

3. ZNANOST I OTVORENOST

U okviru ovog dijela rada biti će pojašnjen pojam znanosti i njezina važnost u današnjem svijetu, poimanje otvorenosti u okviru znanosti, te će se definirati kontekst otvorenih istraživačkih podataka.

Znanost je usmjerena na povećanje i unaprjeđenje znanja putem znanstvenih istraživanja. Znanstvena istraživanja provode se slijedeći tijek istraživačkog životnog ciklusa i upravljanja podatcima kroz životni ciklus podataka.

Temelj razvoja znanosti u budućem je razdoblju efektivno dijeljenje i ponovna uporaba istraživačkih podatka.

3.1. Odnos znanosti i otvorenosti

Znanost je nastala iz nastojanja čovjeka da razumije svijet i prirodu oko sebe te da ih prilagodi prema svojim potrebama. Etimološki riječ znanost ima svoje izvorište u latinskoj riječi *scientia* čije je doslovno značenje *znanje*. U prošlosti pojmom *prirodna filozofija* (engl. *natural philosophy; philosophy of nature; natural science*) podrazumijevalo ono što se danas shvaća kao znanost.

U okviru Velikog rječnika hrvatskog jezika znanost je definirana kao: „*ukupnost sređenih i uopćenih znanja koje uključuje promatranja, pokuse, istraživanja i objašnjavanje činjenica i pojava u pojedinim dijelovima čovjekova poznavanja prirode i društva*“ (Anić 2004:1844). Opisi znanosti u okviru istraživačke literature pokazuju da se radi o sistematiziranom i argumentiranom skupu znanja do kojeg se došlo primjenom objektivnih metoda istraživanja o objektivnoj stvarnosti u određenom vremenskom razdoblju. Petrak također polazi od toga da znanost sadrži skup znanja o objektivnoj stvarnosti do kojega se došlo primjenom istraživačkih metoda, ali i objašnjava što taj skup znanja obuhvaća (Petrak, 2016). Skup znanja prema Petrak, obuhvaća spoznate znanstvene činjenice, pojmove, kategorije, načela, teorije i zakone o objektivnoj stvarnosti ili njenim pojedinim dijelovima. Nadalje, autorica ukazuje na to da je cilj znanosti proširenje i produbljivanje poznavanja prirode i društva kao i mijenjanje uvjeta rada i života.

3.1.1. Razvoj znanosti

Za razvoj znanosti u drevnom svijetu bitan je bio pronalazak pisma, tj. uspostava efikasnog sustava pisanja te širenje pisane riječi (Lindberg, 2008). Širenje informacija kao i znanja unaprijeđeno je Gutenbergovim pronalaskom tiskarskog stroja u 15. stoljeću. U razdoblju od drevnog svijeta do 16 st. bilo je zapisanih događaja, književnih djela i teoloških knjiga, međutim njihov je broj bio malen, kao i broj sadržaja povezanih uz znanost. Širenje informacija bilo je ograničeno.

Spoznaja o vrijednosti znanosti i tehnologije za društvo javlja se početkom 17. stoljeća kada Francis Bacon prepoznaje važnost unaprjeđenja života korisnim izumima utemeljenim na istraživanju i znanosti. Bacon je vjerovao da ljudi trebaju zajedno raditi kako bi postigli bolju budućnost kroz primjenu znanja. Smatrao je da je znanost osnovna društvena aktivnost.

Tijekom 17. stoljeća, pronalaskom tehnoloških rješenja npr. teleskopa, mikroskopa, mehaničke zračne pumpe, termometra kao i napretkom u području matematike, ranim je znanstvenicima omogućeno bolje i pozornije promatranje prirode kao i provođenje eksperimenata. Važan doprinos razvoju znanosti dalo je osnivanje prvog znanstvenog društva *The Royal Society* kao i objava prvih znanstvenih časopisa *Philosophical Transaction of the Royal Society* i *Journal des Sçavans.* Znanstvena društva imaju ulogu u prezentaciji i razmjeni znanja te javnim debatama, a znanstveni časopisi u omogućavanju kumulativnog i javnog znanja[13] te doticaja sa znanošću širem krugu ljudi.

Daljnji razvoj znanosti bio je vezan uz industrijske revolucije, prihvaćanje znanosti od šireg kruga ljudi, akumulaciju znanja, suradnju između znanstvenika, primjenu znanosti u različitim područjima i interdisciplinarnost. Pored toga, znanost je postala temelj za daljnji razvoj ekonomija i država.

Tijekom proteklog vremena bilo je niz značajnih pronalazaka, aktivnosti i događaja u znanosti. Za ovaj su rad bitni: uspješan prijenos signala i poruka na veću udaljenost, razvoj računala, uspostava interneta, omogućavanje dijeljenja informacija kao i povezivanje sadržaja putem hiperteksta. Ovi pronalasci su samo jedan segment koji je

[13] Javno znanje tvori korpus objavljenih spoznaja koje su podvrgnute neprekidnom kritičkom vrjednovanju i oko koji se mora uspostaviti što šire suglasje (konsenzus). Da bi neka spoznaja postala dijelom javnog znanja mora se objaviti kao ususlavljeni tekst (Petrak, 2016).

omogućio stvaranje informacijskog društva[14] kao i širenje digitalne transformacije[15]. Temelj razvoja informacijskog društva i digitalne transformacije je napredak u znanosti, znanstvenim istraživanjima i stvaranju znanja.

Napredak u području informacijskih znanosti i računalnih tehnologija omogućio je transformaciju načina provođenja znanstvenih istraživanja te je došlo do promjena u kreiranju, širenju i očuvanju znanstvenog znanja, ali i do promjena u prikupljanju, pohranjivanju i prenošenju velikih količina podataka. Ove promjene izazov su za mnoga postojeća znanstvena istraživanja. Danas su podatci poveznica između današnje znanosti i općeg koncepta znanosti (Greenberg *et al.*, 2009).

Temeljem digitalnih algoritama i simulacija, online dostupnošću podataka, grupnom suradnjom te umrežavanjem, Američka nacionalna znanstvena organizacija pokazuje da dolazi do nadogradnje i proširenja klasičnih pristupa u znanosti (Atkins, 2003). Unaprjeđenje u području umrežavanja omogućilo je znanstvenicima povezivanje čime je smanjena barijera lokacija, vremena, institucija i disciplina. Za buduće razdoblje razvoja znanosti bitno je distribuirano znanje i uspostava e-infrastrukture[16].

Već u prvim fazama internet je omogućio objavu podataka koji su dostupni širem krugu istraživača ili korisnika te ubrzanje razmjene znanstvenih podataka korištenjem npr. e-maila, foruma i web konferencija. Pojavom Web 2.0[17], popularnošću wikija kao i tehnologijom društvenog umrežavanja, omogućeno je stvaranje složenih znanstvenih sadržaja. S društvenog aspekta znanosti, pojava Web 2.0 je unaprijedila znanstvenu suradnju, koordinaciju, dijeljenje, uspostavu konsenzusa, decentralizaciju kao i demokratizaciju znanstvenog znanja.

Iako je primjena interneta u društvu unaprijedila niz aktivnosti, dovela je i do digitalne podijeljenosti, odnosno nejednake mogućnosti pristupa internetu i podjele na one koji imaju pristup (razvijene države) i one koje nemaju pristup (nerazvijene države). Nejednakim mogućnostima pristupa internetu stvorila se i podijeljenost u dostupnosti

---

[14] Informacijsko društvo možemo definirati kao društvo u kojem su informacije i komunikacijske tehnologije svakodnevni dio naših života.

[15] Digitalna transformacija je integracija digitalne tehnologije u sve ljudske, poslovne i znanstvene aktivnosti u svrhu ostvarenja efektivne vrijednosti.

[16] E-infrastruktura upućuje na infrastrukturu koju čine distribuirana računala, informacije, podatci i komunikacijska tehnologija.. U posljednjih 10-tak godina znanstvena istraživanja karakteriziraju suradnja, distribuiranost i podatci, te postoje očekivanja da nova e-infrastruktura i alati mogu u međunarodnoj suradnji dati doprinos u odgovoru na istraživačka pitanja.

[17] Web 2.0 donosi komunikaciju i društvene mreže.

znanja, što odudara od temeljne pretpostavke da znanje mora bit dostupno svima. Također u svijetu je prisutan trend privatizacije te komercijalizacije istraživačkih podataka i informacija. Izvještavanje o rezultatima znanstvenih istraživanja koje se ostvaruje većinom kroz časopise i knjige, nakon 2. sv. rata prešlo je u ruke komercijalnih izdavača koji su domišljatim pristupom autorskom i srodnim pravima postali jedini vlasnici objavljenih sadržaja, što im je omogućilo nerealno podizanje cijena. Tako je najveći dio znanstvene publicistike postao nedostupan svima koji ne raspolažu dovoljno velikim sredstvima za plaćanje skupih pretplata, što je produbilo podijeljenost između znanstvenih zajednica. Financijeri znanstvenih istraživanja, znanstvene i akademske ustanove i znanstvenici su na taj način izgubili kontrolu nad znanjem koje stvaraju. Pored toga, glavni nositelji znanstvenih aktivnosti, sveučilišne i akademske institucije, pod sve su većim pritiskom ostvarivanja financijskog povrata temeljem znanstvenih i tehnoloških aktivnosti, posebice registracijom patenata. Ovakve aktivnosti i kretanja mogu ugroziti znanost u njenoj misiji stvaranja dobrobiti za društvo. Kako je znanje prepoznato kao glavni pokretač svjetskog napretka, tijekom 2000-ih javljaju se razmišljanja da je znanje zajedničko nasljeđe svih ljudi, te da treba biti dostupno tj. otvoreno za sve.

3.1.2. Koncept otvorene znanosti

Početke otvorenosti možemo tražiti u 40-im godinama prošlog stoljeća i radu Roberta King Mertona, koji je istaknuo važnost dostupnosti rezultata istraživanja svima. Termin „otvorena znanost“ uvodi ekonomist Paul David 2003. godine u opisivanju svojstava znanstvenih rezultata generiranih od strane javnog sektora. On smatra da je znanstveno znanje stvoreno kroz javno financirana istraživanja *„javno dobro“*. Podrazumijeva se da svatko može primijeniti tako stvoreno znanje bez dodatnih troškova, a ono ima pozitivan utjecaj na društvene povrate (OECD, 2015).

Temeljeno na pretpostavci da je znanstveno znanje *„javno dobro“*, nastojanjima UNESCA, istraživačkih grupa i instituta došlo se do zaključka kako znanstveni podatci i informacije moraju biti što je moguće šire raspoloživi i dostupni te kao takvi mogu imati velike pozitivne efekte za cjelokupno društvo (UNESCO, 2003). Ključni pokretači otvorene znanosti u okviru Europske zajednice su: digitalna tehnologija, vjerovanje u

slobodnu cirkulaciju ideja i sugestija kao i uvažavanje uloge podataka od strane istraživača (Europska komisija, 2015b).

Otvorena znanost je u postojećoj znanstvenoj literaturi vrlo različito opisana. U izvještaju o novim trendovima u znanosti The Royal Society definira otvorenu znanost kroz otvorene podatke (raspoloživi, procjenjivi, razumljivi i uporabljivi) te u kombinaciji s otvorenim pristupom publikacijama i efektivnom komunikacijom njihovog sadržaja (The Royal Society, 2012). Otvorenu znanost možemo definirati kao znanstveni rad koji se provodi na način da ostali sudionici mogu sudjelovati i pridonijeti, pri čemu su dostupni istraživački podatci, laboratorijski zapisi i ostali istraživački podatci, te je omogućeno njihovo ponovno korištenje, redistribucija i reprodukcija istraživanja (Delfanti i Pitrelli, 2015).

Razloge uvođenja koncepta otvorenosti možemo tražiti u: efikasnosti difuzije znanstvenih istraživanja, većoj dostupnosti znanstvenih *input*-a i *output*-a koji mogu unaprijediti efektivnost i produktivnost znanstvenog sustava, povećanju prilike međunarodnog sudjelovanja u istraživačkim procesima, istraživačkim sugestijama, verifikaciji istraživačkih rezultata, pristupu istraživačkim ishodima i podatcima te uključivanju i sudjelovanju građana (OECD, 2015). U istraživanju o otvorenoj znanosti na uzorku od 498 osoba Europska je komisija utvrdila da otvorena znanost donosi korist u povećanju pouzdanosti i efikasnosti znanosti, bržim i širim inovacijama, podatkovno intenzivnoj znanosti kao ključnom ekonomskom pokretaču, u povezivanju znanosti i društva kao i odgovoru na društvene izazove (Europska komisija, 2015b).

Otvorena znanost se uglavnom realizira putem otvorenog pristupa publikacijama, otvorenim istraživačkim podatcima i otvorenim kodom. Sveobuhvatna primjena otvorene znanosti uključila bi otvaranje svih faza znanstvenog istraživanja (a ne samo završnu – izvještavanje), otvoreni recenzijski postupak, prosudbu temeljenu na otvorenosti i dr.

3.1.3. Stanje u zemljama Europske unije

Otvoreni istraživački podatci su javno dobro tako da inicijativa razvoja u ovom području leži prvenstveno na ministarstvima znanosti, financijerima znanstvenih istraživanja, kao i organizacijama iz javnog sektora (znanstveni instituti, sveučilišta).

Dosadašnja znanstvena istraživanja relevantna za područje otvorenih istraživačkih podataka ukazuju na sve veću primjenu otvorenih istraživačkih podataka i digitalnih repozitorija. Europsko istraživačko vijeće[18] upozorava na nepostojanje dovoljnog broja repozitorija u području društvenih i humanističkih znanosti, spremnih pohraniti i osigurati pristup raznovrsnim sadržajima u tom području, te kao početni korak u implementaciji digitalnih repozitorija predlaže uspostavu repozitorija otvorenog pristupa (Canny, 2015).

Budimpeštanska inicijativa o otvorenom pristupu jedna je od značajnih inicijativa za omogućavanje slobodnog i otvorenog pristupa istraživačkim publikacijama. Europska infrastruktura za otvoreni pristup publikacijama i istraživačkim podatcima gradi se sustavno kroz projekt OpenAIRE. Svrha projekta je osiguravanje zajedničkih standarda za repozitorije otvorenog pristupa, kako bi se ostvarila veća dostupnost znanstvenih publikacija i istraživačkih podataka te unaprijedila interoperabilnost između repozitorija. Važnost otvorenih istraživačkih podataka prepoznali su i izdavači, a sve više časopisa, kao npr. Nature, PLOS Medicine, Journal of Open Archaeology Data, u sklopu prijave rukopisa za objavu od autora traže i otvorene istraživačke podatke.

Prema izvješću EU *Access to and Preservation of Scientific Information in Europe Report on the implementation of Commission Recommendation* (2012) veći broj država članica ima nacionalne smjernice i politike vezane uz otvoren pristup publikacijama. Glavni dionici ovog procesa su sveučilišta i pripadajuće visokoškolske knjižnice. U mnogim zemljama EU postoje nacionalna tijela koja vode brigu o otvorenom pristupu i digitalnim repozitorijima, dok u praksama susrećemo otvoreni i zatvoreni pristup repozitorijima (Tarazona Rua *et al.*, 2015).

Trenutna situacija s pristupom otvorenim istraživačkim podatcima u državama članicama EU je znatno drugačija. Uzimajući u obzir stupanj primjene, EU komisija dijeli članice u tri skupine (Tarazona Rua *et al.*, 2015). Prva skupina nema ili ima male aktivnosti te je bez nacionalnih smjernica vezanih uz otvorene istraživačke podatke. Glavni razlozi spore primjene u ovoj skupini su nedostatak infrastrukture i neodgovarajuće digitalne vještine. U prvu su skupinu uvrštene sljedeće članice: Cipar, Latvija, Luksemburg, Malta i Poljska. Druga skupina također nema ili ima male aktivnosti, ali kod njih je planiran razvoj nacionalnih smjernica u dogledno vrijeme. U ovu su skupinu uvrštene sljedeće članice: Austrija, Belgija, Hrvatska, Češka, Estonija,

[18] European Research Council (https://erc.europa.eu)

Madžarska, Italija, Portugal, Rumunjska, Slovačka i Švedska. Treća skupina na nacionalnoj razini ima smjernice i strategije, a u nju su uvrštene članice: Danska, Finska, Francuska, Njemačka, Irska, Litva, Norveška, Nizozemska, Ujedinjeno Kraljevstvo i Slovenija.

U nastavku rada detaljnije se analizira situacija u Hrvatskoj te Ujedinjenom Kraljevstvu i Nizozemskoj kao državama predvodnicama u području otvorenosti istraživačkih podataka.

3.1.3.1. Hrvatska

Početak razvoja otvorenosti u Hrvatskoj možemo tražiti u 1997. godini i uspostavi središnjeg repozitorija znanstvenih radova kao dijela Hrvatske znanstvene bibliografije CROSBI[19]. Dodatni poticaj otvorenosti u Hrvatskoj napravljen je tijekom 2006. godine pokretanjem središnjeg portala hrvatskih časopisa pod imenom Hrčak[20], u svrhu okupljanja znanstvenih, znanstveno-stručnih i popularnih časopisa u jednom repozitoriju s otvorenim pristupom. U ovom trenutku u okviru Hrčka postoji 375 aktivnih hrvatskih časopisa u otvorenom pristupu, od kojih 44 pripada području arheologije.

Hrvatska deklaracija o otvorenom pristupu[21] objavljena je tijekom 2012. godine i podržana je od niza znanstvenika, znanstvenih institucija i nadležnog ministarstva.

Snažniji poticaj otvorenosti u Hrvatskoj ostvaren je tijekom 2014. godine kada je prihvaćena Nacionalna strategija obrazovanja, znanosti i tehnologije[22]. U okviru strategije, cjelina *Znanost i tehnologija*, dio *Znanstveno vrednovanje prijedloga infrastrukturnih projekata* i mjere 5.3. navedene su odrednice za uspostavu javnog pristupa postojećoj i novoj istraživačkoj infrastrukturi i opremi, uspostavi podatkovnih usluga (uključujući digitalne repozitorije) za omogućavanje prikupljanja i obrade te osiguranja trajnog i pouzdanog čuvanja i pristupa rezultatima istraživanja, uključujući otvoreni pristup znanstvenim i stručnim informacija koje su nastale sredstvima javnog financiranja (Republika Hrvatska, 2014). Kako bi se unaprijedila istraživanja

[19] https://www.bib.irb.hr/
[20] https://hrcak.srce.hr/
[21] https://www.fer.unizg.hr/oa2012/deklaracija
[22] https://narodne-novine.nn.hr/clanci/sluzbeni/2014_10_124_2364.html

potpomognuta digitalnim tehnologijama u područjima umjetnosti i humanističkih znanosti, Hrvatska postaje članica istraživačkog konzorcija DARIAH[23].

Tijekom 2015. godine pokrenut je sustav digitalnih akademskih arhiva i repozitorija pod imenom Dabar[24], u svrhu javne objave i dostupnosti digitalnih objekata (npr. završni i diplomski radovi, doktorske disertacije, radovi objavljeni u časopisima, slikovni, audio i audiovizualni objekti, izlaganja na skupovima, skupovi podataka, knjige i obrazovni sadržaj)[25].

Nacionalna i sveučilišna knjižnica u Zagrebu uspostavila je nekoliko različitih digitalnih zbirki i tematskih zbirki koje omogućavaju dostupnost sadržaja u slobodnom pristupu. Primjer dobre prakse u kontekstu otvorenosti je digitalni repozitorij Instituta za etnologiju[26], koji omogućava dostupnost sadržaja kao što su fotografije, audio zapisi, rukopisi i crteži.

Hrvatska je do sada sudjelovala u više istraživačkih projekata npr. CLARIN, SERSCIDA, SEEDS, CESSDA, ELIXIR čiji su ciljevi povezani uz izgradnju istraživačke infrastrukture (Vodopijec i Kranjec, 2018). Daljnji razvoj istraživačke infrastrukture osigurava se kroz sudjelovanje u projektima OpenAIRE, OPERAS i NI4OS.

Krajem 2018. godine u svrhu pohrane, dugotrajnog čuvanja i diseminacije istraživačkih podataka u okviru Dabra implementirana je podrška za pohranu i samoarhiviranje digitalnog objekta: skup podataka čime su ostvareni prvi koraci za sustavnu pohranu otvorenih istraživačkih podataka na razini Hrvatske.

3.1.3.2. Ujedinjeno Kraljevstvo

Vlada UK intenzivno zastupa otvorenost u znanosti prepoznajući važnost otvorenih istraživačkih podataka te polazi od toga da je pristup podatcima važan za reproduciranje i verificiranje rezultata istraživanja.

Važnost istraživačkih podataka istaknuta je kroz različite strategije, načela (npr. *Upravljanje podatcima digitalnih istraživanja: načela i smjernice*[27]) kao i izvještaje koji

[23] http://dariah.hr
[24] https://dabar.srce.hr
[25] https://dabar.srce.hr/objekti
[26] https://repozitorij.dief.eu
[27] http://www.rin.ac.uk/system/files/attachments/Stewardship-data-guidelines.pdf

upućuju na potrebnu edukaciju i nova zanimanja u ovom području (Swan i Brown, 2008). Tijekom 2015. godine u svrhu uspostave dobre prakse kod otvorenih istraživačkih podataka kao i poželjnog načina objave istraživanja financiranih javnim sredstvima u UK od strane istraživačkih institucija usvojen je dokument pod naslovom *Concordat on Open Research Data*[28], a koji je po prvi put naveo načela za rad s otvorenim istraživačkim podatcima: važnost otvorenih istraživačkih podataka, način upravljanja podatcima, raspodjelu troškova, prava prvog korištenja, poštivanje pravnih, etičkih i regulatornih zahtjeva, dostupnost podataka u dužem vremenskom periodu, citiranje i razvoj vještina.

Država UK zastupa i promovira veću dostupnost istraživačkih podataka kroz predmetne i institucijske repozitorije (npr. podatci iz područja ekonomije i društva objedinjeni su u UK Data Service[29]). U UK primjećujemo različite pristupe u ostvarivanju otvorenih istraživačkih podataka. Tako se npr. u području inženjerstva i fizike od znanstvenih se organizacija očekuje objava strukturiranih podataka u roku od 12 mjeseci te njihova dostupnost na rok od 10 godina. U području umjetnosti i humanističkih znanosti postoji konzervativniji pristup podatcima, a podatci moraju biti raspoloživi u odgovarajućem repozitoriju u vrijeme izdavanja publikacije te ostati raspoloživi najmanje tri godine (Richards, 2015). Svi arheološki projekti koji kreiraju primarne podatke, moraju u UK biti pohranjeni u servis arheoloških podataka ADS ili slične digitalne repozitorije.

3.1.3.3. Nizozemska

Nizozemsku možemo smatrati jednom od vodećih zemalja u primjeni i promicanju otvorene znanosti. Značajan događaj u području otvorenosti za Nizozemsku, a indirektno i za svijet, dogodio se tijekom 2014. godine kada udruženje nizozemskih sveučilišta i konzorciji instituta s glavnim izdavačima (npr. Springer, Wiley) dogovaraju dostupnost nizozemskih istraživačkih radova u otvorenom pristupu uz odgovarajuće naknade izdavačima (Butler, 2016).

Na razini EU, Nizozemska poduzima značajne aktivnosti za unaprjeđenje otvorene znanosti, prvenstveno otvorenog pristupa znanstvenim člancima i otvorenim istraživačkim podatcima. Tako je tijekom travnja 2016. godine u Amsterdamu održana dvodnevna konferencija o otvorenoj znanosti, koja je rezultirala donošenjem akcijskog

[28] https://www.ukri.org/files/legacy/documents/concordatonopenresearchdata-pdf/
[29] https://ukdataservice.ac.uk/

plana pod nazivom Amsterdam Call for Action on Open Science[30]. Najvažnije aktivnosti ovog plana su: potpuni otvoreni pristup do 2020. godine za sve javno financirane znanstvene publikacije, uspostava otvorenih istraživačkih podataka kao standarda za sva javno financirana istraživanja te uspostava nacionalnih planova za otvorenu znanost.

Na nacionalnoj razini tijekom 2017. godine, usvojena je Deklaracija o otvorenoj znanosti[31] te je donesen nacionalni plan o otvorenoj znanosti[32]. Ključne aktivnosti nacionalnog plana su: potpuni otvoreni pristup znanstvenim člancima do 2020. godine, omogućavanje ponovne uporabe istraživačkih podataka, te prepoznavanje i evaluacija rada u području otvorene znanosti (van Wezenbeek *et al.*, 2017).

U Nizozemskoj se arheološki digitalni podatci pohranjuju u okviru repozitorija *Data Archiving and Networked Services* (DANS). Cilj DANS-a je arhiviranje i ponovna uporaba istraživačkih podataka. DANS uključuje nekoliko repozitorija, kao npr.: DataverseNL, NARCIS[33], EASY i EDNA. Posljednja dva, EDNA i EASY pokrivaju područje arheologije.

EDNA sadrži podatke arheoloških istraživanja npr. GIS data, crteže, tablice, fotografije i konačne izvještaje. Prema podatcima iz 2013. g. u okviru ovog servisa bilo je pohranjeno i dostupno oko 21.500 arheoloških skupova podataka (Hollander, 2014).

3.2. Znanstveno istraživanje, prikupljanje i dijeljenje podataka

Aktivnosti znanstvenih istraživanja (ZI) utječu na razvoj akademskog okruženja i glavni su izvor znanja i inovacija. OECD opisuje ZI kao kreativni rad koji se sustavno provodi u svrhu povećanja razine znanja, znanja ljudi i društva kako bi se znanje uporabilo u nove svrhe (OECD, 2002). Petrak ulogu ZI vidi u povećavanju količine korisnog znanja, povećavanju broja obrazovnih stručnjaka, stvaranju novih znanstvenih metoda i instrumenata, poticanju društvene interakcije te povećavanju sposobnosti rješavanja problema na znanstveni način (Petrak, 2013).

[30] Više o konferenciji i njezinom sadržaju može se vidjeti na: https://english.eu2016.nl/latest/news/2016/04/05/eu-action-plan-for-open-science
[31] Deklaracija o otvorenoj znanosti navedena je u okviru Nacionalnog plana Nizozemske.
[32] https://doi.org/10.4233/uuid:9e9fa82e-06c1-4d0d-9e20-5620259a6c65
[33] National Research and Collaboration Information System, https://www.narcis.nl/

Klasični istraživački životni ciklus započinje s planiranjem projekta, prikupljanjem, obradom i analizom podataka, a završava s objavom rezultata istraživanja. U ovakvom ciklusu istraživački podatci se ne razmatraju kao istraživački ishod i nakon istraživanja su izgubljeni (Briney, 2015).

Spoznaja i općeprihvaćenost da podatci mogu biti iskorišteni za nova istraživanja, da mogu biti i novi činitelji u procesu istraživanja i vanjskom okruženju, usmjerava istraživače na posvećivanje veće pažnje podatcima. Činitelji promjena za sama istraživanja i njihovo vanjsko okruženje utvrđeni su i prikazani kroz Tablicu 2.

Tablica 2.: Činitelji promjena u znanstvenim istraživanjima

Izvor	Činitelji promjena
(Dietrich, 2010)	mali i veliki podatci; ponovna uporaba podataka
(Wood *et al.*, 2010)	dostupnost; pronalaženje i vrjednovanje podataka; ponovna uporaba podataka; javni pristup podatcima
(Wilson, 2010)	velike grupe istraživača (npr. 30, 50 suradnika); suradnja; podatkovno pokrenuta istraživanja
(Qin, Ball i Greenberg, 2012)	provjerljivost podataka u svim fazama istraživanja; podatci opisani metapodatcima i pripremljeni za analize; interoperabilnost
(Martin, 2014)	način prikupljanja, analize, dijeljenja i arhiviranje podataka te publiciranje rezultata istraživanja
(Europska komisija, 2015a)	podatci moraju biti dostupni i besplatni trećim stranama ako su financirani javnim financijama

Ovi činitelji upućuju na potrebu sustavnog rukovanja podatcima u sklopu istraživanja. Sustavnost omogućava životni ciklus podataka, koji možemo okarakterizirati kao pravi životni ciklus jer podatci iz jednog istraživanja mogu ulaziti u drugo istraživanje i tako u krug, stvarajući ciklus. Na ovaj način podatci nisu izgubljeni nego se mogu ponovno koristi (Briney, 2015).

3.2.1. Životni ciklus podataka

Općenito, životni ciklus podataka se može sastojati od sljedećih faza: pokretanje istraživanja i izrada plana upravljanja podatcima, prikupljanje podataka, obrada i analiza podataka, publiciranje podataka, dijeljenje podataka, očuvanje podataka i ponovna uporaba podataka. Detaljniju razradu predložio je Martin koji dijeli ciklus na osam zasebnih faza: planiranje aktivnosti, prikupljanje podataka, kontrolu i osiguranje kvalitete podataka, kreiranje metapodataka, očuvanje podataka, istraživanje podataka, integraciju podataka i analizu podataka (Martin, 2014). Prema Martinu ove faze se ne moraju odvijati slijedno, bez obzira je su li podatci prikupljeni ili stvoreni primjenom eksperimenta, promatranja ili istraživanjem.

Danas mnoge istraživačke institucije koriste životni ciklus podataka u svrhu upravljanja, organiziranja i očuvanja istraživačkih podataka. Raščlanjivanjem procesa životnog ciklusa podatka na to kako podatci ulaze, rastu i kako dolazi do transformacije te njihove svrsishodne primjene, omogućava se lakše uočavanje potreba istraživača. Životni ciklus podataka definira i povezanost između podatkovnih usluga koje su ciljane u pojedinim fazama.

Inicijativa za dokumentaciju podataka[34] jedan je od važnijih standarda za podatke u okviru društvenih znanosti te je bila jedna od prvih inicijativa koja u istraživanje donosi ideju životnog ciklusa podataka. Osnovna ideja je bila povezivanje istraživačkog procesa i aktivnosti vezanih uz upravljanje podatcima kroz cijeli životni ciklus, zaštitu i očuvanje podataka, publiciranje podataka i njihovo dijeljenje (Corti, 2014). Sastoji se od sljedećih faza: koncept istraživanja, prikupljanje podataka, procesiranje podataka, arhiviranje i distribucija podataka. Kao posebnost možemo istaknuti fazu koja se odnosi na prenamjenu i sekundarno korištenje podataka, a ona je realizirana kroz faze istraživanje podataka, analizu podataka i podatkovno procesiranje.

U svrhu omogućavanja dostupnosti i dijeljenja podataka, Australski nacionalni podatkovni servis[35] utvrdio je model životnog ciklusa podataka u kojem su aktivnosti definirane pomoću glagola (Burton i Treloar, 2009). Postojeća lista sastoji se od osam glagola: kreirati, pohraniti, opisati, identificirati, registrirati, istražiti, pristupiti i

[34] Data Documentation Initiative, DDI, https://ddialliance.org
[35] Australian National Data Service, ANDS, https://ands.org.au

iskoristiti. Ovaj model sugerira da je početna faza ujedno i faza kada je potrebno započeti s definiranjem metapodataka, a važnost metapodataka istaknuta je kroz sve daljnje faze. Kreiranje metapodataka od prve faze prisutno je i u okvirima modela životnog ciklusa podatka nacionalnog podatkovnog arhiva Ujedinjenog kraljevstva[36].

U analiziranju okruženja otvorene znanosti i istraživanja u takvom okruženju, Rüegg i suradnici prepoznaju važnost životnog ciklusa podatka i dijele ga na dva dijela (Rüegg *et al.*, 2014). Prvi se dio odnosi na tradicionalne postupke: *planiranje, prikupljanje, osiguranje kvalitete i kontrole* te *analizu podataka*. Upozoravaju da tradicionalni dio samo vodi do lokalnog pohranjivanja podataka na računalu, pri čemu su podatci nedovoljno opisani i dokumentirani. Prijelazna faza između prvog i drugog dijela obuhvaća opis podataka i publiciranje. Drugi se dio odnosi na osiguravanje dugotrajne dostupnosti podataka kao i na mogućnost njihove ponovne uporabe. U okviru ovog dijela uključuju i faze *dodatnog istraživanja podataka, integraciju podataka i konačne analize*. Zaključuju da životni ciklus podataka postaje potpun tek dokumentiranjem podataka metapodatcima, arhiviranjem i omogućavanjem javne dostupnosti repozitorija s podatcima.

3.2.2. Dijeljenje i ponovna uporaba podataka

Istraživači koji stvaraju istraživačke podatke trebaju ih dijeliti na način koji drugim istraživačima omogućava interpretaciju ili ponovnu uporabu podataka. Dijeljenje istraživačkih podataka potrebno je razmatrati s pozicije preduvjeta za istraživački rad, pri čemu se polazi od toga da znanost i istraživanja impliciraju mogućnost ponovnih analiza, što je temeljni zahtjev znanstvenog rada. Samo rezultati koji se mogu ponoviti (reproducirati) istinski su znanstveni rezultati. Dijeljenje istraživačkih podataka ubrzava razmjenu ideja, dovodi do suradnje, a ponovljivost istraživanja obeshrabruje znanstvenu prijevaru i pristranost odabira te povećava vjerojatnost identificiranja i popravljanja pogrešaka (Spencer, 2016). Nadalje važnost dijeljenja istraživačkih podataka možemo potvrditi kroz efektivnu uporabu javnih sredstava i danih resursa, uspješnije obrazovanje

[36] UK Data Archive, https://www.data-archive.ac.uk

novih generacija istraživača (ESF, 2008), kao i verifikaciji rezultata istraživanja te uporabu istraživačkih podataka u novim kontekstima (Fecher, Friesike i Hebing, 2015).

Aktivnosti dijeljenja podataka koncentrirane su unutar nekoliko znanstvenih polja, a praksa dijeljenja je različita (Borgman, 2012). Pojedina istraživanja pokazuju da se dijeljenje podataka može ostvariti na različite načine, od privatne razmjene na upit do spremanja u javnu kolekciju podataka. Objavljivanje setova podataka na javnim web stranicama ili pridruživanje setova podataka člancima objavljenima u časopisu kao dodatni materijal također se kvalificira kao dijeljenje podataka.

Prema Fecheru i suradnicima tri glavna preduvjeta za uspješno dijeljenje istraživačkih podataka su: *pretraživost*, *dostupnost* i *upotrebljivost* (Fecher, Friesike i Hebing, 2015). Pretraživost znači da se istraživački podatci mogu pronaći i procijeniti prema važnosti za potencijalne korisnike. Dostupnost omogućava ponovnu uporabu istraživačkih podataka. Upotrebljivim podatcima označavamo sve one istraživačke podatke koji su osim u tehničkom, razumljivi i u znanstvenom kontekstu. U kontekstu dijeljenja podataka i njihove ponovne uporabe, prethodno spomenutim preduvjetima potrebno je pridodati i dodatne uvjete koji se odnose na jedinstveni identifikator i metapodatke (Canham i Ohmann, 2016).

Novija istraživanja utvrdila su kako unutar znanstvene zajednice postoji nedovoljna osviještenost o važnosti metapodataka te se preporuča poduzimanje aktivnosti na njihovoj pripremi kako bi se omogućilo pronalaženje, očuvanje i ponovno korištenje istraživačkih podataka (Farnel i Shiri, 2014).

Unatoč prisutnosti velikog broja inicijativa vezanih uz dijeljenje, istraživači su još uvijek neskloni dijeliti svoje istraživačke podatke. Glavne razloge nedijeljenja podataka možemo tražiti u nedovoljnoj stručnosti istraživača, nedovoljnim resursima kao i izostanku motivacije za dijeljenje. Čak i u slučaju spremnosti istraživača na dijeljenje podataka, oni često nisu raspoloživi u oblicima pogodnim za objavu ili preuzimanje, a neki se podatci ne mogu dijeliti zbog etičkih ili epistemioloških razloga (Borgman, 2012). U svakom slučaju, dijeljenje podataka u okviru akademskog okruženja je višedimenzionalni pothvat koji uključuje prava, interese, odgovornosti i obveze različitih dionika, entiteta i pojedinaca.

Dijeljenje istraživačkih podataka i njihova javna objava u digitalnom okruženju nameće pitanja vezano uz intelektualno vlasništvo i načine njihove zaštite. Općenito se

prava koja mogu biti pridružena istraživačkim podatcima odnose na poslovnu tajnu (povjerljivi podatci i informacije), autorska prava i posebna prava povezana uz baze podataka (Carroll, 2015).

U skupinu poslovne tajne odnosno povjerljivih podataka, istraživački se podatci mogu uvrstiti u ranim fazama istraživanja, kada se radi o generiranju ekonomske vrijednosti ili ukoliko pojedina država propisuje zaštitu istraživačkih podataka na određena vremenska razdoblja. Na području Hrvatske zaštita istraživačkih podataka u području arheologije indirektno je definirana Pravilnikom o arheološkim istraživanjima koji propisuje tko ima pravo prve objave, vremenske rokove za objavu te prostor objave. Prema važećem pravilniku, pravo prve objave prikupljenih nalaza i dokumentacije ima stručni voditelj sa svojim suradnicima, najkasnije dvije godine od dana završetka istraživanja, a objave rezultata istraživanja i stručno obrađenih nalaza najkasnije do pete godine od dana završetka istraživanja. Prva objava mora biti napravljena u Hrvatskoj (Ministarstvo kulture, 2010).

Autorska prava[37] autorima izvornog djela daju isključiva prava za reproduciranje djela, javnu distribuciju kopija, javno prikazivanje, javno izvođenje, prilagodbu ili predstavljanje rada javnosti na drugi način. Zakonska regulativa u pojedinim državama ima jasno razlikovanje između javnih činjenica i autorskog izražaja. Podatci u arheologiji mogu biti činjenični (npr. fizičke mjere) te autorski (npr. opis, slike, crteži), a nerijetko nije jednostavno odrediti granicu između elemenata koji sadrže činjenične podatke i elemenata koji sadrže autorske podatke. Autorskim pravima u području arheologije štite se svi podatci, koji su proizašli o arheološkim entitetima s nalazišta (Kansa, Kansa i Schultz, 2007). U digitalnom okruženja autorskim pravima i dozvolama[38] različito se štiti digitalni objekt i pripadajuće sadržajne stavke (npr. vektorska grafika, rasterska grafika, digitalni video), u odnosu na metapodatke i koji se najčešće ne štite autorskim pravima i svrstavaju se u javno dostupne (Wright *et al.*, 2016).

Kulturne institucije u svijetu i Europi različito pristupaju autorskim i srodnim pravima u zaštiti digitalnih objekata kao i omogućavanju ponovne uporabe digitalnih objekata. Kako je opći cilj široka dostupnost digitalnih objekata i njihova ponovna

[37] U Hrvatskoj su autorska prava regulirana Zakonom o autorskom pravu i srodnim pravima,

[38] Dozvole koje se mogu pridodati sadržaju odnose se na Creative Commons licence (npr. CC BY / imenovanje, CC BY-SA / imenovanje – dijeli pod istim uvjetima) i javne dozvole (npr. CC0 / bez autorskih i srodnih prava).

uporaba, uspostavljen je konzorciji[39] i radna grupa[40] za definiranje jedinstvenih prava. Prava[41] su objavljena na način da su čitljiva od strane ljudi i strojeva, a obuhvaćaju sljedeće kategorije: autorska prava (npr. pod autorskim pravima, dijela siročad, pod autorskim pravima s dozvolom u obrazovne svrhe), bez autorskih prava sa ograničenjima (npr. ugovorna ograničenja) te ostala prava (npr. autorska prava nisu utvrđena) (IRSWG, 2015).

Pojedine države u Europi i svijetu štite istraživačke podatke unutar baza podataka koje pripadaju pod posebnu nadležnost prava baza podataka. Regulativa EU kao i Hrvatske prepoznaje specifičnosti obrazovanja (nastave) i istraživanja te dopušta[42] korištenje baza podataka u svrhu obrazovanja i istraživanja, uz obavezno navođenje izvora.

Pristup primarnim podatcima ključan je za interpretaciju prošlosti i formulaciju uvjerljivih alternativnih interpretacija (Kansa *et al.*, 2010). Arheologija ima dugu tradiciju upravljanja podatcima, kao i razvoja baza podataka (digitalnih repozitorija), međutim oni su primarno korišteni za interne potrebe u određenim organizacijama. Dijeljenje podataka u području arheologije je postojana aktivnost u arheološkoj zajednici (npr. dijeljenje podataka u zooarheologiji), a danas donosi novi skup tehničkih, konceptualnih ali i poticajnih problema (Kansa, 2007).

U istraživačkoj su literaturi identificirani uzroci koji smanjuju mogućnosti dijeljenja podataka u ovom području. Primarni uzroci su:

- *nepostojanje konteksta* - kontekst arheoloških entiteta u muzejima je najčešće izostavljen; kod većine nalaza pronađenih prije 1960. godine nema konteksta; kod pojedinih arheoloških entiteta nedostaju metode istraživanja, metode uzorka, metoda identifikacije; postoji različita zakonska regulativa kao i različite ontologije (Ixchel *et al.*, 2013)

[39] Članovi konzorcija su Europeana, Digital Public Library of America, National Digital Library of India, National Heritage Digitization Strategy Canada i National Library of Australia
[40] International Rights Statements Working Group
[41] https://rightsstatements.org/page/1.0/?language=en#collection-ic
[42] U Hrvatskoj je Zakonom o autorskom pravu i srodnim pravima (NN 96/2018, Članak 150.) dopušteno korištenje objavljenih baza podataka bez odobrenja njezina proizvođača kada je ona namijenjena nastavi ili znanstvenom istraživanju, uz navođenje izvora ili u mjeri opravdanoj nekomercijalnom svrhom. Na razini Europske unije dopuštenje je propisano Direktivom 96/9/EZ Europskog parlamenta i vijeća od 11. ožujka 1996. godine.

- *nedovoljno vrjednovanje rada* – dodatni rad na pripremi podataka za dijeljenje još uvijek nije prepoznat (Selhofer i Geser, 2014)
- *nedostatak strukturiranih rječnika* - u procesu digitalizacije podataka postoji nedostatak strukturiranih i kontroliranih rječnika (May, Binding i Tudhope, 2015)
- *osobni pogled na podatke* - podatci su najčešće selektirani od strane istraživača i prezentirani iz njegovog/njezinog pogleda; podatci su često prikazani putem tablica koje su jedino raspoložive u tiskanom obliku ili digitalnom formatu namijenjenom tisku (PDF) što zahtijeva njihovo prepisivanje i nije ih moguće pretraživati; razmjena istraživačkih podataka najčešće se realizira u obliku jedan-na-jedan, putem elektroničke pošte (Kansa, 2015).

Razumijevanje konteksta arheoloških podataka ključni je činitelj u njihovoj ponovnoj uporabi od strane arheologa. Kako bi se podatcima dao kontekst, moraju imati relaciju i povezanost s dijeljenim konceptima, kao i drugim skupovima podataka s weba (Kansa, 2012).

Postojeća istraživanja ukazuju na različite pristupe u pripremi podataka u svrhu dijeljenja i ponovne uporabe. U istraživanju Ixcel i suradnika sugerira se korištenje postojećih standarda (npr. standardi za istraživanja, za repozitorije i dijeljenje podataka) (Ixchel *et al.*, 2013). Nadalje kod dijeljenja podataka i u radu s velikim skupovima podataka, arheolozima se sugerira primjena općih metapodatkovnih shema. Ovo može uzrokovati razliku između prikupljenih podataka do koji se došlo tijekom istraživanja te količini i vrsti podataka te metapodataka koji mogu biti objavljeni, zbog korištenja metapodatkovne sheme s nedovoljnim brojem elemenata. Moguće rješenje ovog problema je uspostava dvije vrsta shema, jedne za organizaciju, a druge za razumijevanje (Khazraee i Khoo, 2011). Noviji pristupi ukazuju na uporabu Linked Open Data (LOD), dijeljenih koncepata u svrhu opisa podataka kao i povezivanja različite terminologije. Prednost LOD možemo tražiti u korištenju šireg opsega opisa i pridruživanju taksonomskim konceptima (Kansa, 2015).

Dijeljenje arheoloških podataka zahtijeva i održivost. Naime, ukoliko se financiraju istraživanja i iskapanja, potrebno je osigurati i financiranje dijeljenja rezultata istraživanja (Lake, 2012).

3.3. Zaključno razmatranje

Znanost možemo opisati kao sistematizirani i argumentirani skup znanja o objektivnoj stvarnosti do kojega se došlo primjenom istraživačkih metoda u određenom vremenskom razdoblju. Skup znanja obuhvaća spoznate znanstvene činjenice, pojmove, kategorije, načela, teorije i zakone o objektivnoj stvarnosti ili njenim pojedinim dijelovima. Cilj znanosti je proširenje i produbljivanje postojećih spoznaja o prirodi i društvu, tj. okruženju u kojem ljudi žive i djeluju, a kako bi se unaprijedio život, društvo i okruženje.

Na današnja znanstvena istraživanja utječu različite promjene, koje su za ovaj rad utvrđene npr. u: digitalnoj tehnologiji, velikim skupinama podataka, dostupnosti podataka i njihovom ponovnom korištenju, provjerljivosti podataka, suradnji među istraživačima i postojanju velikih grupa istraživača. Za unaprjeđeni razvoj znanosti kao i dostupnost rezultata istraživanja širokom krugu istraživača i javnosti bitno je ostvariti otvorenu znanost. Na otvorenu znanost možemo gledati kao na "javno dobro" kojem svatko ima pravo pristupa, pri čemu se otvaraju sve faze znanstvenog istraživanja, a ne samo faza izvještavanja, tj. objavljeni znanstveno-istraživački rad. U okviru otvorene znanosti rezultati istraživanja mogu se slobodno uporabiti te su raspoloživi i dostupni drugim istraživačima. Ključni pokretači otvorene i suvremene znanosti su digitalna tehnologija, slobodan protok ideja te uvažavanje važnosti i uloge istraživačkih podataka. Postojeća istraživanja o usvojenim politikama otvorene znanosti pokazuju da postoji različiti stupanj primjene otvorenosti u zemljama EU. Hrvatska je uvrštena u drugu od tri skupine, najviše zahvaljujući brojnim inicijativama otvorenog pristupa publikacijama, međutim u području otvorenih istraživačkih podataka još je uvijek na samim počecima.

Temelj znanosti je znanstveno istraživanje. Za znanstveno istraživanje bitan je istraživački životni ciklus koji obuhvaća i životni ciklus podataka. U klasičnom istraživačkom ciklusu istraživački podatci aktualni su do objavljivanja publikacije, nakon čega im se ne pridaje pažnja i najčešće su izgubljeni. U okvirima istraživanja životni ciklus podataka možemo okarakterizirati kao pravim životnim ciklusom, jer kod njega podatci iz jednog istraživanja mogu biti preuzeti za drugo istraživanje. Kroz ovo poglavlje identificirani su i analizirani sljedeći životni ciklusi podataka: Inicijativa za dokumentaciju podataka, Australski nacionalni podatkovni servis, Nacionalni podatkovni

arhiv Ujedinjenog kraljevstva, te životni ciklus Rüegg i suradnika. Za ovaj rad posebno su značajni životni ciklus podataka Australskog nacionalnog podatkovnog servisa koji ukazuje da je s definiranjem metapodataka potrebno započeti od prve faze te životni ciklus podataka Rüegg i suradnika čija se važnost iskazuje definiranjem uspostave dugotrajne dostupnosti i omogućavanjem ponovne uporabe podataka.

U današnje vrijeme dijeljenje i ponovna uporaba podataka omogućava efektivno korištenje javnih sredstava, verifikaciju istraživanja, ali i uporabu u novim kontekstima. Možemo zaključiti da su dijeljenje i ponovna uporaba podataka osnovni preduvjeti za uspješan istraživački rad. Važni elementi koje je potrebno uzeti u obzir kod dijeljenja podataka su: pretraživost, dostupnost, upotrebljivost, trajni identifikator i metapodatci.

Istraživački podatci mogu biti zaštićeni kao poslovna tajna (povjerljivi podatci i informacije), autorskim pravima i posebnim pravima koja se odnose na baze podataka. Metapodatci ne spadaju u kategoriju štićenih, već se svrstavaju u javno dostupne podatke

Dijeljenje i ponovna uporaba podataka u području arheologije ima dugu tradiciju. Pojava novih digitalnih tehnologija i novih načina razmjene podataka donosi nove izazove. Novija istraživanja pokazuju da je za uspješno dijeljenje podataka potrebno uspostaviti ili realizirati niz uvjeta: kontekst arheoloških entiteta, vrjednovanje rada na dijeljenju podataka, zaštitu autorskih prava, pripremu podataka (npr. uspostavu i primjenu strukturiranih i kontroliranih rječnika, primjenu standarda) te osiguravanje održivost dijeljenja podataka tijekom vremena. Za dijeljenje podataka, kao i u samom životnom ciklusu podataka bitni su metapodatci čiju pripremu je potrebno uključiti u početne faze znanstvenog istraživanja, a polazište za pripremu podataka su postojeći standardi.

4. DIGITALNO OKRUŽENJE I METAPODATCI

Istraživanjem za potrebe ovog rada prepoznato je da su za otvorene istraživačke podatke važne dvije perspektive. Jedna je perspektiva izvornog istraživača u kojoj on prikuplja, analizira, dijeli podatke te radi na očuvanju istraživačkih podataka. Druga je perspektiva istraživača korisnika u kojoj on pronalazi podatke, preuzima ih, prosuđuje njihovu vrijednost te ih ponovno koristi u istraživanjima. Kritičnim fazama možemo označiti pripremu podataka za objavu i dijeljenje podataka u svrhu ponovne uporabe te pronalaženje podataka. Za obje faze bitni su metapodatci.

Jedan od glavnih izazova vezanih uz podatke u današnje vrijeme u arheologiji je raspoloživost i ponovna uporaba arheoloških podataka (Gattiglia, 2014). Teme kao što su reprezentacija arheoloških podataka u strukturiranom obliku, njihova ponovna uporaba kao i semantika do sada su bile zanemarivane (Huggett, 2015). Sveprisutnom digitalnom tehnologijom stvoreni su preduvjeti za omogućavanje veće raspoloživosti arheoloških podataka i njihove uporabe u širim krugovima istraživača i javnosti.

U okviru znanosti korištenje digitalnih podataka u potpunosti je ovisno o raspoloživim i odgovarajućim metapodatcima. Metapodatci sadrže sintaktičke informacije koje nas informiraju o tome kako je skup podataka oblikovan i kako su polja podataka povezana, kao i semantičke informacije koje dokumentiraju postupak uzorkovanja, vremenski, prostorni i kulturni kontekst, procese zapisivanja i klasifikacije. Samo temeljem metapodataka moguće je napraviti usporedbu promatranja različitih skupova podataka i odrediti vrste postupaka koje je moguće provesti nad njima (Kintigh, 2006). Istraživanja ukazuju na izazove u području upravljanja podatcima i izgradnji digitalnih repozitorija u arheologiji, koji se rješavaju kroz osiguravanje kvalitetnih metapodataka, kao i na potrebu unaprjeđenja upravljanja podatcima već u inicijalnim fazama životnog ciklusa podataka, kao i u trenutku objave rezultata (Selhofer i Geser, 2015).

Kako bi arheološke entitete mogli prikazati korištenjem digitalne tehnologije, potrebno je ispravno ih zapisati u digitalnom okruženju i omogućiti njihovu dostupnost i pretraživanje. U nastavku rada detaljnije će se dati pregled postojećih dosega u arheologiji u kontekstu digitalnog okruženja, analizirati i sintetizirati digitalni arheološki zapis, identificirati važne elemente za definiranje i pretraživanje arheoloških entiteta u digitalnom okruženju i prikazati postojeće pojedine metapodatkovne sheme u području

arheologije. Otvoreni istraživački podatci namijenjeni su i drugim istraživačima, a kako bi ih oni mogli pretražiti te prepoznati njihovu relevantnost, bitno je osigurati elemente relevantne za njihovo pretraživanje i prepoznatljivost. U narednim poglavljima opisat ćemo te elemente, a pretraživanje će biti analizirano kroz elemente: korisnik, sučelje i web prostor.

4.1. Arheologija u kontekstu digitalnog okruženja

U području arheologije uporaba digitalnih tehnologija u svrhu istraživanja i katalogizacije[43] npr. arheoloških entiteta započela je krajem 1950-ih. Značajniji događaj dogodio se početkom 1960-ih kada je James Deetz u svojem projektu koristio računalo IBM704 za analizu stilističkih varijacija u keramici (Watrall, 2016). Rad Deetza je važan jer sugerira da je računalo izvrstan alat za statističku, tipološku, kronološku kao i stilističku analizu velikih i složenih skupova podataka u području arheologije. Krajem 1960-ih Chenhall je razvio sustav koji je omogućio zabilježbu opisnih atributa arheoloških entiteta. Ovi atributi su uključivali funkciju, oblik, materijal, tehniku izrade, površinsku obradu, dizajn i lokaciju (Smith, 2000). Projekti započeti u tom razdoblju ipak nisu bili posve uspješni jer nije postojala odgovarajuća tehnologija i infrastruktura.

Digitaliziranje arheoloških podataka tijekom 1970-ih povezano je uz korištenje muzejskih kataloga i programa. Npr. u Ujedinjenom Kraljevstvu koristila se programska podrška preporučena od strane grupe IRGMA, dok se u Sjedinjenim Američkim Državama koristio sustav državnog muzeja Arizone.

U razdoblju 1980-ih nije bilo šire primjene digitalne tehnologije u arheološkim istraživanjima. Međutim u tom razdoblju pojavili su se pojedini sustavi npr. geografski informacijski sustav kao i sustavi za dizajniranje, projektiranje, konstruiranje i vizualizaciju koji su omogućili provedbu istraživanja i diseminaciju rezultata na nove

[43] Katalogizacija je deskriptivni proces u kojem se navodi, identificira i zapisuje skup promatranih varijabli i vrijednosti arheoloških entiteta. Dobar katalog omogućava dovoljno podataka kojim ostali arheolozi mogu spoznati arheološki entitet bez da ga imaju ispred sebe. U većini slučajeva već prilikom pronalaska arheološkog entiteta istraživači mu pridružuju kataloški broj. Kataloški broj omogućava jedinstveno prepoznavanje arheološkog entiteta kao i povezivanje uz njegov kontekst te dokumentaciju istraživanja. Pojedini kataloški brojevi uključuju npr. godinu, broj serije, ili dodatne kodne oznake kojima se označuje materijal arheološkog entiteta (npr. u SAD koristi se Smithsonian trinomial, kojim se označava država, regija (okrug) i serijski broj nalazišta kao i njegove modifikacije). Katalog arheoloških entiteta kroz prošlost najčešće je bio realiziran putem papira, a u današnje se vrijeme primjenjuje digitalna tehnologija.

načine (Watrall, 2016). Za navedeno razdoblje možemo istaknuti sustav MINARK koji je u Australiji razvio Ian Johnson, a omogućavao je rad s različitim arheološkim podatcima i vremenom postao nacionalnim standardom (Smith, 2000).

Razdoblje između 1990-ih i 2010-ih donosi širu dostupnost računala, grafička sučelja, jednostavnije programe za obradu teksta i tablične kalkulacije, kao i web tehnologije. Digitalizacija arheoloških podataka provodi se kroz muzejske sustave (značajan sustav iz ove skupine na razini svijeta je PastPerfect[44], a u Hrvatskoj M++[45]) ili sustave za pojedinačne istraživačke projekte. Možemo reći da su ovi sustavi prvenstveno zatvoreni i ne omogućavaju jednostavnu razmjenu podataka između istraživača i/ili drugih sustava. U tom razdoblju možemo za područje Hrvatske istaknuti projekte:

- *Croato-Aegyptica Electronica* - istraživača Tomorad M. i Zlodi G, u kojem su pripremili bazu podataka o staroegipatskim zbirkama u Hrvatskoj te prezentirali podatke putem web portala http://www.croato-aegyptica.hr[46].
- *Projekt Burnum*[47] – istraživački projekt Odjela za arheologiju Sveučilišta u Zadru, Gradskog Muzeja u Drnišu i Laboratorija za arheološko-topografska istraživanja Odjela za arheologiju Sveučilišta u Bologni, u okviru kojega se provodio eksperiment distribucije znanja i razvoja zajedničkih obrazaca arheološke dokumentacije u kontekstu otvorenosti.

Pojava weba (Web 2.0, Web 3.0[48]) donosi značajne promjene u razmjeni podataka i komunikaciji u znanosti i istraživanjima. Web i pripadajuće digitalne tehnologije omogućavaju transformaciju profesionalne prakse u arheologiji, nove načina istraživanja, javno sudjelovanje u području arheologije, nove načine generiranja i dijeljenja sadržaja, kao i generiranje i dijeljenje metapodataka za opisivanje digitalnog sadržaja (Kansa, 2011).

---

[44] Na poveznici http://www.museumsoftware.com može se saznati više o navedenom programu.

[45] M++ je relacijska baza podataka za inventarizaciju muzejskih zbirki. Omogućava evidentiranje, pretraživanje, ispis, zaštitu podataka, prikaz multimedijalnog sadržaja i konvertiranje podataka u različite formate. Model podataka programa M++ temelji se na CIDOC podatkovnim kategorijama – međunarodnim smjernicama za podatke o muzejskom predmetu. (više na http://dizbi.hazu.hr/object/view/lAdzcMdbgL)

[46] Izvorno je web portal bio dostupan na adresi http://www.croato-aegyptica.hr, a danas je na http://www.starapovijest.eu.

[47] Više o ovom projektu moguće je saznati u okviru rada Vecchietti, E.: Beyond Methodology and Practice: The Burnum Project, a Case-Study of International Cooperation in Archeological Research, Archologia Adriatica, vol. 5, 2012, str. 105-125.

[48] Web 3.0 – semantički web, Linked Data.

Današnje vrijeme karakteriziraju digitalni objekti i digitalni repozitoriji. Namjena digitalnih repozitorija je pohrana, zaštita i široka dostupnost digitalnih objekata. Primjeri digitalnih repozitorija su: Digitalni antikviteti[49], Arheološki podatkovni servis (ADS)[50], Otvoreni kontekst[51], Sustav katalogiziranja arheoloških resursa (ARCS)[52], Usluge za pohranu podataka i umrežavanje (DANS)[53] i IANUS repozitorij Njemačkog arheološkog instituta iz Berlina[54].

Također, u svrhu omogućavanja šire dostupnosti arheoloških podataka i novih istraživanja na temelju većeg broja skupova podataka istraživačkoj zajednici na razini EU tijekom razdoblja 2013 - 2017 uspostavljen je projekt *Napredna istraživačka infrastruktura za umrežavanje arheoloških podataka u Europi* (ARIADNE)[55]. U projekt su bili uključeni različiti međunarodni i nacionalni istraživački centri npr. ADS, DANS, međutim Hrvatska nije bila uključena u ovaj projekt.

4.1.1. Digitalni arheološki zapis

Na prvi pogled kod arheološkog zapisa možemo reći da je on trag o ljudskoj prošlosti. Uključuje bilješke, crteže, fotografije, mape, tablice, grafikone kao i ostale materijale kojima se bilježe podatci o arheološkim entitetima i aktivnostima. Dostupna istraživanja ukazuju na to da je arheološki zapis pojmovno višeznačan. U istraživanju i analiziranju što je arheološki zapis identificirana su tri pristupa.

Prvi pristup je razvio Blackmar, koji arheološki zapis dijeli na tri klase: *zapis povezan uz terenski rad*, *interpretativni istraživački zapis i zapis zaštite* (Blackmar, 2002). Zapis povezan uz terenski rad obuhvaća podatke o istraživačkom projektnom planu, projektnoj dokumentaciji, inicijalnom istraživanju i pronađenim arheološkim entitetima. Ova faza se nadalje može podijeliti na aktivnosti prije terenskog rada kao i aktivnosti tijekom samog terenskog rada. Interpretativni istraživački zapisi uključuju sve dokumente generirane poslije iskopavanja ili tijekom analize, a uključuju i sirove podatke, kao i

[49] Digital Antiquity, https://www.digitalantiquity.org/
[50] Archaeology Data Service, https://archaeologydataservice.ac.uk/
[51] Open Context, https://www.opencontext.org/
[52] The Archaeological Resource Cataloging System, http://dev2.matrix.msu.edu/arcs/
[53] Data Archiving and Networked Services, https://dans.knaw.nl/en
[54] https://www.ianus-fdz.de/
[55] Advanced Research Infrastructure for Archaeological Dataset Networking in Europe, http://legacy.ariadne-infrastructure.eu/ i https://ariadne-infrastructure.eu/

objavljeni te neobjavljeni materijal. Zapisi zaštite kreiraju se tijekom razdoblja pohrane i očuvanja arheološke kolekcije.

Drugi je pristup razvio Carman koji arheološki zapis razmatra kroz perspektivu fizičkog modela kojeg reprezentira materijalni objekt i perspektivu tekstualnog modela kojeg reprezentira post-procesiranje i dekodiranje značenja (Carman, 2002). U okvire fizičkog modela Carman uključuje arheološki entitet, kontekstualne atribute, specifične atribute i deponirane kulturne objekte. Ovdje arheološki zapis postoji kao fizička činjenica, za razliku od tekstualnog modela, kod kojeg značenje zapisa nije dano kao fizička činjenica, nego se značenje kreira kroz proces kodiranja i dekodiranja. Ovaj model obuhvaća materijalne i kulturne resurse.

Treći pristup je Lucasov, a uzima u obzir da arheološki zapis može imati tri značenja (Lucas, 2012). Prvo se značenje odnosi na arheološki entitet, odnosno na sve objekte materijalne kulture[56]. U okviru drugog značenja zapis se odnosi na teoriju njihovog formiranja. Treće značenje je povezano uz povijesne izvore. Važnost Lucasovog razmatranja možemo tražiti u razmatranju arheološkog zapisa kao objekta (događaji, procesi, materijalni dio, vrijeme i njihova međusobna povezanost) kao i kroz novi način promatranja materijalnih promjena objekta temeljem formalne, prostorne, povezane i frekvencijske varijabilnosti (Walker, 2014).

Sastavni elementi arheološkog zapisa, su: izvorna dokumentacija (npr. zapisi s istraživanja, forme, crteži, fotografija, kataloški zapisi), analitička dokumentacija (zapisi fizičke, kvalitativne i kvantitativne analize), administrativna dokumentacija (projektna dokumentacija, nacrt istraživanja) i projektni izvještaji (deskriptivni i analitički tekstovi o istraživanju i nalazima) (McManamon, 2014).

Stavljanjem arheoloških zapisa u digitalno okruženje, stvaraju se mogućnosti za evidentiranje, zaštitu, analizu, npr. agregaciju širokog skupa podatka, usporedba podataka iz različitih područja, vizualizacija i prostorno prikazivanje podataka kao i njihovu široku diseminaciju. Transformacija arheološkog zapisa u strukturirani i digitalni oblik, sastoji se od interpretacije arheološkog zapisa, njegovog evidentiranja i zapisivanja kroz različite digitalne sustave te nadopunjavanja putem pojedinih dodatnih digitalnih sadržaja (npr.

[56] Materijalna kultura je pojam koji se odnosi na sve arheološke objekte. Obuhvaća objekte koje su ljudi izradili u prošlosti ali i prirodne objekte (npr. životinjske kosti, sjemenke). Materijalna kultura uključuje izrađevine i ekofakte.

tekst, slika, video, 3D model). Digitalni arheološki zapis u digitalnom okruženju predstavljen je putem digitalnog objekta.

Digitalni objekt možemo općenito opisati kao minimalnu jedinicu / skup podataka kojima opisujemo neki resurs u digitalnom okruženju. U katalogu termina Saveza istraživačkih podataka (RDA)[57] pod digitalnim objektom podrazumijeva se *„datastream“* bita / bajta, kojemu se može pristupiti putem jedinstvenog identifikatora ili pomoću referentnih atributa koji prikazuju njegova svojstva. Digitalni objekt ima sljedeće karakteristike: mogućnost uređivanja, interaktivnost, otvorenost te mogućnost kopiranja i distribucije (Research Data Alliance, 2017). Digitalni objekt sastoji se od dvije komponente, sadržaja i metapodataka (Nelson *et al.*, 2001).

Fedorin generički model digitalnog objekta podrazumijeva složeni objekt koji je agregiran od jedne ili više stavki sadržaja[58]. Sadržajne stavke mogu biti bilo koji sadržaj koji je lokalno pohranjen u repozitoriju, pohranjen na drugim vanjskim lokacijama ili samo referenciran od strane digitalnog objekta. Stavka sadržaja digitalnog objekta predstavljena je putem *„datastream-a“*. Svaki digitalni objekt ima najmanje jednu stavku sadržaja (*„datastream“*) koji se odnosi na metapodatke (Prater i Woods, 2017).

Sličan pristup digitalnom objektu prisutan je i u području arheologije. U studiji slučaja analize i konstrukcije minimalnih elemenata digitalne knjižnice u području arheologije Shen i suradnici koriste metodološki okvir 5S[59] te koriste digitalni objekt kao jedan od minimalnih elemenata za digitalnu knjižnicu (Shen *et al.*, 2005). Navode da se digitalni objekt sastoji od strukture i stavki sadržaja. Strukture pokazuju na koji način su arheološki podatci organizirani u odnosu na nekoliko dimenzija (npr. prostor, vrijeme, taksonomiju). Ističu važnost prostornog mjesta za uspostavu arheološke vertikalne i horizontalne povezanosti. Stavke sadržaja odnose se na crteže, slike, publikacije, preliminarne i završne izvještaje, kao i n-torke podataka iz baza podataka.

Istraživanje Gkrousa i Nikolaidoue vezano uz izgradnju digitalnih repozitorija za arheološka istraživanja ukazuje na potrebu dijeljenja podataka potrebnih za opis

---

[57] Research Data Alliance, https://www.rd-alliance.org/

[58] Fedora Digital Object Model, https://wiki.lyrasis.org/display/FEDORA34/Fedora+Digital+Object+Model

[59] Metodološki okvir 5S - (engl. streams, structures, spaces, scenarios, societies) je formalna teorija za digitalne knjižnice. Apstrakcija digitalne knjižnice provodi se temeljem digitalnih objekata, metapodataka, zbirki, repozitorija, usluga. Opisi i izjave u okviru nje se izvode temeljem matematičkih formulacija i objekata.

digitalnog objekta u dvije osnovne kategorije: *fizički dio* i *dio digitalne reprezentacije* (Gkrous i Nikolaidou, 2011). Svaka od navedenih kategorija ima potkategorije, koje sadrže metapodatke. Fizička kategorija sadrži potkategorije opći podatci (npr. istraživač, namjena, povijesni period, korišteni alati i itd.) i strukturni podatci (npr. je li dio arheološkog entiteta ili je sadržan u nekom od izloška). Kategorija digitalna reprezentacija sadrži dvije potkategorije: multimedija (sadrži digitalne slike i video u svrhu vizualizacije) i korelacija (sadrži prostorne podatke te podatke vezane uz konceptualnu korelaciju).

Temeljem prethodno navedenog, u okviru ovog rada pod pojmom digitalni arheološki zapis podrazumijevamo digitalni zapis nastao kroz terenski, interpretativni ili zaštitni rad istraživača-arheologa vezanog uz pojedini arheološki entitet, kojeg karakterizira fizički (materijalni objekt) odnosno tekstualni model (post procesiranje i dekodiranje značenja). Digitalni arheološki zapis u okviru digitalnog okruženja pohranjen je putem digitalnog objekta koji ima osnovnu strukturu (npr. atributi i vrijednosti) te stavke sadržaja (npr. slike, video zapisi, izvještaji i itd.).

4.1.2. Digitalni repozitoriji

Digitalni repozitorij je skup sustava i usluga koje omogućavaju pohranu, upravljanje, dohvat, prikaz i ponovnu uporabu digitalnih objekata (Pinfield, 2009). U kontekstu otvorenih istraživačkih podataka, digitalni repozitorij je proizvod istraživačkih aktivnosti kojemu mogu slobodno i bez (ili s malim) restrikcija pristupiti korisnici (Vrana, 2011).

Uži opis digitalnog repozitorija sugerira da se radi o entitetu koji je pretraživ te omogućava postavljanje upita. Osim digitalnih objekata, važnost repozitorija iskazana je i kroz čuvanje, upravljanje i omogućavanje dostupnosti digitalnim materijalima u različitim formatima. Materijal u online repozitorijima pripremljen je na način da omogućava pretraživanje, istraživanje i ponovnu uporabu. Kod repozitorija mora postojati dovoljno kontrole kako bi se osigurala autentičnost, pouzdanost, dostupnost i ponovna uporaba (Johnston, 2017).

Moguće aktivnosti u okviru pojedinih digitalnih repozitorija su deponiranje digitalnih objekata i njihovo testiranje u svrhu osiguravanja karakteristika navedenih od

strane istraživača, redovita provjera stabilnosti i očuvanja integriteta, sigurnosno arhiviranje, omogućavanje sredstava za pristup i uporabu digitalnih alata u ovisnosti od pravila i zakonske regulative, osiguranje da su digitalni objekti pripremljeni i migrirani u nove digitalne objekte ili standarde u svrhu dugotrajne dostupnosti (McManamon, 2014).

Repozitorij može biti uspostavljen od strane institucije, zajednice, istraživača ili drugih grupa, a omogućava pristup različitim digitalnim objektima (npr. znanstvenim člancima, knjigama, disertacijama, skupovima podataka itd.). Repozitorije možemo podijeliti na (Nicholas *et al.*, 2012) institucijske repozitorije (pohranjuju široki krug digitalnih objekta različitih oblika), predmetne repozitorije (prikupljaju i pohranjuju digitalne objekte iz jedne discipline, pokrivaju više institucija) i repozitorije oblika (odnose se na npr. studentske radove, doktorate, istraživačke podatke, digitalne slike).

Važan dio digitalnih repozitorija su metapodatci. Pojedina istraživanja ukazuju na to da je uporaba metapodatkovnih standarda u istraženim znanstvenim repozitorijima nekonzistentna, u pojedinim predmetnim repozitorijima uporabljuju se različiti standardi, najčešće se uporabljuju samo deskriptivni metapodatci, postoji velika razlika u korištenju vrsta podataka (eksperimentalni, promatrački, itd.) te je interoperabilnost kod takvih repozitorija na niskoj razini (Marcial i Hemminger, 2010).

4.1.2.1. Opći funkcionalni zahtjevi istraživačkih repozitorija

U području znanosti i istraživanja, repozitorij koji pokriva otvorene istraživačke podatke naziva se Istraživački podatkovni repozitorij. Kako bi istraživački podatkovni repozitoriji bili korisni u istraživanjima, moraju omogućiti određene funkcionalnosti. Inicijalne funkcionalnosti za repozitorij definiraju se prije izgradnje repozitorija.

U svrhu utvrđivanja zahtjeva za repozitorij, RDA[60] sugerira korištenje tzv. *„matrice funkcionalnih zahtjeva“*. Matrica se sastoji od funkcionalnih zahtjeva za repozitorij i studija slučajeva, pri čemu se sjecištu određenog funkcionalnog zahtjeva i studije slučaja pridružuje jedna od vrijednosti (npr. od 1 – presudno važno do 4 – nije važno).

Istraživanje Kima identificiralo je 75 zahtjeva, raspoređenih u 13 kategorija. Kategorije su sljedeće: metapodatci, trajni identifikatori, autentikacija i autorizacija,

[60] Opširnije u https://rd-alliance.org/sites/default/files/case_statement/rda-rprd-case-statement.pdf

pristup podatcima, potpora smjernicama, publikacija, objava i upravljanje, organizacija podataka, lokacija, integracija, zaštita i održivost, korisničko sučelje, kvaliteta podataka i proizvoda (Kim, 2018).

Pregled identificiranih zahtjeva za istraživačke podatkovne repozitorije u kategoriji metapodatci dan je u Tablici 3., u kojoj su navedeni identificirani zahtjev i izvor zahtjeva.

Tablica 3.: Zahtjevi za metapodatke kod istraživačkih podatkovnih repozitorija

Zahtjevi povezani uz metapodatke	Izvor		
	(Kim, 2018)	(Webb i McGoohan, 2015)	(Qin, Ball i Greenberg, 2012)
Podržavanje različitih metapodatkovnih shema i shema određenog područja	✓	✓	
Interoperabilnost	✓	✓	✓
Osiguranje metrike za procjenu kvalitete metapodataka	✓	✓	✓
Podržavanje pohranjivanja XML[61] zapisa	✓		
Pretraživanje, upiti i filtriranje	✓	✓	
Automatsko i poluautomatsko generiranje metapodataka	✓		✓
Povezivanje publikacija sa skupovima podataka			✓
Istraživanje resursa i njihova ponovna uporaba			✓
Mapiranje metapodataka		✓	
Povezivanje s vanjskim shemama u svrhu pobiranja i agregiranja		✓	
Povezanost putem *poveznica*		✓	
Izvoz metapodataka u formatu u kojem su uneseni i pohranjeni		✓	
Ispis metapodataka		✓	

[61] eXtensible Markup Language, https://www.w3schools.com/xml/xml_whatis.asp

Kao osnovne zahtjeve mogli bismo izdvojiti: podržavanje različitih metapodatkovnih shema i shema određenog područja, osiguranje interoperabilnosti i metrike za procjenu kvalitete, omogućavanje pretraživanja, upita i filtriranja te automatsko i poluautomatsko generiranje metapodataka.

4.2. Metapodatci

Važnost metapodataka istaknuta je već uvodnom dijelu rada, a vidljiva je i u životnom ciklusu podataka, posebno u fazi dijeljenja, ponovne uporabe arheoloških podataka (Willis, Greenberg i White, 2012), kao i u kontekstu digitalnih objekata i repozitorija.

Početne izvore metapodataka i strukturnih podataka možemo naći u glinenim pločicama iz kraljevskog arhiva Ebla iz vremena 2250 prije nove ere. Arhiv Ebla sadrži 15000 tisuća glinenih pločica koje ukazuju na standardizaciju zapisivanja, formuliranja i prakse (Gilliland, 2011). Sama arhiva sadrži nekoliko dijelova, pri čemu je uočljiva dosljednost u dokumentiranju, kao npr. nizanje po funkciji i subjektu, ukupni iznos naveden na kraju, a na raspolaganju su i imena ministra ili osobe koja je kreirala zapis kao i informacije o korištenju..

Početke uporabe izraza „metadata“ možemo tražiti u kasnim 1960-im kada Jack E. Myers uporablja ovaj termin vezan uz proizvod *„MetaModel*“, dok širi auditorij upoznaje ovaj termin početkom 1970-ih iz brošura o ovom proizvodu. Otprilike u isto vrijeme u okviru doktorske disertacije Bo Sundgren uporablja koncept meta informacije i artikulira razliku između informacije o fenomenu i podataka kojima reprezentira informacije opisujući fenomen (Sundgren, 1973). Početkom 1990-ih termin metapodatci koristi se u kontekstu prilagodbe računalnih podataka, kako bi bili razumljivi ljudima. Prva specifikacija podataka koja sadrži ovaj termin je iz područja prostornih podataka i poznata je pod nazivom „*Content Standard for Digital Geospatial Metadata*“ iz 1994. godine. Povećanjem važnosti računalnih mreža i interneta, termin metapodatci počinje se primjenjivati u kontekstu opisa digitalnih objekata na mreži. Tijekom vremena termin metapodatci prihvatio je široki krug znanstvenika i stručnjaka.

Termin metapodatci ne pojavljuje se često u arheološkoj literaturi i povezan je uz širu brigu o standardizaciji digitalnih arheoloških zapisa i objekata. Inicijalni razvoj

metapodataka u području arheologije dolazi preko digitalnih prostornih podataka. Podatci u digitalnom obliku zahtijevaju detaljne metapodatke u svrhu očuvanja kao i omogućavanja dostupnosti različitim korisnicima (npr. istraživači, javnost). Metapodatci postoje za svaki digitalni objekt ili grupu objekata koji su pohranjeni u digitalnom obliku.

U području arheologije, metapodatci omogućuju prikaz prirode podataka, pronalaženje podataka te njihovo grupiranje prema određenim obilježjima (Wise i Miller, 1997). Prema smjernicama Europskog arheološkog konzilija, svrha metapodataka leži u omogućavanju podataka o digitalnim objektima kako bi im se omogućio jednostavniji pristup, spoznaji i odlučivanju jesu li podatci korisni za ponovnu uporabu (Perrin *et al.*, 2014).

U kontekstu znanstvenih istraživanja i podataka, metapodatci moraju ispuniti tri osnovna zadatka (Canham i Ohmann, 2016). Prvi zadatak odnosi se na metapodatke koji služe za identificiranje *istraživačke studije*[62] iz koje proizlaze podatci. Drugi zadatak povezan je uz postojanje metapodataka koji moraju karakterizirati sam *istraživački objekt*. Treći zadatak uključuje metapodatke koji navode gdje se neki digitalni objekt *može pronaći* i uvjete pod kojima su podatci *raspoloživi i dostupni*

4.2.1. Definicija metapodataka

Najjednostavnije i najučestalije pojašnjenje metapodatke definira kao „podatke o podatcima“. U znanstvenim publikacijama možemo pronaći različite definicije i opise metapodataka. U nastavku ovoga poglavlja izdvojen je prikaz pojedinih opisa i definicija iz znanstvenih istraživanja u području informacijskih znanosti, kako bi se spoznala širina značenja metapodataka.

Miller opisuje metapodatke kao dodatne podatke koji se pridodaju objektu ili resursu, a omogućavaju korisniku smještaj objekta ili resursa u kontekst, kao i „dobivanje osjećaja za njih“ (Miller, 1999). Greenberg usmjerava opis metapodataka prema strukturiranim podatcima o objektima, pri čemu metapodatci podržavaju funkcije povezane s određenim objektom (Greenberg, 2003). Njezin opis pokazuje da se kod

[62] Autori ukazuju na to da ne postoji univerzalni i jedinstveni sustav identifikacije za istraživačke studije (projekte), te u tu svrhu sugeriraju uzimanje u obzir ime studije (projekta) uz dodavanje javnog identifikatora.

metapodataka radi o sustavnom uređenju podataka, pri kojem se kreiraju zapisi o objektima koji mogu biti entiteti, forme ili načini za koje kontekstualni podatci mogu biti zabilježeni. Zadnji dio njezine definicije usmjeren je na podržavanje opisa aktivnosti ili ponašanja objekta. Funkcije metapodataka u kontekstu ove definicije odnose se na pretraživanje resursa, upravljanje resursima, uporabu resursa od odgovarajuće zajednice, povezivanje resursa s drugim resursima i resursnu ovisnost o IT (Greenberg, 2005). Istraživanja (Caplan, 2003), (Smiraglia, 2005b), (Bawden i Robinson, 2012) također navode da se radi o strukturiranim podatcima za pristup resursu, koje je potrebno prikazati dokumentiranom metapodatkovnom shemom (Caplan, 2003), a omogućavaju različite funkcije (npr. istraživanje, upravljanje) kao i pretraživanje (Smiraglia, 2005b), (Yasser, 2011).

Novija istraživanja usmjeravaju opise metapodataka prema ukupnosti svega što u danom trenutku možemo navesti o digitalnom objektu i što reprezentiramo informacijskim objektom [63]. Kroz metapodatke iskazuju se sve informacije povezane uz *sadržaj* (intrinzične informacije o objektu, npr. što objekt sadrži), *kontekst* (ekstrinzične informacije o objektu, npr. tko, što, kada, gdje i kako je napravio objekt) i *strukturne* (formalni skup informacija o objektu) (Gilliland, 2016). Poveznicu između metapodataka i digitalnih objekata navode Ding i suradnici koji metapodatke tretiraju kao podatke za opis digitalnih objekata, pri čemu se objekti opisuju kroz sadržaj, kontekst i strukturu (Ding, Lin i Zarro, 2017).

Temeljem prethodnog pregleda literature metapodatke možemo opisati kao sustavno uređeni (standardizirani, strukturirani) skup podataka kojima se opisuje digitalni objekt. Putem metapodataka opisani su sadržaj, kontekst i struktura pojedinog digitalnog objekta te je moguće ostvariti njihovo pretraživanje, upravljanje, povezivanje kao i uporabu u zajednici. Metapodatci koji sačinjavaju informacijski objekt osiguravaju autentičnost, pouzdanost, uporabljivost i cjelovitost tijekom vremena, kao i upravljanje te razumijevanje (ISO, 2006).

[63] Gilliland pod informacijskim objektom smatra digitalnu stavku ili skupinu stavki, bez obzira na vrstu ili format, koji je moguće adresirati ili su čitljive računalima. Informacijski objekt može označavati digitalni „surogat“ izvornog objekta ili stavke (npr. slika, pdf knjige) i opisne zapise koji se odnose na objekte ili kolekcije. Ovaj opis informacijskog objekta odražava autoričinu usmjerenost na digitalni objekt..

4.2.2. Klasifikacija metapodataka i razine definiranja

U kontekstu znanosti, istraživanja i podataka, metapodatke možemo klasificirati kao *deskriptivne*, *strukturne*, *administrativne* i metapodatke vezane uz *interpretaciju, razumijevanje te korištenje* (Davenhall, 2011). U okvirima knjižničarstva metapodatke klasificiramo kao: *deskriptivne*, *strukturne* i *administrativne,* pri čemu administrativne metapodatke dodatno dijelimo na*: tehničke metapodatke, metapodatke autorskih prava i dozvola i metapodatke za čuvanje i zaštitu* (Caplan, 2003). U kontekstu informacijskih znanosti Gilliland metapodatke dijeli na: *administrativne*, *deskriptivne*, *za čuvanje i zaštitu*, *tehničke* i *korisničke* (Gilliland, 2016).

Administrativni metapodatci koriste se u svrhu upravljanja i administriranja digitalnih objekata. Ovi metapodatci uključuju primjerice podatke kada je digitalni objekt kreiran, tko je odgovoran za arhiviranje sadržaja i koje su aktivnosti poduzete s njime. Deskriptivni metapodatci koriste se u svrhu pronalaženja digitalnih objekta, identifikacije, odabira i evaluacije. Strukturni metapodatci odnose se na lokaciju koja sadrži podatke o digitalnim objektima, kao i njihove relacije u odnosu na druge objekte. Korisnički metapodatci su povezani uz razinu i način korištenja digitalnog objekta npr. praćenje uporabe, pretraživanje log-datoteka, inačicu, registriranje ponovne uporabe i sl.

U određenim znanstvenim područjima, poljima i granama određeni se skupovi metapodataka učestalo koriste, pa tako bilježimo: *biologija, biomedicina i srodne znanosti* (npr. Ecological Metadata Language (EML)[64], Genome metadata[65], Observ-OM[66]), *geografija* (Astronomy Visualization Metadata (AVM)[67], Directory Interchange Format (DIF)[68], ISO 19115 Geographic Information[69]), , *fizika* (SPASE Data Model[70], Observations and Measurements[71]), *društvene i humanističke znanosti* (npr. Data Documentation Initiative (DDI)[72], Statistical Data and Metadata eXchange (SDMX)[73],

[64] https://eml.ecoinformatics.org/
[65] https://docs.patricbrc.org/user_guides/organisms_taxon/genome_metadata.html
[66] http://www.observ-om.org/wiki/ObservStart
[67] https://www.virtualastronomy.org/avm_metadata.php
[68] https://earthdata.nasa.gov/esdis/eso/standards-and-references/directory-interchange-format-dif-standard
[69] http://www.dcc.ac.uk/resources/metadata-standards/iso-19115
[70] http://www.spase-group.org/data/
[71] https://www.opengeospatial.org/standards/om
[72] https://ddialliance.org/
[73] https://sdmx.org/

MIDAS-Heritage[74]) i *opći istraživački podatci* (Common European Research Information Format (CERIF)[75], Open Archives Initiative Object Reuse and Exchange (OAI-ORE)[76], DataCite Metadata Schema[77]).

Elings i Waibel podijelili su opis metapodataka na pet ključnih koncepata: *podatkovna polja i strukture* (elementi ili kategorije koje je potrebno popuniti određenim informacijama o djelu); *podatkovni sadržaj i vrijednosti* (informacije koje su namijenjene za popunjavanje tih elemenata i kategorija); *podatkovni format* (vezan je uz kodiranje informacije), *način zapisa* (XML) i *razmjena podataka* (protokol za dijeljenje zbirke zapisa) (Elings i Waibel, 2007 prema Skinner, 2014).

U sklopu potpoglavlja 4.1.1 definirano je da su osnovna struktura i stavke sadržaja sastavni dijelovi digitalnog objekta. Europski arheološki konzilij[78] u svojim smjernicama ukazuje na to da je metapodatke moguće definirati na tri razine: na razini *projekta* (opći kontekst, geografska lokacija, vremenski period), *sadržaja* (uključuje sve varijable / atribute i vrijednosti koje su prikupljene tijekom istraživanja) i *datoteke* (odnosi se na specifični sadržaj) (Perrin *et al.*, 2014). Ovakav pristup možemo vidjeti i kod digitalnog nizozemskog digitalnog repozitorija za pohranu istraživačkih podataka EASY koji ima tri razine metapodataka: *metapodatke projektne razine, specifične metapodatke na razini datoteka i metapodatke na razini varijabla i koda* (Hollander, 2014).

Analizom modela životnih ciklusa podataka Australskog nacionalnog podatkovnog servisa te Rüegg i suradnika utvrđeno je da je metapodatke potrebno definirati za sve faze istraživačkog ciklusa (npr. povijest istraživanja, kreiranje ili prikupljanje podataka, čuvanje i zaštitu podataka, organizaciju podataka, identifikaciju podataka, analizu podataka, pristup podatcima kao i korištenje podataka). Usporedimo li faze životnog ciklusa podataka i identificirane razine definiranja metapodataka možemo utvrditi da nedostaju elementi koji se odnose na pripremnu fazu istraživanja.

[74] https://rdamsc.dcc.ac.uk/msc/m24
[75] https://www.eurocris.org/cerif/main-features-cerif
[76] https://www.openarchives.org/ore/
[77] https://schema.datacite.org/
[78] Europae Archaeologiae Consilium, https://www.europae-archaeologiae-consilium.org/

4.2.3. Metapodatkovne strukture

Kako bi se omogućila uspostava odnosa između elemenata metapodataka i njihova smislenost, metapodatci moraju biti strukturirani. Strukture koje su prisutne kod metapodataka su: *standardi, sheme i aplikacijski profili*.

Svaka struktura sadrži metapodatkovne elemente. Metapodatkovni elementi su povezani uz opis ili sadržaj digitalnog objekta. Svakom metapodatkovnom elementu je pridružen naziv (npr. ime, autor, lokacija) koji razlikuje metapodatkovni element od drugih metapodatkovnih elemenata u pojedinoj strukturi.

Struktura najviše razine je *metapodatkovni standard*. On je skup metapodataka predodređenih u svrhu standardiziranja opisa objekta u digitalnom okruženju. Metapodatkovni standard je razvijen za podržavanje specifičnih interesa pojedine zajednice (St. Pierre i LaPlante, 1999). Razvoj ovakve vršne strukture kontrolira se usklađivanjem u zajednici, uz formalne procese predlaganja, odobravanja i objavljivanja novih elemenata. Objavljena specifikacija održava se na središnjoj lokaciji unutar referentnog dokumenta ili metapodatkovnog registra koji sadrže načela, semantičke definicije elemenata, opise njihove reprezentacije u digitalnom obliku kao i način implementacije. Stupanj do kojeg možemo primijeniti neki standard ovisi o objektima od interesa, raspoloživoj tehnologiji i aktivnostima koje su prepoznate od zajednice. Svaki standard je pripremljen s različitim ciljevima uporabe metapodataka za različite korisničke grupe, jedinstvenim rječnikom, prilagođenim taksonomijama i odgovarajućim razinama granuliranosti. Najpopularniji metapodatkovni standard je Dublin Core (DC).

Struktura niže razine od metapodatkovnog standarda je *metapodatkovna shema*. Metapodatkovnu shemu možemo promatrati kao: skup elemenata prikupljenih u svrhu podrške funkciji ili skupu funkcija za digitalni objekt, skup elemenata metapodataka koji formiraju strukturirani spremnik kojeg nadopunjujemo podatkovnim vrijednostima ili skup podatkovnih elemenata s atributima formaliziranim u specifikaciji (ili podatkovnom rječniku) (Greenberg, 2005). Međunarodna organizacija za normizaciju[79] pod metapodatkovnom shemom podrazumijeva logički plan koji pokazuje povezanost između elemenata metapodataka temeljem uspostavljenih pravila za uporabu i upravljanje metapodataka, uzimajući u obzir semantiku i sintaksu (ISO, 2006).

[79] International Organization for Standardization (ISO), https://www.iso.org/home.html

Općenito, sheme u području arheologije možemo podijeliti na sheme koje opisuju digitalne objekte (npr. DC, ADS, tDAR[80]) te sheme višeg reda koje su usmjerene na agregiranje, ontologiju i preuzimanje metapodataka (npr. LIDO[81], CARARE[82]).

Kontrolirani rječnici i tezaurusi su dodatne ključne komponente u okviru metapodatkovnih shema. Njihovom uporabom kod digitalnih objekata korisnicima su osigurane bolje mogućnosti pretraživanja i pronalaženja. Moguće je definirati više rječnika po shemi, a najčešće se koriste npr. tezaurus geografskih imena, kontrolirani rječnik umjetnosti i arhitekture (npr. Getty Art & Architecture Thesaurus) ili internacionalni tezaurusi (Shaw, Corns i Mcauley, 2009).

Metapodatkovne sheme u području arheologije imaju dva osnovna problema. Prvi je da shema uzima resurs kao informacijski paket, bez obraćanja pozornosti na razlikovanje sadržaja i nositelja, a druga poteškoća jest ta da je većina shema napravljena bez empiričkog razumijevanja koncepta koji treba biti predstavljen i kako će se metapodatkovni elementi primijeniti za pretraživanje (Smiraglia, 2005a).

U kontekstu znanstvenih istraživanja bitno je naglasiti da zbog različite prirode istraživačkih podataka (npr. varijacija po znanstvenim disciplinama, razlika u formatu i vrstama, procesiranju i metodama) ne postoji niti jedan metapodatkovni standard i shema koji univerzalno mogu biti primijenjeni na sve vrste istraživačkih skupova podataka (Qin, Ball i Greenberg, 2012; Canham i Ohmann., 2016).

Na nižoj razini od metapodatkovne sheme nalazi se *aplikacijski profil*.

4.2.3.1. Aplikacijski profil

Inicijalnu definiciju aplikacijskog profila (AP) daju Herry i Patel, a glasi: „*aplikacijski profil je shema koja se sastoji od podatkovnih elemenata preuzetih iz jedne ili više metapodatkovnih shema*[83] *kombiniranih od strane implementatora i optimiziranih*

[80] The Digital Archaeological Record, https://www.tdar.org/
[81] Lightweight Information Describing Objects, http://www.lido-schema.org/documents/LIDO-Handout.pdf
[82] Connecting ARchaeology and ARchitecture in Europeana, https://pro.carare.eu/
[83] Izvorno je u definiciji naveden imenski prostor. Imenski prostor sadrži sve elemente definirane od strane registracijskog tijela, odnosno tijela koje je odgovorno za deklariranje i održavanje sheme. Imenski prostor je važan za aplikacijski profil jer se temeljem njega identificira tijelo koje upravlja skupom elemenata, osigurava jedinstvenost identifikatora za elemente, kao i jedinstvenost za određene podatkovne elemente ili rječnike. Imenski prostor u okviru ovog rada je metapodatkovna shema.

za određenu primjenu“ (Heery i Patel, 2000). Kritiku inicijalne definicije daju Nilsson i suradnici koji ukazuju da uzimanjem metapodataka iz modela različitih apstrakcija dovodi do semantičke zbrke (Nilsson *et al.*, 2008). Drugi pristup je usmjeren na primjenu metapodataka za određenu domenu gdje su poznati funkcionalni zahtjevi, entiteti koje je potrebno opisati kao i njihove povezanosti. U tom kontekstu Nilsson, Baker i Johnston ukazuju da se radi o specifikaciji korištenja metapodatkovnog standarda kako bi se podržali zahtjevi određene aplikacije, funkcije, zajednice ili konteksta (Nilsson, Baker i Johnston, 2008). Primjena u određenom području i ispunjenje funkcionalnih zahtjeva provodi se elementima iz jednog ili više skupova elemenata, kao i lokalno definiranim elementima (Chaudhri *et al.*, 2010).

U okvirima ovog istraživanja identificirana su dva pristupa u razvoju aplikacijskog profila: DCMI[84] metodološki okvir *Singapore Framework* (SF)“[85] (Nilsson, Baker i Johnston, 2008) i *MAP*[86] *reverzni inženjering* (MAP-RI) (Malta i Baptista, 2017).

Obvezni elementi kod DCMI-SF su funkcionalni zahtjevi, model domene i profil opisa. Ovim elementima mogu se pridodati korisničke smjernice i smjernice o formatima podataka. MAP-RI ima sljedeće elemente: funkcionalne zahtjeve, model korištenja slučaja, identifikaciju i opis elemenata iz modela. Usporedba ovih pristupa navedena je u Tablici 4., a dana je u odnosu na obvezatne elemente iz DCMI-SF i njihovo generaliziranje.

Tablica 4.: Usporedba razvojnih pristupa za aplikacijski profil

Usporedba		Razvojni pristup	
Naziv	Element	DCMI-SF	MAP-RI
Utvrđivanje funkcionalnih zahtjeva	Usmjerenje	- korisnik	- sustav
	Realizacija	- što treba AP omogućiti / ispuniti, ograničenja	- kako sustav radi, koji su elementi i kako su povezani

[84] Dublin Core Metadata Initiative, https://www.dublincore.org/
[85] Skraćenica DCMI-SF
[86] Metadata Application Profile

Usporedba		Razvojni pristup	
Naziv	Element	DCMI-SF	MAP-RI
Opis zahtjeva i njihov prikaz	Opis	- entiteti i njihova povezanost	- vanjski entiteti i interakcija sa entitetima analiziranog sustava
	Prikaz	- ER[87] dijagram	- UML[88] dijagram slučaja korištenja
Identifikacija i opis elemenata	Postupak	- provjera entiteta u rječniku shema - definiranje svojstva prema RDF[89]	- definiranje elementa temeljem dijagrama - definiranje svojstva prema RDF
	Rezultat	- svojstvo, rang, URI[90], opis	- ime elementa, kardinalnost, pretraživost i povezivanje

Vidljivo je njihovo razlikovanje u odnosu na usmjerenje, DCMI-SF je usmjeren na korisnika i njegove potrebe, a MAP-RI je usmjeren na funkcionalnost sustava. DCMI-SF je široko prihvaćen pristup u izradi aplikacijskog profila, a MAP-RI ima tek nekoliko primjena.

Općenito, aplikacijski profil ima najveću primjenu u okviru istraživačke zajednice. Od metapodatkovnih shema najviše se primjenjuje Dublin Core metapodatkovna shema i rječnik DCMI Type Vocabulary[91]. Praktičari koriste različite nazive (npr. metapodatkovni rječnik, standard, semantički elementi) za aplikacijski profil (Malta i Baptista, 2014).

4.2.3.2. Model domene

Model domene općenito prikazuje važne tipove objekta u kontekstu nekog sustava. Prema Baker i Coylu model domene u kontekstu metapodatkovnih shema je opis objekata koje

[87] Entity Relationship diagram, https://www.sciencedirect.com/topics/computer-science/entity-relationship-diagram
[88] Unified Modeling Language, https://www.uml.org/
[89] Resource Description Framework, https://www.w3.org/RDF/. Više o ulozi RDF u aplikacijskom profilu: http://dublincore.org/documents/profile-guidelines/#RECIPES, dodatak C.
[90] Uniform Resource Identifier, https://tools.ietf.org/html/rfc3986
[91] DCMI Type Vocabulary, https://www.dublincore.org/specifications/dublin-core/dcmi-type-vocabulary/2000-07-11/

će metapodatci opisivati kao i relacije između njih. Model domene je osnovni nacrt za aplikacijski profil (Coyle i Backer, 2009).

U raspoloživoj literaturi je identificirano nekoliko pristupa u izradi modela domene za potrebe izrade aplikacijskog profila, a značajniji pristupi su konceptualni model funkcionalnih zahtjeva za bibliografski zapis (FRBR)[92] (Žumer, Zeng i Salaba, 2010), model objekt - uloga[93] (Malta i Baptista, 2013) i model agilnog razvoja (Ochiai, Nagamori i Sugimoto, 2014). Modeli objekt-uloga te agilnog razvoja su složeni postupci[94] razvoja modela domene. Uključuju iterativni pristup razvoju modela, nedovoljno su dokumentirani te nisu uzeti u obzir za izradu modela domene.

Konceptualizaciju na razini digitalnog objekta i u kontekstu otvorenih istraživačkih podatka u ovom radu povezujemo uz model *Funkcionalnih zahtjeva bibliografskih zapisa*. Ovaj konceptualni model definirala je IFLA[95] tijekom 2008 godine, s usmjerenjem na konceptualno modeliranje u svrhu unaprjeđenja katalogiziranja zapisa te pripadajućih procesa uz pomoć tehnologije. Značaj FRBR možemo tražiti u uvažavanju sadržaja, konkretizaciji na razini jedinice, usmjerenosti na korisnika te omogućavanju provođenja generičkih zadataka koji najbolje odgovaraju korisničkim potrebama (Žumer, Zeng i Salaba, 2010). Generički zadatci[96] se odnose na pronalazak, identifikaciju, odabir, pristup i istraživanje resursa (Riva, Le Boeuf i Žumer, 2016). Ove zadatke možemo usporediti sa FAIR načelima za otvorene istraživačke podatke.

FRBR definira tri grupe entiteta. Entiteti prve grupe odnose se na različite aspekte interesa korisnika za intelektualne ili umjetničke kreacije, a obuhvaćaju: rad, izraz, pojavni oblik i jedinicu. Druga grupa je usmjerena na predstavljanje odgovornih za stvaranje ili diseminaciju intelektualnog ili umjetničkog sadržaja, a obuhvaća entitete osoba i organizacija. Entiteti treće grupe predstavljaju dodatne entitete koji mogu služiti za označavanje predmeta rada. Ova grupa uključuje entitete koncept (apstraktna notacija

[92] Functional Requirements for Bibliographic Records, FRBR
[93] Object Role Modeling, http://agilemodeling.com/artifacts/ormDiagram.htm
[94] Za izradu modela domene uz pomoć modela objekt-uloga potrebno je identificirati klase, objekte, odrediti njihovu povezanost i napraviti detaljan dijagram za modeliranje domene.
[95] International Federation of Library Associations, https://www.ifla.org/
[96] Pronalazak – pretraživanje temeljem relevantnih kriterija u svrhu pronalaska jednog ili više resursa od interesa; Identifikacija – razumijevanje prirode resursa i njegovo razlikovanje u odnosu na slične resurse; Odabir – određivanje prikladnosti pronađenih resursa i odabir određenog; Pristup – pristup sadržaju resursa; Istraživanje – korištenje povezanosti (relacija) među resursima u svrhu smještaja u kontekst ili povezivanja.

ili ideja), objekt (materijalni pojam), događaj (akcija ili pojavnost) i prostor (mjesto) (Madison *et al.*, 2009).

Svaki entitet u ovom modelu ima skup karakteristika odnosno atributa[97]. Atributi su namijenjeni za formuliranje upita pri traženju podataka o određenom entitetu i interpretaciju dobivenih odgovora. Dijelimo ih u dvije kategorije: one svojstvene entitetu i one pridodane izvana.

4.2.4. Metapodatkovne sheme u arheologiji

U arheologiji se koriste različite metapodatkovne sheme i standardi. U ovome se dijelu daje pregled značajnih metapodatkovnih shema. Uvidom u raspoloživu literaturu identificirane su sljedeće relevantne metapodatkovne sheme: *Dublin Core (DC)*, *Archaeology Data Service (ADS)*, *the Digital Archaeological Record (tDAR)*, *MAPPA*[98] *Open Data Metadata (MOD)* i *Connecting Archaeology and Architecture in Europeana (CARARE)*. Prethodne metapodatkovne sheme su različitih struktura, složenosti i zahtjevnosti. DC shema je odabrana zbog opće i široke primjene. Sheme ADS i tDAR su odabrane zbog široke uporabe u području arheologije, uporabe u arhiviranju i očuvanju različitih arheoloških entiteta te omogućavanju javne dostupnosti arheoloških podataka. MOD shema je odabrana zbog pokrivanja različitih arheoloških entiteta i sadržaja (npr. projekta, arheološke literature, teksta, slika, multimedije) i povezanosti uz kontekst otvorenih istraživačkih podataka. CARARE shema je odabrana zbog uvida u sheme namijenjene za prikupljanje i preuzimanje podataka.

Pregled navedenih metapodatkovnih shema napravljen je temeljem sastava digitalnog objekta, pojavnosti pojedinih entiteta u okviru osnovne strukture i kod sadržajnih stavki te smjernica Europskog arheološkog konzilija o mogućim razinama evidentiranja metapodataka (projekt, sadržaj, datoteka).

---

[97] U okviru modela FRBR navodi se da se radi o atributima; atribute u okviru ovog rada s obzirom na njihovu namjenu izjednačavamo sa metapodatkovnim elementima.
[98] Metodologie applicate all predittività del potenziale archeologico, http://mappaproject.arch.unipi.it/mod/Index.php

4.2.4.1. Dublin Core (DC)

Dublin Core (DC) je osnovni skup elemenata metapodataka dovoljno širok i generički, koji se koristi u svrhu opisa digitalnih objekata i poboljšanja pretraživanja tih objekata u online okruženju. DC ima 15 osnovnih elemenata i to: suradnik, opseg, stvaratelj, datum, opis, format, identifikator, jezik, izdavač, odnos, prava, izvor, tema, naslov i tip.

Iako shema ima fiksni i ograničeni format vrlo je popularna i ima široku primjenu. Razloge široke primjene možemo tražiti u pripremljenosti DC kao izvora za opis svih digitalnih sadržaja, jednostavnosti i mogućnosti uspostave odnosa između objekata (Kulasekaran *et al.*, 2014). Implementacija DC najčešće se realizira uporabom različitih sintaksi npr. HTML[99], XML, RDF ili u generičkoj formi.

Elemente DC možemo razvrstati s obzirom na kategorije: sadržaj, intelektualno vlasništvo i prava korištenja te samu pojavnost izvora (Hakala, 2000). Osnovni DC formalno podržavaju tri standarda: ISO Standard 15836:2009, ANSI[100]/NISO[101] Standard Z39.85-2007 i IETF[102] RFC[103]. Tijekom vremena osnovni DC je proširen kvalifikatorima koji se moraju primijeniti zajedno s elementima na koje se odnose te koje su označavali. Razlikujemo tri vrste kvalifikatora; za jezik, shemu i tip. Jezični kvalifikator omogućava višejezičnost DC. Kvalifikator shema usmjeren je na sadržaj, dok je svrha kvalifikatora tip suženje značenja pojedinog elementa.

Iz dostupnih rezultata istraživanja vidljivo je da se DC uporablja i u području arheologije npr. (Kulasekaran *et al.*, 2014), (Wise i Miller, 1997) uz potrebnu prilagodbu npr. autor = kreator, suradnik = radnik na iskopavanju. Pojedina istraživanja ukazuju na to da DC ima ograničenja vezano uz opisivanje složenijih resursa (Ryan, 2001).

Postojeća znanstvena istraživanja kao i digitalni repozitoriji pokazuju da se pojedini elementi DC koriste za entitet *projekt* u okviru metapodatkovne sheme ADS. U okviru digitalnog repozitorija EASY shema DC također se koristi za opis entiteta *projekt*. Za opis entiteta *projekt* koristi se obaveznih sedam DC elemenata (*kreator, naslov, opis, datum kreiranja, prava, datum raspoloživosti, licencije*) (Hollander, 2014).

---

[99] Hyper Text Markup Language, https://www.w3schools.com/html/html_intro.asp
[100] American National Standard Institute, https://www.ansi.org/
[101] National Information Standards Organization, https://www.niso.org/
[102] Internet Engineering Task Force, https://ietf.org/
[103] Request form Comments, https://en.wikipedia.org/wiki/Request_for_Comments

4.2.4.2. The Digital Archaeological Record (tDAR)

The Digital Archaeological Record (tDAR) je digitalni repozitorij koji je razvila institucija Digital Antiquity čiji je cilj zaštita i omogućavanje pristupa digitalnim zapisima arheoloških istraživanja iz različitih dijelova svijeta. Digitalni repozitorij je razvijen u svrhu uključivanja baza podataka, tablica, izvještaja, slika kao i ostalog digitaliziranog arheološkog sadržaja.

Digitalni objekti unutar tDAR dokumentirani su setovima metapodataka. U okvirima ovog rada metapodatci i pripadajući elementi analizirani su na temelju sadržaja objavljenog na web stranicama tDAR-a[104]i Atlassian[105].

Metapodatci pridruženi su na razini projekta[106], zbirke[107] ili pojedinog resursa. Za u objekte u repozitoriju tDAR-a postoje opći metapodatci te metapodatci koji su povezani uz dokumentacijsku datoteku, sliku, ontologiju, prostorne podatke i senzorske podatke.

U okviru ove sheme identificirani su entiteti: projekt, osnovna struktura, publikacija, slika, prostorni podatci i senzorski podatci.

Entitet *projekt* opisan je pomoću identifikatora, imena, statusa i opisa projekta te pripadnosti kolekciji.

Opći elementi ove sheme povezani su uz opis arheološkog entiteta. U okviru ovog rada opće elemente povezujemo uz entitet *osnovna struktura*. Elementima općeg dijela opisujemo entitet putem: imena, kratkog opisa, statusa u okviru životnog ciklusa, izdavača, lokacije izdavača, autora (ime, prezime, elektronička pošta, institucija, uloga), institucije (ime, uloga, elektronička pošta), identifikatora (ime, pridružena vrijednost), vrste istraživanja, nalazišta (ime, vrsta, ključne riječi), materijala (vrsta materijala, dodatne vrste), kulturnog pojma (kulturni pojam, dodatni kulturni pojam), vremenskih odrednica (vrsta datuma, početna godina, završna godina, pojmovi), ključnih riječi, geografskih odrednica (geografsko ime, koordinate), institucije koja je omogućila sadržaj

[104] https://docs.tdar.org//display/TDAR/Data+Dictionary, inačica od 16. 1. 2015.
[105] https://tdar-arch.atlassian.net/wiki/spaces/TDAR/pages/557072/Data+Dictionary, inačica od 16. 1. 2015.
[106] U okviru tDAR repozitorija pod projektom se podrazumijeva grupirani skup digitalnih objekata i pripadajućeg sadržaja. Projekt je u ovom smislu istraživački projekt u svrhu očuvanja arheoloških entiteta, ali i istraživanje koje uzima u obzir odabrani skup podataka.
[107] Kolekcija u okviru tDAR omogućava grupiranje projekata, pojedinih digitalnih objekata ili ostalih kolekcija. Na razini kolekcije određuju se prava pristupa i dijeljenje podataka s ostalim istraživačima.

(ime institucije), osoba povezanih uz sadržaj (ime, prezime, institucija, uloga) te osoba koje imaju pravo ažuriranja metapodataka (ime, prezime, dozvole).

Ova metapodatkovna shema sadrži i elemente koji se odnose na sadržajne stavke, a to su sljedeći entiteti: publikacija, slika, prostorni podatci i senzorski podatci.

Entitet *publikacija* opisan je sljedećim elementima: naslovom, vrstom publikacije, DOI[108], ISSN[109], ISBN[110], jezikom, edicijom, imenom serije, brojem serije, volumenom, brojem izdanja, početnom stranicom, završnom stranicom, institucijom, odjelom, konferencijom, lokacijom konferencije i lokacijom izdanja. Opis entiteta *slika* dan je temeljem pojedinih elemenata iz općih elementa kao i navođenjem lokacijom pohrane.

Prostorni podatci koji se prikupljaju opisani su kroz entitet *prostorni podatci*. Ovaj entitet opisan je putem prostornih referenci, izvora za mapu i skala.

Podatci koji se prikupljaju pomoću senzora, sadržani su u okviru entiteta senzorski podatci. Entitet *senzorski podatci* opisan je elementima koji se odnose na: opće podatke, istraživačke podatke, podatke o skeniranju, podatke o referentnoj slici, podatke za usklađenje točaka i podatke o skupu točaka. Općim podatcima navodi se o kojem se objektu radi. Podatcima o istraživanju opisuju se npr. vremenski termini, uvjeti, detalji o uređaju, rezoluciji te konačni skup podataka. Skeniranje se odnosi na podatke uz ime datoteke, ime objekta, datum skeniranja i rezoluciju. Referentna slika opisana je elementima: ime i opis. Temeljem senzorskih podataka moguće je definirati 3D model[111], a za prikaz 3D modela potrebni su podatci o skupu točaka. Skup točaka ovisan je o vrsti oblika koji se koriste za mrežu, a zajednički su im opisi npr. ime skupa podataka, broj točaka poligona ili trokuta, operacije procesiranja.

Na razini pojedine datoteke, za opis se koriste sljedeći elementi: ime datoteke koja se stavlja na sustav, opis datoteke, datum kreiranja datoteke i prava pristupa.

---

[108] Digital Object Identifier, https://www.doi.org/
[109] International Standard Serial Number, https://www.issn.org/
[110] International Standard Book Number, https://www.isbn-international.org/
[111] 3D model je digitalna reprezentacija fizičkog ili zamišljenog modela uz pomoć tri dimenzije. Radi se putem specijaliziranih programskih rješenja.

4.2.4.3. Archaeology Data Service (ADS)

Digitalni repozitorij Archaeology Data Service (ADS) osnovan je 1996. godine u svrhu očuvanja arheoloških digitalnih podataka iz Ujedinjenog Kraljevstva te omogućavanja njihove dostupnosti i ponovne uporabe. Inicijalno je uspostavljen kao dio usluge za podatke iz područja umjetnosti i humanističkih znanosti.

Od strane ADS-a prepoznata je važnost metapodataka. Polazi se od toga da je metapodatke potrebno generirati od početka projekta, kao i tijekom procesiranja (Mitcham, Niven i Richards, 2010).

Metapodatci i pripadajući elementi ADS analizirani su temeljem Vodiča za dobru praksu (ADS, 2017) objavljenog u suradnji ADS-a i Digital Antiquity.

Grupiranje metapodataka kod ADS-a provodi se u 4 kategorije. Prva kategorija pokriva metapodatke za entitet *projekt*, pri čemu je usmjerenje na evidentiranju deskriptivnih podatka cijelog projekta. Podatci za ovu skupinu preuzimaju se iz istraživačkog izvještaja s lokacije. ADS u svrhu ove kategorije koristi pojedine elemente DC metapodatkovne sheme. Elementima se opisuju: jedinstveni identifikator, ime projekta, osnovni ciljevi i kratki opis sadržaja, geografske i vremenske odrednice, autor i odgovorne osobe, organizacija koja prikuplja podatke, suradnici na projektu, prethodni relevantni izvori za istraživanje, podatci vezani uz životni ciklus podataka, nositelj vlasničkih prava, povezanost na izvorni materijal, jezik koji je korišten i oblik u kojem su podatci snimljeni.

Druga kategorija pokriva entitet *arheološki resurs* i sadržajne stavke, a cilj ove kategorije je detaljni opis resursa kao i njegovih mogućih sadržajnih stavki. U okviru ove kategorije, ADS se u velikoj mjeri oslanja i koristi tDAR metapodatke. Entitet arheološki resurs opisujemo sljedećim elementima: općim podatcima (status u okviru životnog ciklusa, jezik, godina kreiranja, opis / sažetak, fizička lokacija pohrane), bibliografskim podatcima, identifikatorima (vrsta, vrijednost), podatcima o nalazištu (ime, vrsta, ključne riječi), vrstom materijala, kulturnim terminima (vrsta, dodatni termin), vremenskim odrednicama (vrsta datuma, početna i završna godina, način određivanja datuma), ključnim riječima, geografskim odrednicama (geografski termin, koordinate), pružateljem usluga (institucija) te individualnom i institucijskom ulogom (ime, e-mail, institucija, uloga).

Sadržajna stavka može biti jedna ili više datoteka, ovisno o kontekstu (npr. slika, skup podataka, senzorski podatci). Može uključivati specifične elemente (npr. citate, datume, lokacije, tip materijala, ključne riječi). Metapodatci na ovoj razini raspoređeni su kroz kategorije: *osnovni sadržaj, sadržaj povezan uz prikupljanje arheoloških podataka i terenski rad* te *podatkovne analize i vizualizacije*. Njihov opširniji opis i pregled dan je u nastavku ovog poglavlja.

Treća kategorija obuhvaća razinu metapodataka povezanu uz pojedinu datoteku. Ovi su metapodatci usmjereni na zaštitu i diseminaciju datoteke, te prepoznavanje potencijala podataka za ponovno korištenje. Na ovoj razini potrebno je evidentirati sljedeće elemente: ime datoteke, format, program kojim je kreirana datoteka, hardware koji je korišten za kreiranje datoteke (npr. vrsta GPS[112] uređaja), korišteni operacijsku sustav, datum stvaranja i tijek procesiranja.

Četvrta se kategorija odnosi na administrativne metapodatke. Ova kategorija pokriva elemente: kreiranje, nabavu, alternative, kontrolu verzije kao i zaštitu intelektualnog vlasništva. Navedeni elementi nisu detaljnije opisani. Ulogu ovih elemenata možemo tražiti u praćenju životnog ciklusa digitalnog objekta. Životni ciklus digitalnog objekta daje informacije o kreiranju i identifikaciji, procjeni ima li digitalni objekt daljnju vrijednost ili je označen za brisanje iz baze, o uporabi i kontroli te raspoloživosti (Wallace, 1993).

4.2.4.3.1. Pregled metapodatkovnih elemenata sadržajnih stavki

Sadržajne stavke u okviru ADS-a razvrstane su u kategorije. Svaka kategorija ima entitete. Prikaz pojedinog entiteta, područja, pripadajućih elementa i njihovih opisa u ovom radu temelje se na izvorima (ADS, 2015) i (ADS, 2017).

Entiteti kategorije osnovnog sadržaja prikazani su u Tablici 5. u kojoj su navedeni entitet i područja pokrivena elementima. Svi entiteti ove kategorije imaju jednake elemente koji se odnose na datoteku. Datoteka je opisana elementima: ime datoteke, format datoteke, veličina datoteke, programska podrška i verzija te povezanost s drugim datotekama.

[112] globalni položajni sustav, http://www.enciklopedija.hr/Natuknica.aspx?ID=22330

Tablica 5.: Prikaz entiteta za sadržajne stavke osnovnog sadržaja

Entiteti	Područja pokrivena elementima
Dokumenti i tekst	naslov, sadržaj, autorstvo, nakladnik, vremenski period, formalna identifikacija, jezik i vlasnička prava
Publikacija	ime, vrsta, međunarodna identifikacija, bibliografski podatci, institucija, konferencija i lokacija
Tablice	ime radne knjige, svrha i sadržaj, svrha i sadržaj radnog lista, opisi polja, stupaca i redaka, dokumentiranost funkcija
Baze podataka	svrha i sadržaj baze, tablice, polja, primarni i vanjski ključevi, relacije između tablica
Vektorska grafika	identifikator, ime, opis, autorstvo, ključne riječi, porijeklo / povezanost, konvencije
Rasterska grafika	identifikator, ime, opis, autorstvo, datum, autorska prava, ključne riječi, lokacija te tehničke karakteristike
Video	opis sadržaja te tehničke karakteristike
Zvuk	opis sadržaja te tehničke karakteristike

Kategorija prikupljanje arheoloških podataka i terenski rad sadrži entitete: prostorno istraživanje, istraživanje bespilotnim letjelicama, geofizička istraživanja, istraživanje podmorja i dendrokronološka istraživanja.

Entitet *prostorna istraživanja* opisan je putem elemenata koji se odnose na: opis sadržaja, opis prostora, autorstvo, zaštitu podataka te tehničke karakteristike. Prostorna istraživanja mogu uključivati i opće metapodatkovne elemente entiteta projekt.

Opis entiteta *istraživanja bespilotnim letjelicama* provodi se kroz tri razine. Prva se razina odnosi na opis projekta i istraživanje, druga razina na slike, a treća razina na elemente kojima se prati obrada slika iz izvornog, a ne procesiranog formata. Razina projekta opisana je općim elementima entiteta projekta, a elementi istraživanja pokrivaju tehničke karakteristike letjelice. Elementi na razini slike pokrivaju ime slike te geografski prostor istraživanja. Treća je razina digitalna transformacija izvornog sadržaja u novi sadržaj, za nju su bitni elementi koji se odnose na izvorne podatke, programsku podršku, prirodu obrade te opis generiranih podataka.

Entitet *geofizička istraživanja* opisan je metapodatcima projektne razine, geofizičke razine i izvještajne razine. Evidentiranje metapodatkovnih elemenata entiteta

geofizička istraživanja vremenski su zahtjevna. Projektna razina opisana je imenom, identifikatorom, svrhom, bibliografskim referencama, ključnim riječima, geografskim, vremenskim i geološkim odrednicama te autorskim i vlasničkim podatcima. Razina geofizičkih metapodataka uključuje nekoliko podrazina. Iz identificiranih razina, dvije se podrazine izdvajaju kao osnovne: istraživačke tehnike i metodologija, dok su ostale podrazine vezane uz vrstu uređaja kojima se radi istraživanje (npr. istraživanje otpora tla, istraživanje magnetometrom, istraživanje radarima, istraživanje sonarima). Podrazina istraživačke tehnike uključuje elemente povezane uz vrstu istraživanja, instrument, opis odabrane tehnike, istraženo područje, metode te tehničke pojedinosti. Elementi podrazine metodologije istraživanja uključuju elemente o podatkovnoj mreži, tehničkim specifikacijama i načinu istraživanja. S obzirom na veliki broj različitih uređaja, njihove specifikacije i funkcionalnosti, elementi za pojedini uređaj nisu analizirani. Razina izvještaja uključuje sljedeće metapodatkovne elemente: naslov izvještaja, referencu izvještaja, autora izvještaja i lokaciju.

Istraživanje podmorja je složeno istraživačko područje. Obuhvaća prikupljanje podataka iz različitih izvora, područja te različitih znanstvenih disciplina. U ovom dijelu se mogu primijeniti i metapodatkovni standardi iz drugih znanstvenih područja (npr. iz područja geografije, ISO 19115:2003 Geographic Information). Entitet *istraživanje podmorja* opisujemo metapodatcima koji su raspoređeni u projekt, istraživačke tehnike, istraživanje magnetometrom, istraživanje sonarom, metodologiju istraživanja i postupanje podatcima. Na razini projekata cilj je evidentiranje konteksta u kojem su podatci nastali. Istraživačke tehnike usmjerene su na elemente vezane uz vrstu istraživanja. Istraživanje magnetometrom i sonarom usmjereno je na opis uređaja i tehnika kojima se prikupljaju podatci. Metodologija istraživanja usmjerena je na elemente kojima se opisuje kako je istraživanje provedeno. Kroz postupanje podatcima opisuje se koji su programi korišteni te kakav je postupak procesiranja podataka.

Metapodatci na razini datoteke za ovu skupinu ovise o vrsti datoteke koja je kreirana, a elementi koji bi se trebali uzeti u obzir su: ime, veličina datoteke, program i verzija te opis sadržaja.

Entitet *lasersko skeniranje* opisujemo metapodatcima na projektnoj razini, razini skeniranja, registriranjem skupa podataka i dodatnim metapodatcima za mreže. Na projektnoj razini u obzir su uzeti elementi kojima se opisuje: ime projekta, ime i broj

arheološkog entiteta, opis, istraživačka lokacija, vremenske odrednice, uvjeti istraživanja, uređaj za skeniranje i njegove tehničke pojedinosti. Na razini skeniranja potrebno je uključiti elemente kojima se opisuje način provedbe skeniranja, entitet koji se skenira, vremenske odrednice skeniranja te tehničke pojedinosti. Putem laserskog skeniranja moguće je napraviti 3D model, a u tu svrhu potrebno je registrirati mrežu točaka. Razina registriranja skupa podataka odnosi se na mrežu točaka. Mreža točaka se opisuje elementima vezanim uz: ime skupa podataka, korištene metode te tehničke pojedinosti o mreži. Dodatni podatci uključuju elemente kojima se opisuje poligonalna mreža.

Za opisivanje entiteta *dendrokronološka istraživanja* koristi se standardizirana metapodatkovna shema TRiDaS[113]. Putem ovog standarda metapodatci se evidentiraju na razini projekta, objekta, elementa, uzorka, radijusa i serije.

Sadržajne stavke povezane uz podatkovne analize i vizualizaciju sadrže podatke o entitetima GIS, CAD[114] i 3D model.

Metapodatci na razini entiteta GIS evidentiraju se na razini projekta i na razini datoteke. Na razini datoteke moguće je evidentirati različite vrste podataka. S obzirom na ovu različitost moguće je pri evidentiranju uzeti u obzir različite skupine metapodataka i elemenata[115].

Evidentiranje metapodataka za potrebe entiteta CAD provodi se na razini: projekta, dokumentiranja konvencija, dokumentiranja podataka istraživanja, dokumentiranja izvora podatka i dokumentiranja CAD modela. Elementi na razini projekta odnose se na ime, opis, ključne riječi, geografske odrednice, autorstvo, osobu koja je pohranila entitet, pravnu zaštitu i bibliografiju. Na razini opisivanja konvencija, pokrivaju se konvencije vezane uz imenovanje projektnih slojeva i imenovanje datoteka. Dokumentiranje podataka istraživanja uključuje elemente povezane uz ime, vrstu istraživanja, svrhu, vremenske odrednice, ključne riječi, instrumente te tehničke pojedinosti. Dokumentiranje izvora podataka uključuje elemente vezane uz projekt te tehničke pojedinosti. Za svaki model u okviru CAD potrebno je evidentirati elemente povezane uz ime modela, referencu, autora i korištene programe. Entitet CAD moguće je

[113] The Tree Ring Data Standard, TRiDaS, http://www.tridas.org/
[114] Computer Aided Design, http://www.enciklopedija.hr/Natuknica.aspx?ID=68079
[115] Puni popis elemente koje je moguće evidentirati za razinu datoteke kod GIS moguće je vidjeti na adresi: http://guides.archaeologydataservice.ac.uk/g2gp/Gis_3-3.

povezati uz vanjske baze podataka, a one se opisuju elementima vezanim uz vrstu baze, tablice, relacije, imena polja, ključeve i povezana polja između CAD i baze.

Metapodatci kod entiteta *3D modela* evidentiraju se na razini projekta, kao i na razini pojedine datoteke. Pojedina datoteka opisana je elementima vezanim uz model, njegov broj točaka, korištenu osnovicu za model te tehničke detalje.

4.2.4.4. MAPPA Open Data Metadata (MOD)

MAPPA Open Data (MOD) je digitalni repozitorij koji obuhvaća arheološke podatke iz Italije i omogućava njihovu dostupnost širem krugu korisnika. Prvotni je cilj ovog repozitorija bio prikupljanje dokumentacije vezane uz istraživanja. Prepoznavanjem važnosti otvorenih istraživačkih podataka te nužnosti dijeljenja podataka ovaj repozitorij preuzima i ulogu repozitorija za otvorene podatke. Tijekom 2013. godine *Journal of Open Archaeology Data* prepoznao ga je kao repozitorij za pohranu podataka. Repozitorij je usmjeren na pojedinačno arheološko istraživanje, a od podatkovnih izvora uključuje tekstualne dokumente, slike, multimedijalne objekte, datoteke baze podataka, geografske podatke itd. Pretraživanje repozitorija moguće je napraviti putem kronologije, teme, godine, autora, naslova, vrste datoteka u repozitoriju ili prema geografskom području.

Posebna je pažnja posvećena kreiranju metapodataka, s obzirom na definiranje minimalnog skupa elemenata koji su garantirali korektnu uporabu podataka (Anichini i Gattiglica, 2015).

Metapodatkovna shema utemeljena je na Dublin Core i ISO 19115[116] shemi te koristi vlastite rječnike kao i rječnike nacionalnog instituta za dokumentaciju. Metapodatkovna shema sastoji se od četiri entiteta: povijest istraživanja, izvori za kreiranje podataka, metode i struktura podataka te izvještaji (Anichini i Gattiglica, 2015).

Entitet *povijest istraživanja* uključuje metapodatkovne elemente kojima se opisuje: ime istraživanja, svrha i metode, vrsta dokumentacije koja nastaje (npr. crtež, fotografija, tekst, video, multimedija), geografske odrednice, pripadnost kronološkom periodu i razdoblju, istraživač, godina te povezanost s ostalim resursima važnim za

[116] ISO 19115 je shema usmjerena na opisivanje geografskih informacija i usluga. Ona omogućava informacije vezane uz identifikaciju, kvalitetu, prostor, vrijeme, reference kao i distribuciju geografskih podataka.

istraživanje. Entitet *izvori za kreiranje podataka* uključuje elemente vezane uz arhivu, korištenu kartografiju i prethodna istraživanja u području. Opis entiteta *metode i strukture podataka* dan je putem elemenata povezanih uz vremenske odrednice, tematsku kategoriju, listu priloženih datoteka i njihov sadržaj, pridružene identifikatore, konverzije u druge formate i vlasnička prava. Entitet *izvještaj* opisan je elementima vezanim uz bibliografiju, lokaciju arheološke dokumentacije i poveznice.

4.2.4.5. Connecting Archaeology and Architecture in Europeana (CARARE)

Connecting ARchaeology and ARchitecture in Europeana (CARARE) je mreža najbolje prakse uspostavljena u svrhu omogućavanja digitalnog sadržaja kroz Europeanu kao i agregiranje usluga od strane europske mreže institucija iz područja kulturnog nasljeđa, arheoloških muzeja, istraživačkih institucija i specijaliziranih digitalnih arhiva.

Na razini EU prepoznato je kako nema dovoljno digitalnog sadržaja iz područja arheologije i kulturnog nasljeđa te je jedan od ciljeva povećanje same količine kao i kvalitete digitalnog sadržaja kako bi se utjecalo na uspostavu usluga za kulturni turizam, ali i istraživanja (Hansen i Fernie, 2010). Osim orijentiranosti na sliku i tekst CARARE punu pažnju posvećuje trodimenzionalnim objektima, kao i objektima pokrivenima virtualizacijom.

CARARE metapodatkovna shema je napravljena tako da podržava isporuku metapodataka CARARE agregatorima i Europeani (Papatheodorou *et al.*, 2011). CARARE shema je usmjerena na detaljan opis spomenika, digitalnih objekata i povezanih događaja. Konceptualno su osnovne domene:

- omotač - obuhvaća jedan ili više CARARE zapisa
- objekt baštine - opisne informacije i metapodatci o arheološkim građevinama, povijesnim zgradama, arheološkom krajoliku, podvodnim objektima, izrađevinama i ekofaktima
- digitalni resurs - digitalna reprezentacija i izvor informacija (npr. slika, tekst, video, audio, 3D model) kulturnog nasljeđa. Sadrži metapodatke o reprezentaciji, vrsti, formatu i lokaciji digitalnog resursa

- aktivnost - sadrži metapodatke o povijesnim događajima koji su bili vezani uz objekt baštine kao i arheološke aktivnosti (npr. kreiranje, istraživanje, itd.)
- informacije o kolekciji - opisuju kolekciju koja ima sadržaj.

Metapodatci i pripadajući elementi CARARE sheme identificirani su i analizirani temeljem sadržaja objavljenog u okviru publikacije (Fernie, Gavrilis i Angelis, 2013). CARARE informacije o objektima baštine temelje se na MIDAS Heritage standardu i CIDOC[117] Core Data Indeksu za arheologiju. Putem ove sheme želi se obuhvatiti arheološke spomenike, povijesne građevine, arheološka nalazišta i prostor, brodolome, izrađevine i ekofakte, kao i knjige, fotografije, 3D modele (obuhvaća i sadržajne stavke koje ova shema opširnije opisuje kroz digitalne resurse).

Ova shema omogućava identifikaciju sljedećih entiteta: objekt baštine, digitalni resurs, aktivnost ili događaj i kolekcija.

Entitet *objekti baštine* opisan je metapodatkovnim elementima vezanim uz jednoznačnu identifikaciju, ime, opis, opću klasifikaciju u svrhu razlikovanja npr. spomenika od izrađevina, osobe koje su povezane s objektom, podatke o zaštiti, stanju objekta, podrijetlu, značajkama (vrsta objekta baštine, vremenske odrednice, materijal, natpisi, dimenzije, informacije o plovilu, prostorni podatci, lokacija repozitorija, prava), reference (ime reference, vrsta reference, poveznica). Ovaj entitet također je moguće opisati s relacijama u odnosu na druge objekte.

Entitet digitalni resurs uključuje različite vrste sadržaja npr. sliku, tekst, video, audio i 3D objekte. Sadržaj može biti na bilo kojoj lokaciji u digitalnom okruženju. Opis ovog entiteta moguće je napraviti na temelju sljedećih metapodatkovnih elemenata: jednoznačne identifikacije, imena, vrste i opisa resursa, navođenja autora, poveznica za prikaz u servisima, pravnih elemenata i povezanosti s ostalim digitalnim resursima.

Uloga entiteta *aktivnost ili događaj* je praćenje objekta kroz vrijeme, a vezano uz aktivnosti poduzete kroz istraživanje, analizu, procesiranje, promjene u uporabi, ali i opisivanje povijesnih događaja. Za opisivanje ovog entiteta koriste se sljedeći metapodatovni elementi: jednoznačna identifikacija, ime, opis, opis događaja / aktivnosti,

[117] International Committee for Documentation, http://network.icom.museum/cidoc/

sudionici, vremenske i geografske odrednice, metode te povezanost. Shema omogućava da se jedan događaj ili aktivnosti sastoji od više aktivnosti / događaja.

Uloga entiteta *kolekcija* je kreiranje skupa digitalnih objekta. Entitet je opisan putem sljedećih metapodatkovnih elemenata: jednoznačna identifikacija, ime kolekcije, organizacija koja je izvor kolekcije, kontakt za kolekciju, vlasnička prava, jezik kolekcije, način preuzimanja sadržaja, prostorna i vremenska pokrivenost kolekcije te povezanost.

Ova metapodatkovna shema pokazuje da može evidentirati promjene koje se događaju kod digitalnih objekata.

4.2.5. Dodatni metapodatci iz istraživanja i standarda

Pojedine relevantne institucije za arheološke arhive razmatraju ulogu metapodataka i njihovog definiranja. Izvještaj o metapodatcima Muzeja Londona – Arheološki arhiv (Fetherston, 2013) sadrži prikaz metapodataka entiteta projekt. Metapodatci entiteta *projekt* dijele se na osnovne i opcionalne metapodatke. Osnovnim metapodatcima opisuje se projekt putem identifikatora, organizacije, imena, vrste, referenci te geografskih i vremenskih odrednica. Opcionalnim metapodatcima opisuju se suradnici, njihova uloga u projektu, pripadnost organizaciji, povezani projekti te način pristupa.

Za područje arheologije pojedina istraživanja pokazuju da je moguće primijeniti The Core Data Index for Historic Buildings and Monuments of the Architectural Heritage, The Core Data Standard for Archeological Sites and Monuments (CDSASM) i The Object ID (Haddad i Akasheh, 2005). Istraživanja ukazuju na to da je u uporabi i International Core Data Standard for Archaeological Objects (ICDSAO).

Važnost CDSASM-a i ICDSAO-a u okviru ovog rada možemo tražiti u definiranju metapodatkovnih elemenata za opis sadržaja entiteta *osnovna struktura* kao i opis sadržaja entiteta *kontekst*. Standard CDSASM definira minimalne kategorije koje je potrebno evidentirati za istraživačku lokaciju kao i arheološke entitete. Standard ICDSAO se temelji na standardu CDSASM te daje prošireni skup kategorija podataka koje treba evidentirati za pojedini objekt.

Elementi standarda CDSASM identificirani su temeljem (ICOM, 2017), kao i provedene analize primjera objavljenog na web stranici[118] Međunarodnog vijeća muzeja (ICOM)[119]. Područja i pripadni elementi koji su se uporabljali za opis pojedinog objekta odnose se na ime i povezane reference (nalazište, izrađevina, događaj), geografske i vremenske odrednice, vrstu i kategoriju objekta, fizičko stanje objekta, oznake zaštite te kratki sažetak.

Identifikacija elemenata ICDSAO napravljena je na temelju sadržaja objavljenog na web stranici *ICOM International Observatory on Illicit Traffic in Cultural Goods*[120]. Opis pojedinog objekta putem standarda ICDSAO moguće je napraviti elementima koji

[118] http://archives.icom.museum/object-id/heritage/sample2.html
[119] International Council of Museum, https://icom.museum/en/
[120] https://www.obs-traffic.museum/sites/default/files/ressources/files/CIDOC_Coredata_1992.pdf

se odnose na identifikaciju objekta, instituciju odgovornu za čuvanje objekta, instituciju odgovornu za zaštitu. Sastavni dio opisa su i elementi koji se odnose na imenovanje i opise, materijale i tehnike, dimenzije i oblike, arheološki kontekst, izvore i kulturnu pripadnost, tipologiju te vremensku pripadnost. Kod opisa potrebno je navesti i elemente povezane uz način nabave te postupke zaštite.

Zadnjih se godina radilo na standardima za područje cijele arheologije kao i za pojedine vrste arheoloških entiteta. Na razini Europe u okvirima projekta *Archaeological Resource in Cultural Heritage: a European Standard*[121] pripremane su smjernice za opći standard u području arheologije vezan uz arhiviranje i digitaliziranje. U Velikoj Britaniji tijekom 2016. godine usvojen je standard za evidentiranje, arhiviranje i digitalizaciju keramike – *A Standard for Pottery Studies in Archaeology* (Barclay *et al.*, 2016). Razloge korištenja međunarodnih standarda možemo tražiti u pripremi arheoloških podataka koji se mogu razmjenjivati (interoperabilnost) te primijeniti i interpretirati i od strane drugih istraživača.

Za interpretaciju i primjenu[122] postojećih podataka u istraživačkom životnom ciklusu važnu ulogu ima i citiranje.

Svrhu citiranja podataka u okviru znanstvenih istraživanja možemo tražiti u priznavanju ideje, autora i izvora podataka, kao i omogućavanje drugim istraživačima pronalazak podataka. U opsežnom pregledu razvoja sustava podatkovnog citiranja Altman i Crosas utvrđuju četiri faze razvoja citiranja podataka (Altman i Crosas, 2013). Prva faza je usmjerena na opis i dohvat podatka, druga faza se odnosi na pristup podatcima i postojanje trajnih identifikatora te direktni pristup putem web stranica, treća faza se odnosi na verificiranje i reproduciranje podataka, a četvrta faza odnosi se na integriranje u okviru znanstvenih radova i sustave publiciranja.

Tijekom 2014. godine usvojena je Deklaracija o načelima citiranja podataka. Deklaracija pokriva načela povezana uz legitimnost citiranja podataka u okvirima istraživanja; priznavanje autorstva svim sudionicima tijekom procesa kreiranja podataka; tijekom istraživanja i rada s podatcima potrebno je citirati odgovarajuće podatke; citiranje podataka temelji se na strojno čitljivoj, jedinstvenoj i trajnoj metodi; citiranje uključuje

[121] Više o projektu ARCHES moguće je doznati na web stranicama projekta http://archaeologydataservice.ac.uk/arches/Wiki.jsp?page=Main

[122] Pojedina istraživanja pokazuju da se realizacija aplikacijskog profila provodi kroz cjeline digitalni objekt i citiranje (Greenberg *et al.*, 2009).

korištenje metapodataka i dokumentacije; trajni identifikator i metapodatci moraju postojati i nakon životnog vijeka podataka koje opisuju; citati omogućuju identifikaciju, pristup i provjeru podataka koji se odnose na ideje i tvrdnje u istraživanju, varijante citiranja mogu biti prilagođene pojedinim istraživačkim zajednicama, uz zadržavanje interoperabilnosti (Data Citation Synthesis Group, 2014).

Generički citiranje podataka obuhvaća sljedeće metapodatkovne elemente: *autor(i), godina, ime skupa podataka, trajni identifikator, podatkovni repozitorij ili arhiva, verzija i podskup* (Altman i Crosas, 2013). Istraživači u citiranju podataka primjenjuju različite pristupe i metapodatkovne elemente (npr. koriste se različiti elementi za citiranje digitalnog objekta i različiti elementi za citiranje upita), a usmjereni su na korištenje minimalnog skupa metapodatkovnih elemenata (Silvello, 2018). U području arheologije Marwick i Birch za citiranje podataka sugeriraju korištenje sljedećih metapodatkovnih elementa: *kreator, naziv, godina objave, izdavač, trajni identifikator, verzija* (Marwick i Birch, 2018). Navedeni metapodatkovni elementi daju vjerodostojnost, omogućavaju procjenu relevantnosti i kvalitete skupa podataka kao i njihovu dostupnost.

4.3. Pretraživanje

Razvoj digitalnih tehnologija i usmjerenje prema otvorenoj znanosti omogućava velikom broju korisnika (npr. istraživača, studenata, zainteresiranih dionika) dostupnost podataka kao i samostalnu potragu za njima.

Korisnik započinje s traženjem podataka kada shvati da je postojeća razina znanja manja od razine koja je potrebna za rješavanje problema, a faze koje su pritom moguće obuhvaćaju prepoznavanje potreba, potragu za podatcima, pronalazak podataka te korištenje podataka (Kadli i Kumbar, 2013). U kontekstu znanstveno-istraživačkog rada, svrhu pretraživanja podataka možemo tražiti u pronalaženju činjenica za razrješenje pojedinih istraživačkih pitanja, prikupljanju podataka u svrhu pisanja rada ili donošenja odluka te ostajanju „up-to date“ (Amin *et al.*, 2008).

Općenito se pretraživanje podataka može opisati kao svrhovito postupanje korisnika u pronalaženju relevantnih ili korisnih podataka kroz interakciju s digitalnim sustavom. Pojam pretraživanja podataka[123] prvi je definirao Calvin N. Mooers, koji pod ovim pojmom podrazumijeva proces pronalaženja ili istraživanja pohranjenih podataka bitnih za korisnika. Nadalje pretraživanje podataka obuhvaća intelektualne aspekte opisa podataka i postavki za pretraživanje, kao i sve one sustave, tehnike ili strojeve koji se rabe kako bi se izvršila radnja pretraživanja (Mooers, 1951). Ovako opisano pretraživanja podataka usmjerava nas na postojanje tri elementa kod pretraživanja podataka. Prvi element je korisnik koji traži podatak, drugi element je proces pronalaženja ili istraživanja podataka, a treći element je sustav u kojemu su pohranjeni podatci (npr. aspekti opisa i pretraživanja su metapodatci, a sustav je digitalni repozitorij s funkcionalnošću pretraživanja).

Pojedina istraživanja naglašavaju važnost interakcije korisnika s digitalnim sustavom kao važnom strategijom za pronalaženje digitalnih objekata (Peiling, 2011). Prema njemu interakcija se odvija kroz sljedeće korake: prepoznavanje potrebe za podatcima, traženje podatka kroz interakciju s digitalnim sustavom za pretraživanje podataka, procjenu rezultata pretraživanja u odnosu na bitne i sporedne digitalne objekte i uporabu podataka.

[123] Izvorno se odnosi na informacije.

Sveobuhvatniji pogled i analizu pretraživanja podataka daje Xie, koja identificira četiri važne razine kod pretraživanja podataka: taktiku, strategiju, obrasce uporabe i modele (Xie, 2009). Taktiku opisuje kao poteze[124] koje korisnici primjenjuju u procesu pretraživanja. Strategije pretraživanja sastoje se od taktika ili poteza, a temeljem analize dosadašnjih istraživanja svrstava ih u tri grupe. Prva se grupa odnosi na digitalne sustave kod kojih strategije mogu biti konceptualno usmjerene (npr. način primjene pojmova kod pretraživanja), usmjerene na sustav (npr. značajke sustava), planirane i reaktivne. Druga grupa povezana je uz interakciju sa sustavom kao i digitalnim objektima sadržanima u sustavu. Za ovu grupu identificira pretraživanje i pregledavanje kao glavne strategije korisnika. Treća je grupa povezana uz strategiju pretraživanja u okruženju web pretraživača, kod kojih je pretraživanje npr. dinamično, simultano, upit se ponavlja nekoliko puta, prate se linkovi (npr. prema naprijed, natrag). Nove digitalne tehnologije kao i pojava web pretraživača, dali su temelj za uporabu internih podataka sustava u svrhu prilagodbe pretraživanja kao i za analiziranje obrasca uporabe pretraživanja od strane korisnika. Obrasci uporabe karakterizirani su kroz oblikovanje i preoblikovanje upita. Prikazom modela Xie ukazuje na dinamičnost procesa kao i na glavne elemente koji utječu na proces pretraživanja, a dijeli ih u dvije grupe. Prva se grupa odnosi na modele povezane uz proces podatkovnog pretraživanja (npr. Ellisov model ponašanja kod traženja informacija, Batesov *„berrypicking“* model, i Kuhlthauov model procesa pretraživanja informacija), a druga grupa uključuje modele sa činiteljima koji utječu na proces (npr. Fidelov i Soergelov konceptualni metodološki pristup za online bibliografsko pronalaženje, Vakkarijevu teoriju procesa informacijskog pretraživanja temeljenu na zadatku, Ingwersenov i Järvelinov kognitivni model, Saračevićev stratificirani interakcijski model te Wang, Hawk i Tenopirev višedimenzionalni model interakcije korisnika i weba).

Pretraživanje otvorenih istraživačkih podataka prije svega vrše korisnici u digitalnom okruženju, kroz interakciju s digitalnim repozitorijima i u otvorenom web prostoru. S obzirom na ove karakteristike i u kontekstu ovog rada, model s kojim najbolje možemo identificirati elemente bitne za ovakvo pretraživanje je Višedimenzionalni model interakcije korisnika i weba Wanga, Hawka i Tenopira.

[124] Potezi direktno ilustriraju kako su korisnici u interakciji s digitalnim sustavom za pretraživanje podataka. Oni su klasificirani na temelju promjene značenja upita, a u ovisnosti su od koncepata (npr. analiza uvjeta) i fizičke strane (npr. značajke sustava).

Višedimenzionalni model interakcije korisnika i weba (Wang, Hawk i Tenopir, 2000) uzima u obzir da se između korisnika i weba interakcija odvija kroz komunikaciju i seriju transakcija, a procesiranje, rješavanje problema te donošenja odluka ostvaruje se na temelju interpretacija podataka prezentiranih putem sučelja. Model se sastoji od tri osnovne komponente: *korisnika*, *sučelja* i *web prostora*. Korisnik je pod utjecajem dinamičkih situacijskih činitelja, kognitivnog ponašanja, afektivnog stanja i fizičkih vještina. Sučelje omogućava korisničku interakciju s web-om. Elementi sučelja su: metoda pristupa (npr. web stranica, URL[125]), rezultati pristupa (npr. popis URL s opisom), navigacija (npr. povratak na staru stranicu ili prijelaz na drugu, povijest pretraživanja, izbornik), poruke (npr. poruka o pogrešci, nepostojećoj stranici) i ulazno-izlazne jedinice. Web prostor je označen kao ključni element za pretraživanje podataka, a sastoji se od sljedećih elemenata: objekata izraženih kroz sliku, tekst, video; aktivnih objekata s kojima je korisnik u interakciji; web prostora; organizacijske sheme i metapodataka.

Osim prethodno navedenih važnih elemenata za pretraživanje, za procjenu izvedbe sustava koja korisnicima omogućava pronalaženje podataka od temeljne je važnosti i koncept relevantnosti. Sveobuhvatnu analizu relevantnosti daje Saracevic (Saracevic, 2007b), a možemo izdvojiti sljedeće opise relevantnosti: ona nije zadana već se uspostavlja; relevantnost je prosudba; stvorena je na temelju prosudbe ali i je rezultat prosudbe; postoji kontinuitet od nastajanja do dobivanja relevantnosti; sustavi ili strojevi stvaraju relevantnost, a korisnici dobivaju relevantnost; korisnici izvlače relevantnost iz digitalnih objekata (uspoređuju i pojašnjavaju objekte s problemom koji rješavaju, svojim spoznajama i drugim čimbenicima); proces odabiranja uključuje više vrsta interakcija, stoga shvaćanje relevantnosti uvažava postajanje odabira i interakcije.

Iz dosadašnjih istraživanja o relevantnosti možemo izdvojiti sljedeće važne kriterije na temelju kojih korisnici donose zaključke o relevantnosti (Saracevic, 2007b): sadržaj, karakteristike digitalnih objekta, valjanost, uporabna vrijednost, razumijevanje novina, emocionalna reakcija na podatak, osobno vjerovanje podatcima i prihvaćanje njihove istinitosti.

Prethodni opisi nas usmjeravaju da se kod relevantnosti radi o uspostavi relacije, te da različite manifestacije uključuju različite relacije. Manifestacija relevantnosti u

[125] Uniform Resource Locator

području informacijskih znanosti uključuje sljedeće vrste relevantnosti (Saracevic, 2007a):

- sustavna ili algoritamska – relacija između upita i digitalnog objekta,
- tematska ili predmetna – relacija između teme / subjekta izrađenog kroz upit i teme / subjekta dobivenog kroz digitalni objekt
- kognitivna relevantnost – relacija između kognitivnog stanja znanja korisnika te digitalnog objekta
- situacijska relevantnost – relacija između situacije (zadatka, problema) i digitalnog objekta i
- emocionalna relevantnost – relacija između ciljeva, emocija i motivacije korisnika te digitalnih objekata.

Daljnji pregled i analiza pretraživanja u kontekstu otvorenih istraživačkih podataka u području arheologije bit će prikazana temeljem elemenata Višedimenzionalnog modela interakcije korisnika i weba.

4.3.1. Korisnik

Kroz projekt ARIADNE provedena su dva opsežna istraživanja (Selhofer i Geser, 2014), (Selhofer i Geser, 2015) o korisničkim potrebama arheologa. Istraživanja pokazuju da su klasične publikacije kao i digitalni izvori (npr. repozitoriji) podjednako važni kao izvori podataka za istraživački rad i prikupljanje podataka. U okviru istraživanja ispitanici su prepoznali podatke iz iskapanja kao najvažniju vrstu podataka, a uz njih ističu važnost GIS podataka te podataka materijalne i biološke analize. Ispitanici ukazuju na problem nedovoljne dostupnosti podataka iz digitalnog okruženja.

Istraživanje o korištenju otvorenih istraživačkih podataka za različita znanstvena područja, za područje arheologije utvrđuje da su korisnicima važni i potrebni podatci o arheološkim entitetima, fotografije, zabilješke, geografski podatci, vremenski podatci, stratigrafski podatci i kronološki podatci, a ovi se podatci koriste u svrhu opisa arheoloških entiteta, povezivanja i provjere podataka s drugim istraživanjima te za istraživački rad (Gregory, Groth i Cousijn, 2017). U kontekstu kulturne baštine, pretraživanja digitalnih objekata za muzeje obavljaju osobe s višom razinom znanja o

kolekcijama te je važan element njihovog pretraživanja vizualno pretraživanje (npr. slika) (Skov i Ingwersen, 2008).

Pojedina istraživanja pokazuju da su u pretraživanju arheoloških digitalnih podataka za korisnike arheologe i studente arheologije važni: digitalna pismenost, društvene mreže (npr. Facebook, Twitter, YouTube, Academia.edu.), vjerodostojnost organizacije (povjerenje, stručnost) kao i socio-demografske karakteristike (Richardson, 2014).

4.3.2. Sučelje

Interakcija između korisnika i digitalnog repozitorija odvija se kroz sučelje. Kroz proteklo razdoblje postojali su različiti oblici sučelja npr. u početku weba sučelje je bilo usmjereno na prikaz sadržaja i navigaciju do dodatnog sadržaja, poslije se javljaju sučelja koja su omogućila interakciju slanjem informacija kroz forme, a sredinom 2000 god. javljaju se tehnologije koje omogućavaju sučelja usmjerena na „korisničko iskustvo[126]“.

Sučelja digitalnih repozitorija u području otvorenih podataka općenito imaju jasan izgled s navigacijskom trakom, polja za pretraživanje i tematske kategorije vizualizirane pomoću ikona. Funkcije pretraživanja omogućavaju jednostavno pretraživanje tekstom kao i kombinirane operacije pretraživanja logičkim operatorima uz korištenje zamjenskih znakova ili dodatnih filtera koji proizlaze iz različitih metapodatkovnih kategorija (npr. vrsta, ključne riječi, autor,..).

Noviji pristupi u dizajnu korisničkog sučelja usmjereni su prema korisničkom iskustvu, no ne postoji njegova jednoznačna definicija. Pojedina istraživanja razmatraju korisničko iskustvo s tehničke strane[127] i korisničke strane[128]. Na temelju sveobuhvatne analize znanstvenih istraživanja o korisničkom iskustvu utvrđeno je da ono ovisi o internom stanju korisnika, karakteristikama dizajniranog sustava i kontekstu ili okruženju unutar kojeg dolazi do interakcije (Hassenzahl i Tractinsky, 2006).

U području arheologije primjer sučelja temeljenog na korisničkom iskustvu i povezanog uz pretraživanje, identificiran je u okviru digitalnog repozitorija projekta

[126] User Experience.
[127] Usmjerenje je na razinu do koje sustav ili usluga ispunjava korisničke ciljeve na efikasan i efektivan način uz osiguranje zadovoljstva.
[128] Usmjerenje je na korisničkoj percepciji i njegovoj reakciji koja proizlazi iz uporabe sustava ili usluge.

ARIADNE. Sučelje omogućava vizualno pretraživanje i to na tri načina. Prvi način pretraživanja možemo opisati terminom „gdje je“ digitalni objekt i vezan je uz vizualni prikaz digitalnog objekta na javno dostupnim online digitalnim kartama. Drugi je način pretraživanja vezan uz prikaz vremena, koji je povezan uz digitalni objekt te ga opisujemo terminom „kada“, a treće pretraživanje je vezano uz prikaz i uvid u različiti sadržaj unutar repozitorija i opisujemo ga terminom „što“ (Glanznig, 2012).

Dizajn korisničkog sučelja pokriven je kroz različite aspekte interakcije čovjeka i računala te iskoristivosti pa nije predmet daljnjeg istraživanja u okviru ovoga rada.

4.3.3. Web prostor

Web prostor označen je kao jedan od najvažnijih dijelova za pretraživanje. Usporedimo li web prostor s dosadašnjim sadržajem u okviru ovog rada, onda nam web prostor predstavljaju: digitalni repozitoriji, digitalni objekti sa sadržajnim stavkama, organizacijska shema sustava te metapodatci.

Metapodatci, kao što je i već prethodno spomenuto, omogućavaju korisnicima efektivno pretraživanje digitalnih objekata putem pretraživanja i pregledavanja. Pretraživanje se sastoji od definiranja specifičnog kriterija temeljem kojega će željeni digitalni objekt biti pronađen u digitalnom repozitoriju, a zatim pregledavanjem izdvojen iz danog skupa podataka. Općenito se za tekstualno pretraživanje selekcijski kriteriji sastoje od ključnih riječi ili fraza, koje se uspoređuju s indeksiranim elementima iz digitalnog repozitorija. Kod znanstvenog pretraživanja selekcijski kriteriji mogu biti uvjetovani domenom.

Pregledom postojećih digitalnih repozitorija tDAR i ARIADNE te pripadajućih radova i sadržaja, u svrhu pretraživanja identificirani su sljedeći metapodatkovni selekcijski elementi:

- tDAR: *naslov, ključne riječi, vrsta resursa, kolekcija, institucija, osoba, vremensko razdoblje, geografska regija, vrsta materijala, kulturni termini i vrste istraživanja* (tDAR, 2013)
- ARIADNE: *vrsta resursa, izvorni subjekt, izvedeni subjekt, ključne riječi, agent (osoba) koji je odgovoran za opis digitalnog objekta, izdavač koji je*

odgovoran za omogućavanje pristupa resursu, mjesto, vremenski period, prava pristupa i jezik digitalnog resursa (Aloia *et al.*, 2017)

- MOD: *kronologija, tema, godina, autor, naslov, vrsta datoteke, geografsko područje* (Anichini i Gattiglica, 2015).

Dodavanjem metapodataka povezanih uz značenje povećavamo mogućnost ponovnog korištenja podataka. Za pretraživanje istraživačkih podataka ključno je postajanje kontekstualnih metapodataka (Futrelle, 2000).

Pojedina istraživanja iz primjene digitalne tehnologije u području arheologije ukazuju na postojanje različite prakse evidentiranja arheoloških podataka te različitih načina zapisivanja (različiti pristupi u definiranju termina i polja). Ova različitost ne omogućava jednostavne upite, pretragu te analizu, a interpretacija ovakvih podataka je vrlo otežana (May, Binding i Tudhope, 2015). Dodatna ograničenja u pristupu i pretraživanju podataka možemo tražiti u visokim troškovima, lošoj kvaliteti metapodataka kao i jezičnim barijerama (Selhofer i Geser, 2014).

Kvalitetu metapodataka možemo opisati kao stupanj do kojega metapodatci kroz upit izvršavaju osnovne funkcije pretraživanja, uporabe, utvrđivanja podrijetla, opticaja, izvornosti, a kriteriji koji se najčešće koriste odnose se na potpunost, točnost i dosljednost (Park, 2009). Potpunost je mjera punog pristupa lokalnim digitalnim objektima, a u ovisnosti je od vrste digitalnog objekta, relaciji s kolekcijama kao i metapodatkovnim smjernicama. Točnost se odnosi na opis i prikaz podataka za digitalni resurs, a pokrivena je kroz ispravnost sadržaja podatkovnog elementa, intelektualnog vlasništva i verziranja. Dosljednost se odnosi na konceptualnu i strukturnu cjelovitost.

Kako je područje otvorenih podataka i otvorenih istraživačkih podataka novo, postoji mali broj istraživanja povezanih uz kvalitetu metapodataka. U okviru provedenog istraživanja (Kubler *et al.*, 2018), identificirane su sljedeće preporuke za metapodatke i digitalne repozitorije: izgradnju shema i modela potrebno je provesti na temelju standarda i rječnika koji omogućavaju interoperabilnost između podatkovnih kataloga objavljenih na webu-u, automatizirano preuzimanje metapodataka (npr. veličina datoteke, format), ograničavanje metapodatkovnih vrijednosti temeljem unaprijed definiranih vrijednosti, ispitivanjem i provjerom vrijednosti (npr. URL, e-mail,..).

4.4. Prepoznatljivost i jednoznačnost u digitalnom okruženju

U kontekstu istraživačkih podataka i njihove otvorenosti (dijeljenje, ponovna uporaba) podatkovni identifikator je opisan kao slijedni niz simbola stvorenih u svrhu identifikacije, citiranja, komentiranja i/ili povezivanja istraživačkih podataka kao i njihovih pridruženih metapodataka (Lee i Stvilia, 2014). Trajni identifikator (TI) povezujemo uz digitalni objekt, a možemo ga opisati kao globalno jedinstveni numerički ili znakovni niz koji je pridružen digitalnom objektu, i ne može se pridružiti niti jednom drugom digitalnom objektu. On je kombinacija identifikatora institucije, vrste resursa i informacije kako doći do resursa. U svojoj realizaciji TI sadrži metapodatke[129] i usmjerava na cilj u obliku URL[130] koji ukazuje na set podataka smještenih u digitalnom okruženju (mreži, repozitoriju).

Smisao sustava za TI je odvajanje imena digitalnog objekta od njegove lokacije, te postojanje rezolvera koji prevodi ime u lokaciju. Pojednostavljeni opis naveden je u nastavku, a prikaz sustava dan je na Slici 1.

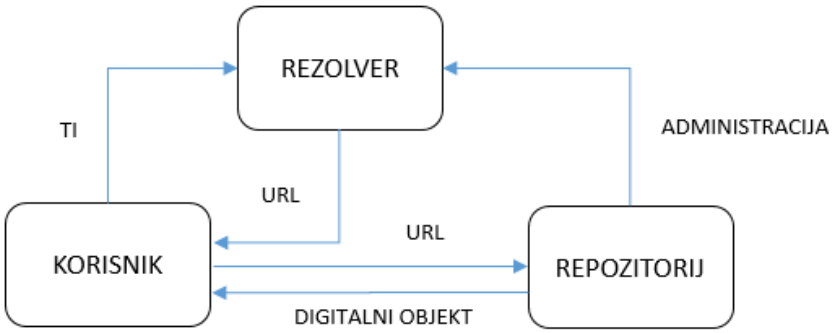

Slika 1.: Primjer sustava trajnog identifikatora

[129] U pojedinim standardima metapodatci se nalaze u okviru skupine ključne vrijednosti.

[130] Postoje različiti identifikatori u okviru digitalnog okruženje. URI (Uniform Resource Identifier) je generičko ime za identifikaciju resursa (apstraktnog ili fizičkog) raspoloživog u digitalnom okruženju ili u okviru podatkovne mreže. Može biti klasificiran kao „lokator“ (URL - Uniform Resource Locator) i „ime“ (URN - Uniform Resource Name) ili oboje. URL se koristi od strane protokola (npr. HTTP) za adresiranje dokumenata, a kada se koristi kao identifikator, URL je tada ime i lokacija resursa. Ne garantira jedinstvenost i trajnost resursa, a često se koristi kao sinonim za adresu html stranice. URN je stvoren u svrhu imenovanja resursa umjesto njegovog adresiranja, a njegova je svrha omogućavanje globalne jedinstvenosti i trajne identifikacije.

Korisnik zadaje identifikator digitalnog objekta, koji se prosljeđuje rezolveru, rezolver odgovara korisniku s lokacijom i imenom digitalnog objekta (daje URL). Po pronalasku repozitorija i digitalnog objekta, repozitorij prosljeđuje podatke (sadržaj i metapodatke) o digitalnom objektu. U svrhu trajne dostupnosti i pronalaženja digitalnog objekta, rezolveru se pridružuju ime i lokacija digitalnog objekata.

Kod digitalnog objekta TI se može primijeniti npr. za potvrđivanje autentičnosti, izvornosti i autorskih prava. Ulogu TI u okviru kulturne baštine i području arheologije možemo tražiti u jedinstvenoj identifikaciji digitalnog objekta, pouzdanog lokatora u digitalnom okruženju, osiguravatelju autentičnosti i vjerodostojnosti kao i jednom od elemenata za osiguravanje trajnog pristupa (Bellini *et al.*, 2008). U kontekstu znanstvenog istraživanja svrhu TI možemo tražiti u sljedivosti i ponovnom korištenju znanstvenih resursa (npr. digitalnih objekata) te omogućavanju mjerenja utjecaja i širenja koje imaju takvi resursi u okviru znanstvene zajednice (Mayernik i Maull, 2017). Rasprostranjena infrastruktura TI može ubrzati primjenu otvorene znanosti temeljem otkrića znanstvenih izrađevina, jasnog određenja doprinosa, mogućnosti praćenja izvora, nedvosmislenog citiranja u znanstvenom radu, omogućavanja i podržavanja ponovljivosti istraživanja te poboljšanja kvalitete metapodataka kroz povezane izvore (Dappert *et al.*, 2017).

Stručnjaci iz Savez istraživačkih podataka (RDA) vide bitne karakteristike za TI u sljedećem (Wittenburg *et al.*, 2017):

- jednoznačna identifikacija određenog digitalnog objekta
- TI se najčešće sastoji od indikatora imena prostora[131] (prefiksa) i lokalnog identifikatora (sufiksa)
- omogućava poduzimanje aktivnosti na web-u
- može perzistentno rezolvati na metapodatke, skup podataka pojedinog digitalnog objekta, html stranicu ili samo na podatkovnu sekvencu
- pridružen je trajnom i postojanom sustavu za rezolvanje i
- generiran je i upravljan od ovlaštenog tijela za registraciju.

[131] Imenski prostor: domena (područje) u kojemu je pojedini identifikator kreiran

4.4.1. Značajni trajni identifikatori

U okviru istraživanja, istraživačkih i kulturnih institucija ne postoji jedan formalni međunarodni standard ili shema TI za fizičke ili digitalne objekte.

U uporabi su različite sheme i standardi za TI[132]. Kao najrelevantniji su se pokazali: Uniform Resource Names (URN), Handle[133] sustav, Digital Object Identifier (DOI), European Persistent Identifier Consortium (ePIC), Life Science Identifiers (LSID)[134], Persistent URL (PURL)[135], Archival Resource Key (ARK) i Library of Congress Control Number (LCCN)[136].

U okviru istraživačkih digitalnih repozitorija trenutno je najšire primjenjiv DOI, međutim ukoliko se usmjeri prema TI u području pojedinih disciplina na važnosti dobivaju i drugi identifikatori (Klump i Huber, 2017). Pojedina istraživanja ukazuju na to da znanstvena područja u okviru humanističkih i društvenih znanosti kao i njihovi repozitoriji u manjoj mjeri koriste TI, međutim i da u ovom trenutku ne postoje dovoljno relevantni podatci o samoj širini primjene TI (Dappert *et al.*, 2017).

Postoje različiti istraživački projekti kojima se istražuje primjena TI. Za potrebe primjene TI u okviru kulturnih institucija u Njemačkoj je tijekom 2017. godine pokrenut projekt *Trajni identifikatori za entitete kulturne baštine (PICHE)*[137], a u Nizozemskoj je u proteklom razdoblju pokrenuto nekoliko projekata (integracija TI u okvire sustava npr. Picturae, DeventIT, De Ree Archiefsystemen) za unaprjeđenje dugotrajne dostupnosti objekata iz područja kulturne baštine na webu. Za primjenu TI u području otvorene znanosti i istraživanja tijekom 2015. godine pokrenut je projekt *Tehnička i ljudska infrastruktura za otvorena istraživanja* (THOR)[138].

U području arheologije na razini digitalnih repozitorija imamo u primjeni različite TI; npr. DOI je u primjeni kod tDAR, ADS i MOD-a, Open Context koristi ARK, a repozitorij DANS koristi URN.

---

[132] Za svaki trajni identifikator potrebno je postojanje registracijskog tijela. Registracijsko tijelo je neovisno tijelo koje dodjeljuje imena i jamči njihovu jedinstvenost i postojanje.
[133] Handle je apstraktna referenca do resursa.
[134] http://www.lsid.info/
[135] http://www.purlz.org/
[136] http://www.loc.gov/marc/lccn.html
[137] Persistent Identifiers for Cultural Heritage Entities, https://www.dnb.de/EN/Professionell/ProjekteKooperationen/Projekte/PICHE/piche.html?nn=264914
[138] Technical and Human Infrastructure for Open Research, https://project-thor.eu/

U nastavku rada prikazuju se TI koji se koriste u okviru postojećih arheoloških repozitorija (npr. URN, DOI, ARK), u okvirima znanstvenih istraživanja (npr. ePIC) te koji sadrže metapodatke (npr. izostavljen je PURL sustav koji ne koristi metapodatke).

4.4.1.1. Uniform Resource Names (URN)

Osnovna funkcionalnost URN je imenovanje resursa i on je opći koncept koji omogućava korištenje različitih tipova identifikatora. Osnovna sintaksa URN identifikatora je u obliku: *"urn:" <Identifikator Imenskog Prostora> ":" <Specifični String Imenskog Prostora>*. Postoje različiti imenski prostori (npr. CLEI[139], ISBN, ISSN) čiju registraciju i evidenciju provodi organizacija za Internet adrese i protokole IANA[140]. Nema središnjeg administrativnog tijela niti središnje infrastrukture. Najčešće ga koriste nacionalne i znanstvene knjižnice. Na razini Hrvatske u kontekstu otvorenosti koristi se kao referenca u okviru sustava Dabar.

Metapodatci su definirani od strane središnjeg administrativnog tijela u odnosu na pojedine digitalne objekte. Npr. u Hrvatskoj je za pohranu digitalnog objekta ocjenski radovi u okviru Dabra definiran zasebni skup metapodataka[141]. Nadalje, Njemačka nacionalna knjižnica je definirala skup metapodataka[142] koji se odnose na različite digitalne objekte, a koji npr. obuhvaćaju monografije, audio knjige, disertacije.

Istraživanja primjene URN za potrebe TI u području kulture i znanstvenog istraživanja provode se u Njemačkoj (npr. projekt PICHE) kao i u Italiji[143].

4.4.1.2. Handle sustav

U svrhu osiguravanja jedinstvenosti i trajnog pristupa digitalnim objektima, neprofitna organizacije *Korporacija za nacionalne istraživačke inicijative* (CNRI)[144] razvila je Handle sustav. Ovaj sustav je servis opće namjene koji omogućava mehanizam za pristupanje trajnom identifikatoru digitalnog objekta te rezolvanje identifikatora kako bi omogućio pristup do podataka neophodnih za lociranje, pristup ili druge načine korištenja

[139] Common Language Equipment Identifier, https://tools.ietf.org/html/rfc4152
[140] Internet Assigned Numbers Authority, https://www.iana.org/
[141] https://dabar.srce.hr/sites/default/files/upute_za_pohranjivanje_radova_v1.0.pdf
[142] https://d-nb.info/1160064784/34
[143] Više o primjeni URN u Italiji može se vidjeti u članku (Bellini *et al.*, 2008).
[144] Corporation for National Research Initiatives, https://www.cnri.reston.va.us/

identificiranog digitalnog objekta. Podatci o trenutačnoj lokaciji digitalnog objekta pohranjeni su kao zapis u okviru sustava Handle. Promjenom kod digitalnog objekta (npr. lokacija) mijenja se samo pojedini dio zapisa, ali ne i adresa Handle sustava koja je trajna.

Konceptualno Handle sustav realiziran je nezavisno od imenskog servisa Interneta (DNS)[145] te ne postoji vršni poslužitelj, svaka administrativna jedinica uspostavlja vlastiti vršni poslužitelj. Za sve organizacije koje koriste Handle sustav postoji centralni vršni poslužitelj, Globalni registar Handle sustava (GHR)[146] koji sadrži sve prefikse organizacija (ili imenovanih jedinica). Na razini pojedine organizacije potrebno je uspostaviti lokalnu Handle uslugu za digitalni repozitorij. Ovime se omogućava sustav koji daje odgovore na upite klijenta te isporučivanje podataka / metapodatak o digitalnom objektu.

Ovaj sustav omogućava pridruživanje više tipova vrijednosti npr. Internet adrese i URL sa svakim identifikatorom, a dodatne značajke sustava možemo tražiti u optimiziranosti je za brzinu i pouzdanost, otvorenom i dobro definiranom protokolu te podatkovnom modelu.

Handle sustav sastavljen je od sljedećih elemenata: skupa protokola, imenskog prostora i programskog dijela.

Handle identifikator se sastoji od prefiksa i sufiksa. Prefiks identificira administrativnu jedinicu (organizaciju) kreiranja i administriranja referenci. Prefiksom se osigurava globalna jedinstvenost u okviru Handle sustava. Drugi dio Handlea je sufiks koji daje lokalno ime resursa. Sintaksa je u obliku: *<Handle>::=<Naming Authority> "/" <Local Name>*.

Putem Handle sustava dobivaju se pojedini metapodatkovni elementi o digitalnim objektima. Najčešće se radi o elementima kojima se definira lokacija objekta, oblik u kojem je raspoloživ i tip pristupa (npr. slobodan).

Sustav se uporablja za identifikatore prema člancima, izvještajima, knjigama, dokumentima, metapodatcima, distribuiranom sadržaju i skupovima podataka.

Na temelju Handle sustava napravljeni su npr. DOI i ePIC.

---

[145] Domain Name System
[146] Global Handle Registry, https://www.dona.net/prefix/resolve

4.4.1.3. Digital Object Identifier (DOI)

DOI je administrativna shema i trajni digitalni identifikator za objekte[147]. Upravljanje i kontrolu DOI-a provodi organizacija International DOI Foundation (IDF). Tijekom 2012. godine postao je službeni ISO standard – ISO 26324[148]. DOI je kreiran u svrhu stalnosti (stalna relacija na imenovani resurs), omogućavanja aktivnosti (može se pristupiti metapodatcima objekta), omogućavanja interoperabilnosti te je prikladan za identifikaciju različitih objekata u digitalnom okruženju (Hilse i Kothe, 2006). Elementi DOI sustava su: standardizirana sintaksa numeriranja, usluga rezolvanja, podatkovni model s podatkovnim rječnikom i implementacijski mehanizmi. DOI identifikator sastoji se od dvije komponente, prefiksa i sufiksa, koji zajedno daju cjelovito ime.

Prefiks se kod DOI sastoji od indikatora direktorija 10 te koda registranta, koji je jednoznačni niz znakova pridružen registrantu. Kod registranta može imati pod elemente. Indikator direktorija se kod registranta kao i ostali pod elementi odvajaju točkom (npr. 10.1529.16, 10 je indikator direktorija, 1529 je DOI registranta Sveučilište u Zadru, a 16 je primjer pod elementa Sveučilišta u Zadru). Sufiks kod DOI-a sastoji se od niza znakova odabranih od registranta. Jedinstvenost se osigurava sekvencijalnim brojevima od strane registranta ili uključivanjem identifikatora nekog od sustava registranta. Primjer cjelovitog DOI-a za digitalni objekt arheološki časopis *Archaeologia Adriatica* je DOI:10.15291/archeo.

DOI se može dodijeliti bilo kojem objektu, bez obzira u kojoj mjeri taj objekt može biti sastavni dio nekog većeg entiteta. Prilikom dodjeljivanja DOI-a, registrant osigurava metapodatke kojima opisuje objekt. Metapodatci kojima se opisuje objekt moraju biti navedeni tako da osiguravaju razlikovanje i jedinstvenost objekta kao zasebnog entiteta u okviru DOI sustava. Metapodatci kod DOI-a mogu biti npr. imena, identifikatori, opisi, tipovi, klasifikatori, lokacije, mjere, relacije kao i druge relevantni tipovi. U okviru DOI postoji minimalni skup metapodataka kojima se osigurava prepoznavanje i interoperabilnost.

[147] Kod DOI objekt može biti bilo koji entitet npr. fizički, digitalni ili apstraktni.
[148] Information and documentation – Digital Object Identifier, https://www.doi.org/ISO_Standard/sc9n475.pdf

Administrativni elementi sadržani su u samo tri metapodatkovna elementa i vezani su uz pridruženi kod registracijskog autoriteta, datum izdavanja DOI-a i broj pridružene inačice.

4.4.1.4. European Persistent Identifier Consortium (ePIC)

Tijekom 2009. godine osnovan je ePIC kao konzorcij Europskih partnera u svrhu stvaranja TI za potrebe znanstveno-istraživačkog rada kao i u području kulturne baštine na području Europe. Jedan od ciljeva uspostave ePIC je stvaranje nove metode za referenciranje primarnih i sekundarnih istraživačkih podataka te imenovanje tih podataka na jedinstven i bezvremenski način. U kontekstu znanstvenog istraživanja fokus ePIC-a je na registriranju podataka u ranim fazama istraživačkog procesa, u kojem postoji mnoštvo podataka i koji bi mogli biti korišteni od drugih istraživača, grupa ili zajednica. Kao važna karakteristika ePIC-a ističe se postojanje vrste podataka[149] kao jednog od parametara.

Temelj ePIC je Handle sustav i infrastruktura. ePIC identifikator je znakovni niz koji se sastoji od prefiksa i sufiksa, međusobno odvojenih s "/". Prefiks ima broj 21[150]. Sufiks se sastoji od sljedećeg znakovnog niza „*fg-inst-num1-num2-num3-c*", kod kojeg se *fg* koristi u posebne svrhe, *inst* je alfanumeričko polje putem kojeg se navodi institucija (registrant) u okviru Handle sustava, *num-1-num2-num3* heksadecimalni brojevi, a *c* je kontrolna suma kojom se osigurava cjelovitost handle stringa.

Prethodno spomenute vrste podataka su dodatni metapodatci kojima se osiguravaju informacije prije same obrade i pristupa, a odnose se na to o kojim se podatcima radi i gdje su ti podatci. Tipični elementi koji se navode su: priroda i vrsta dokumenta (MIME[151] vrsta, npr. tekst/html, slika/jpeg, video/mp4), verzija, prethodna verzija, embargo, datum trajanja, dodatni podatci o lokaciji i osnovni elementi Dublin Core sheme.

[149] engl. Data Type
[150] Stari broj za prefiks je bio 11858, koji je prestao važiti 9. siječnja 2018. godine.
[151] Multipurpose Internet Mail Extensions, https://tools.ietf.org/html/rfc2049

4.4.1.5. Archival Resource Key (ARK)

U svrhu kvalitetne i trajne identifikacije informacijskih resursa (npr. digitalnih dokumenata, baza podataka, programa, kao i apstraktnih entiteta), California Digital Library je tijekom 2001. godine dizajnirala shemu ARK. Ovo je decentralizirani sustav identifikatora koji koristi ideju URL kao trajnog identifikatora.

Identifikator ARK predstavljen je slijednim nizom znakova koji sadrže oznaku *"ark:"* čija je uloga potvrđivanje vrste sheme koja se uporablja. Pojedini ARK se sastoji od promjenjivog i nepromjenjivog dijela.

Sintaksa ARK je sljedeća: *[http://NMA/]ark:/NAAN/ObjectName[Qualifier]*.

Kada je u okvirima URL, započinje oznakom protokola (npr. http:// ili https://) i imenom usluge ili autoriteta mapiranja[152] koja omogućava podršku za ARK. Ime usluge ili autoriteta mapiranja je promjenjiv i zamjenjiv te je odgovoran za objavu ARK u mrežnom okruženju kao URL.

Nepromjenjivi dio identifikatora započinje oznakom *"ark:"*. Nakon njega slijedi broj pridružen autoritetu imenovanja[153], njime se određuje organizacija[154] koja je imenovala ARK te pridružuje ime objekta. Ime objekta definira se u odnosu na skup pravila, a mogu biti složena i s varijantama. Može se pridodati i dodatni u svrhu identificiranja usluge. Usluge kod ARK-a mogu biti digitalni objekt, metapodatci kojima opisujemo digitalni objekt i podatci o njegovoj postojanosti.

ARK kao usluga može raditi s metapodatkovnim shemama DC, METS[155] kao i ostalim metapodatkovnim shemama koje su oblikovane kao XML. Osnovni ARK servisi vraćaju ERC[156] format. ERC[157] opisujemo kao objekt s osnovnim skupom elemenata DC. Namjera ovakvog pristupa je stvaranje sustava izraza koji je ljudima jednostavan za rad kao i za strojnu obradu.

Može se uporabiti za interakciju s drugim sustavima, može se primijeniti kao poveznica na web stranice, može biti referenciran s OpenURL[158], metapodatci mogu biti

---

[152] Name Mapping Authority, NMA
[153] Name Assigning Authority Number, NAAN
[154] Organizacija može biti nacionalna knjižnica, nacionalni arhiv, izdavač ili pojedini repozitorij.
[155] Metadata Encoding and Transmission Standard, http://www.loc.gov/standards/mets/
[156] Electronic Resource Citation
[157] ERC koristi osnovna četiri elementa: tko, što, kada i gdje kako bi se dobio minimalni i jednoznačni opis.
[158] https://en.wikipedia.org/wiki/OpenURL

preuzeti od drugih repozitorija te može sadržavati i druge identifikatore (npr. ISSN, ISBN). Pojedina istraživanja (Peyrard, Tramoni i Kunze, 2014) pokazuju na to da je ARK rado korišten od strane institucija u području kulturne baštine, međutim ne navode se razlozi ili dobrobiti koje proizlaze od korištenja ARK-a.

4.4.2. Identifikacija elemenata usporedbe

Osnovni funkcionalni zahtjevi vezani u identifikator definirani su već sredinom 90-ih i povezani su uz: *globalni opseg* (identifikator ne implicira lokaciju npr. adresu, i na globalnoj razini ima isto značenje npr. ime), *globalnu jedinstvenost* (identifikator je pridružen samo jednom određenom digitalnom objektu), *trajnost* (identifikator mora biti trajan, globalno jedinstven te se može primijeniti kao trajna referenca), *skalabilnost* (identifikator se može dodijeliti bilo kojem digitalnom objektu, koji može biti raspoloživ niz godina), *podržavanje postojećih shema i standarda* (shema identifikatora ili standard mora omogućiti podršku postojećim sustavima imenovanja ukoliko ispunjavaju postavljene zahtjeve), *proširivost* (shema identifikatora mora dozvoli moguća buduća proširenja sheme), *nezavisnost* (odgovornost o imenima i uvjetima je na autoritetu imenovanja) (Sollins i Masinter, 1994). Također navedeni su i zahtjevi povezani uz kodiranje i dekodiranje identifikatora. Zahtjevi u tom kontekstu odnose se na prezentaciju u jasnom tekstualnom obliku, jednostavnu usporedbu, jednostavno ljudsko praćenje i bilježeneu identifikatora, prijenos identifikatora postojećim protokolima te mogućnost korištenja od strane stroja (Sollins i Masinter, 1994).

Noviji funkcionalni zahtjevi identificirani su u *utemeljenosti na dokumentiranom standardu ili usluzi koja pridružuje identifikator* (Wittenburg *et al.*, 2017), *identifikator treba podržati istraživača tijekom istraživačkih aktivnosti i kroz cijeli životni ciklus*, *omogućiti metapodatke kao i podržati interoperabilnost* (Dappert *et al.*, 2017), *podržavanje referenciranja i granularnosti* (istraživački repozitoriji mogu sadržavati različite vrste podataka te je potrebna identifikacija pojedinačnog skupa podataka) (Paskin, 2005) (Lee i Stvilia, 2014) (Bellini *et al.*, 2008) te *vjerodostojnost i održivosti registracijskog autoriteta* (institucije) (Bellini *et al.*, 2008).

4.5. Zaključno razmatranje

U današnje vrijeme u području arheologije i njezinom digitalnom okruženju važni su digitalni objekti i digitalni repozitoriji. Putem njih omogućava se široka dostupnost arheoloških entiteta, kao i njihova ponovna uporaba u istraživanjima. Digitalni objekt je skup podataka kojima opisujemo neki resurs u digitalnom okruženju. On je složeni objekt koji je agregiran od jedne ili više stavki sadržaja. Sastavni dio digitalnog objekta su i metapodatci.

Digitalni repozitorij je skup sustava i usluga koji omogućavaju pohranu, upravljanje, dohvat, prikaz i ponovnu uporabu digitalnih objekta. Istraživački podatkovni repozitorij je repozitorij koji pokriva otvorene istraživačke podatke, a u okviru istraživanja identificirani su sljedeći osnovni zahtjevi: podržavanje različitih metapodatkovnih shema, interoperabilnost, metrika za procjenu kvalitete, omogućavanje pretraživanja, upita i filtriranja te automatsko i poluautomatsko generiranje metapodataka.

Arheološki zapis je trag o ljudskoj prošlosti i sadrži bilješke, crteže, fotografije, mape i tablice o arheološkim entitetima. Sastavni elementi arheološkog zapisa su: izvorna dokumentacija, analitička dokumentacija, administrativna dokumentacija i projektni izvještaji. Transformacijom arheološkog zapisa u digitalno okruženje stvaraju se mogućnosti za njegovo evidentiranje, zaštitu, analizu te široku diseminaciju.

Digitalni arheološki zapis nastaje temeljem terenskog, interpretativnog ili zaštitnog rada istraživača arheologa vezanog uz pojedini arheološki entitet, kojeg karakterizira fizički odnosno tekstualni model. Digitalni arheološki zapis u okviru digitalnog okruženja predstavljen je putem digitalnog objekta koji ima osnovnu strukturu (npr. atributi i vrijednosti) te stavke sadržaja (npr. slika, video, izvještaj).

Važnost metapodataka uočena je u nizu znanstvenih istraživanja, smjernica, životnom ciklusu podataka, znanstvenoj komunikaciji, kao i za digitalne objekte te repozitorije. Zaključujemo da su u području arheologije metapodatci neophodni za: pristup podatcima, pronalaženje podataka, grupiranje podataka temeljem obilježja, za spoznaju i odlučivanje jesu li podatci korisni za ponovnu uporabu. Temeljem sinteze postojećih znanstvenih istraživanja te danih opisa i definicija metapodataka, u okviru ovog rada pod pojmom metapodatci podrazumijevamo sustavno uređeni (standardiziran, strukturiran) skup podataka kojima se opisuje digitalni objekt. Putem metapodataka dan

je sadržaj, kontekst i struktura pojedinog digitalnog objekta, te je putem njih moguće ostvariti pretraživanje, upravljanje, povezivanje kao i ponovnu uporabu u zajednici.

Temeljem provedene analize metapodatke možemo klasificirati na: administrativne, deskriptivne, strukturne i korisničke metapodatke. Nadalje metapodatke možemo podijeliti i s obzirom na znanstvene discipline.

Strukture koje su prisutne kod metapodataka su: standardi, sheme i aplikacijski profili. Temelj svake strukture je element.

Za ovaj rad važna struktura je aplikacijski profil, koji omogućava prilagodbu postojećih metapodatkovnih shema sukladno zahtjevima i za određenu primjenu, u ovom slučaju u području arheologije i otvorenih istraživačkih podataka.

Pristupi koji su mogući kod izrade aplikacijskog profila su: DCMI metodološki okvir „Singapore Framework“ i MAP reverzni inženjering. DCMI metodološki okvir „Singapore Framework“ polazi od korisnika i njegovih zahtjeva, a MAP rezervni inženjering polazi od postojećih sustava i prepoznavanja kako oni rade. Za izradu aplikacijskog profila bitni su funkcionalni zahtjevi, model domene te opis metapodatkovnih elemenata. Za izradu modela domene identificiran je pristup Funkcionalnih zahtjeva bibliografskih zapisa. Ovaj pristup je usmjeren na korisnika, te omogućava izvođenje generičkih zadataka pronalazak, identifikaciju, odabir, pristup i istraživanje resursa.

Provedenom analizom utvrđena je potreba evidentiranja metapodataka na tri razine: na projektnoj razini, razini sadržaja i razini datoteke. Metapodatke koji su povezani uz projekt, osnovnu strukturu i kontekst u okviru ovog rada integriramo u cjelinu „osnovna struktura digitalnog objekta“. Sadržajne stavke sadrže entitete koji su povezani uz ostali sadržaj npr. slika, video, 3D.

Za područje arheologije identificirane su sljedeće značajne metapodatkovne sheme: DC, tDAR, ADS, MOD i CARARE, a o njima možemo zaključiti sljedeće:

- *DC* - ima osnovnih 15 elementa. Pojedini prilagođeni elementi sheme uporabljuju se za opis sadržaja entiteta projekt kao i entiteta bibliografski podatci.
- *tDAR* - metapodatkovni elementi koriste se na razini projekta, zbirke ili resursa. Metapodatkovni elementi se koriste za opisivanje sadržaja osnovne strukture te sadržajnih stavki. Za osnovnu strukturu identificirani su entiteti projekt i osnovna

struktura, a za sadržajne stavke identificirani su entiteti publikacija, slika, prostorni i senzorski podatci. Shema sadrži veliki broj elemenata (> 90).

- *ADS* - metapodatkovni elementi vezani su uz: projekt, detaljan opis osnovne strukture, sadržajne stavke, datoteke i administraciju. Identificirani su entiteti projekt, arheološki resurs te veći broj entiteta sadržajnih stavki. Entitet projekt ima 14 elemenata. Entitet arheološki resurs sadrži nekoliko područja (npr. opće informacije, kreatori, identifikatori, vrsta istraživanja) i ima veći broj elemenata (> 25). Sadržajne stavke pokrivaju osnovni sadržaj (entiteti: dokumenti i tekstovi, tablice, baze podataka, vektorska grafika, rasterska grafika, video i zvuk), sadržaj povezan uz prikupljanje arheoloških podataka i terenski rad (entiteti: prostorna istraživanja, geofizička istraživanja, istraživanje podmorja, lasersko skeniranje i dendrokronološka istraživanja) te podatkovne analize i vizualizaciju (entiteti: GIS, CAD i 3D model). Na razini datoteke kod ove sheme usmjerenje je na osnovnim elementima (npr. ime datoteke, format, program), a administrativni elementi su vezani uz životni ciklus digitalnog objekta.
- *MOD* - ima definirani minimalni skup metapodatkovnih elemenata vezanih uz pojedinačno arheološko istraživanje. Elementi su raspoređeni kroz četiri entiteta: povijest istraživanja, izvori za kreiranje podataka, metode i strukture te izvještaj. Shema sadrži manji broj elemenata (< 35) u odnosu na tDAR i ADS.
- *CARARE* - usmjerena je na agregiranje podataka, njezini su metapodatkovni elementi vezani uz opis digitalnog sadržaja izraženog kroz objekt baštine, opis digitalnog resursa, pripadajućih aktivnosti i informacije o kolekciji. Identificirani su entiteti: objekt baštine, digitalni resurs, aktivnost ili događaj i kolekcija. Entitet objekt baštine pokriva sadržaj o objektu materijalne kulture, a digitalni resurs uključuje različiti sadržaj.

Prethodno navedene metapodatkovne sheme imaju najveću podudarnost vezano uz metapodatkovne elemente za entitet projekt, dok na razini entiteta povezanih uz sadržaj i sadržajne stavke digitalnog objekta uzimaju u obzir različite metapodatkovne elemente. Pretpostavka za ovakvu različitost je u namjeni digitalnih repozitorija čiji su oni sastavni dio, vremenskom raskoraku kreiranja i načinu prezentacije samih podataka prema potencijalnim korisnicima (npr. razina zbirke kod tDAR).

U svrhu točnijeg formuliranja elemenata osnovne strukture i sadržajnih stavaka, identificirani su i analizirani pojedini znanstveni radovi i standardi (npr. CDSASM, ICDSAO). U njihovim okvirima identificirani su entiteti: projekt, osnovna struktura i kontekst. Elementi entiteta kontekst pripadaju u važne elemente u kontekstu otvorenih istraživačkih podataka.

Metapodatci na razini datoteke identificirani su kod shema tDAR i ADS, a elementima se pokriva sadržaj koji se odnosi na ime datoteke, format datoteke, veličinu datoteke, korišteni program i označavanje moguće povezanosti s drugim datotekama.

Otvoreni istraživački podatci postoje u digitalnom okruženju i osim njihovog arhiviranja i dostupnosti, za njihovu procjenjivost, shvatljivost i uporabljivost bitno je pretraživanje. U kontekstu znanstvenog rada i istraživanja, pretraživanje podataka se poduzima u svrhu pronalaženja činjenica za razrješenje istraživačkih pitanja, prikupljanje podataka za istraživački rad, donošenje odluka ili ostajanje „up-to date“.

Kod pretraživanja podataka utvrđeni su sljedeći osnovni konstrukti: korisnik (prepoznaje potrebu i traži podatke), digitalni sustav (mjesto i usluga na kojemu su podatci dostupni i raspoloživi), proces pronalaženja ili istraživanja (npr. pretraživanje, pregledavanje) i interakcija (npr. procjena rezultata, preoblikovanje upita).

Pretraživanje u okviru ovog rada analizirano je putem Višedimenzionalnog modela interakcije korisnika i weba Wanga, Hawka i Tenopira koji uzima u obzir korisnika, sučelje i web prostor.

Utvrđeno je da istraživači u području arheologije kao izvore podataka koriste klasične publikacije kao i digitalne izvore (repozitorije). Za istraživanje i rad arheologa važni su podatci o arheološkim entitetima i iskapanjima; geografski, prostorni, vremenski i kronološki podatci, GIS podatci, podatci o biološkima i materijalnim analizama. Na korisnika kod pretraživanje utječe digitalna pismenost, uporaba društvenih mreža, kredibilitet organizacije kao i socio-demografske karakteristike.

Kroz sučelje imamo mogućnost pretraživanja temeljem tematskih kategorija, jednostavnog pretraživanja kao i temeljem logičkih operatora pretraživanja. U novije vrijeme pretraživanje se zasniva na korisničkom iskustvu, a pretraživanje koje možemo povezati s korisničkim iskustvom identificirano je u okviru ARIADNE repozitorija. Takvo pretraživanje omogućava vizualno pretraživanje s usmjerenjem na prostorno i vremensko određenje digitalnog objekta te prikaz različitog sadržaja repozitorija.

U okviru web prostora značajan element su metapodatci. Pretraživanje u ovom dijelu sastoji se od definiranja selekcijskih kriterija. Selekcijski kriteriji su ključne riječi ili fraze, a mogu biti domenski uvjetovani. Kod istraživačkih podataka bitni su kontekstualni podatci. Temeljem pregleda postojećih digitalnih repozitorija u području arheologije, utvrđeno je da repozitoriji koriste različite selekcijske elemente. Razlog različitih elementa možemo tražiti u svrsi samih digitalnih repozitorija.

Za pretraživanje podataka u digitalnom okruženju u području arheologije identificirana su sljedeća ograničenja: različita praksa zapisivanja, loša kvaliteta metapodataka i jezične barijere, koje se mogu smanjiti temeljem uporabe standarda i rječnika, ograničenjem metapodatkovnih vrijednosti te provjerom vrijednosti.

U svrhu osiguravanja trajne, stabilne i opće prihvaćene reference digitalnog objekta identificiran je trajni identifikator, te je napravljen pregled značajnih trajnih identifikatora. Utvrđeni su sljedeći TI: URN, Handle sustav, DOI, ePIC i ARK. Kroz znanstvena istraživanja utvrđeni su bitni elementi za njihovu usporedbu kako bi se u kasnijoj fazi ovog rada mogla provesti njihova evaluacija i određivanje koji od TI je prikladan za aplikacijski profil.

5. ISTRAŽIVAČKI DIO

Istraživačka pitanja postavljena su u kontekstu otvorenih istraživačkih podataka. U okviru ovog rada kontekst otvorenih istraživačkih podataka odnosi se na kreiranje podataka koji nastaju kao rezultat znanstvenog i istraživačkog procesa, te su dio životnog ciklusa podatka. Temeljem analize postojećih znanstvenih spoznaja nadalje je utvrđeno da otvoreni istraživački podatci moraju biti dostupni u digitalnom okruženju, pretraživi, procjenjivi, razumljivi i uporabljivi. S obzirom na ove zahtjeve potrebno je identificirati elemente kojima će se opisati npr. kreiranje digitalnog objekta, definirati elementi za pretraživanje, kao i odrediti elemente koji se mogu primijeniti u svrhu usporedbe istraživačkih podataka.

U okviru ovog dijela rada razrješavaju se istraživačka pitanja postavljena u ovom radu prema definiranoj metodologiji istraživanja. Identifikacijom i usporedbom elemenata iz znanstvenih istraživanja i postojećih metapodatkovnih shema kreirat će se osnovna lista entiteta i metapodatkovnih elemenata digitalnog objekta. Metapodatkovni elementi bit će definirani za osnovnu strukturu i sadržajne stavke digitalnog objekta. Identificirani elementi su temelj za mjerni instrument kojim će se preispitati i procijeniti važnost elemenata kod stručnjaka u području arheologije. Temeljem e procjene stručnjaka bit će utvrđeni elementi, koji će se koristiti za konstruiranje aplikacijskog profila. Aplikacijski profil usporedit će se u odnosu na postojeću praksu kod kreiranja baza podataka u arheologiji na primjerima iz Hrvatske, te će biti preispitan i vrjednovan u odnosu na korisničku percepciju. Temeljem dobivenih rezultata napravit će se ažuriranje aplikacijskog profila te će biti predložene preporuke za istraživačku zajednicu.

5.1. Relevantni metapodatkovni elementi

Prethodno je utvrđeno da je digitalni arheološki zapis u okviru digitalnog okruženja pohranjen putem digitalnog objekta koji ima osnovnu strukturu (npr. atributi i vrijednosti) te stavke sadržaja (npr. slike, video i zvučni zapisi, izvještaji itd.).

Cilj je kroz osnovnu strukturu identificirati elemente kojima se može objasniti nastanak tih podataka i kontekst, te prikazati elemente identifikacije i svojstva kako bi se omogućila npr. njihova pohrana, pretraživanje, shvatljivost i uporabljivost. U okviru

osnovne strukture bit će prikazani i analizirani metapodatkovni elementi koji su povezani uz entitete: povijest istraživanja, projekt, osnovnu strukturu i kontekst.

Sadržajne stavke pokrivaju sadržaj koji proizlazi iz ili je povezan uz entitete osnovne strukture. One pokrivaju sljedeće: *osnovni sadržaj* (entiteti: dokumenti, tekstovi, publikacije, tablice, baze podataka, vektorska grafika, rasterska grafika, digitalni video i zvuk), *sadržaj povezan uz prikupljanje arheoloških podataka i terenski rad* (entiteti: prostorno istraživanje, istraživanja bespilotnim letjelicama, geofizička istraživanja, istraživanja podmorja, dendrokronološka istraživanja), kao i sadržaj koji se odnosi na *podatkovne analize i vizualizaciju* (entiteti: GIS, CAD i 3D modeli).

5.1.1. Elementi povijesti istraživanja

Metapodatkovni elementi koji se odnose na entitet povijest istraživanja povezani su uz identificiranje elemenata koji mogu pomoći u razumijevanju pripremne faze istraživanja i prethode definiranju projekta. Elementi za ovaj dio strukture identificirani su u okvirima MOD i ADS metapodatkovne sheme. Ovim elementima možemo imenovati istraživanje, opisati svrhu istraživanja, navesti metode koje se koriste u istraživanju, navesti vrstu dokumentacije koja proizlazi iz istraživanja, opisati geografsku lokaciju na kojoj se provodi istraživanje, odrediti kronološki period i razdoblje na koje se odnosi istraživanje, imenovati glavnog istraživača te odrediti godinu istraživanja. Metapodatke ove razine možemo klasificirati u deskriptivne metapodatke. Imena metapodatkovnih elemenata, pripadnost metapodatkovnoj shemi, kratki opis te oznaka za daljnje uključenje u istraživanje prikazani su u Tablici 6.

Tablica 6.: Relevantni metapodatkovni elementi povijesti istraživanja

Metapodatkovni element	**Izvor elementa**		**Kratki opis**	**Uključen u daljnje istraživanje**
	MOD	ADS		
1	*2*	*3*	*4*	*5*
Ime istraživanja	✓	-	Ime istraživanja	Da
Svrha	✓	-	Kratki opis svrhe i glavnih rezultata istraživanja	Da
Metode	✓	-	Planirane metode istraživanja	Da
Vrsta dokumentacije	✓	-	Vrsta dokumentacije koje nastaje istraživanjem npr. crteži, fotografije, izvještaji, video,..	Da

Metapodatkovni element	Izvor elementa		Kratki opis	Uključen u daljnje istraživanje
	MOD	ADS		
1	*2*	*3*	*4*	*5*
Planirana lokacija istraživanja	✓	-	Županija, Općina, Mjesto, Adresa	Da
Kronološki period i razdoblje	✓	-	Pripadnost kronološkom razdoblju i periodu	Da
Istraživač	✓	-	Glavni istraživač, voditelj istraživanja	Da
Godina	✓	-	Godina ili vremenski interval istraživanja	Da
Izvor	-	✓	Važni prethodni izvori (resursi) na temelju koji nastaje ovaj projekt	Da

Svi prethodno navedeni elementi u Tablici br. 6 uzeti su u daljnji tijek istraživanja, te su navedeni u istraživačkom instrumentu za prvi krug istraživanja.

5.1.2. Elementi projekta

Metapodatkovni elementi entiteta projekt omogućavaju interpretaciju te razumijevanje na koji je način pripremljeno i provedeno istraživanje. Općenito, pri definiranju projekta potrebno je navesti: ime projekta, opis projekta, svrhu i ciljeve, koristi i troškove, metode implementacije, vremenske termine provedbe projekta, potrebne resurse te očekivane ishode. U okviru standarda i smjernica za arheološka istraživanja i evidentiranje građevina ili struktura (CIFA, 2014) naveden je minimalni skup elemenata koje je potrebno navesti za projekt. Ti elementi su: sažetak, lokacija istraživanja i deskriptori, kontekst projekta, arheološka i povijesna pozadina, opći i specifični ciljevi rada na terenu, zakonski propisi, metodologija istraživanja i rada na terenu, način prikupljanja i pohrane arheoloških entiteta, način zaštite, metodologije istraživanja koje se koriste poslije rada na terenu, izvješćivanje i izrada crteža, način publiciranja i diseminacija informacija, zaštita autorskih prava, postupak arhiviranja, vremenska razdoblja, postupci nadzora i osobe koje su vezane uz projekt.

Metapodatkovni elementi povezani uz projektnu razinu identificirani su u okviru istraživanja (Fetherston, 2013), (Hollander, 2014) te u metapodatkovnim shemama DC,

tDAR i ADS. Identificirani elementi, njihova imena, pripadnost području i uključenost u daljnje istraživanje prikazani su u Tablici 7.

Tablica 7.: Relevantni metapodatkovni elementi projekta

Metapodatkovni element	**Izvor elementa**					**Područje**	**Uključen u daljnje istraživanje**
	(Fetherston, 2013)	(Hollander, 2014)	*tDAR*	*ADS*	*DC*		
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*
Identifikator projekta	✓	-	-	✓	✓	Osnovno	Da
Ime projekta	✓	✓	✓	✓	✓	Osnovno	Da
Vrsta projekta	✓	-	-	-	-	Osnovno	Da
Opis projekta	-	-	✓	✓	✓	Osnovno	Da
Jezik	-	-	-	✓	✓	Osnovno	Da
Vrsta resursa	-	-	-	✓	-	Osnovno	Da
Oblik	-	-	-	✓	-	Osnovno	Da
Lokacija projekta	✓	-	-	✓	✓	Prostorno	Da
Datum	✓	✓	-	✓	✓	Vremensko	Da
Organizacija	✓	-	-	-	-	Organizacijsko	Da
Izdavač	-	-	-	✓	✓	Organizacijsko	Da
Voditelj / Stvaratelj	✓	-	-	✓	✓	Autorsko	Da
Suradnik	✓	-	-	✓	-	Autorsko	Da
Uloga suradnika	✓	-	-	-	-	Autorsko	Da
Pripadnost suradnika organizaciji	✓	-	-	-	-	Autorsko	Da
Vlasnička prava	-	✓	-	✓	✓	Vlasničkih prava	Da
Povezanost	✓	-	✓	✓	-	Referenca	Da
Primarna mrežna referenca	✓	-	-	-	-	Referenca	Da
Datum raspoloživosti	-	✓	-	-	-	Dijeljenja podataka	Da
Licence	✓	✓	-	-	-	Dijeljenje podataka	Da

S obzirom na brojnost, elementi su raspoređeni u sljedeća područja: *osnovno, prostorno, vremensko, organizacijsko, autorsko, vlasničkih prava, referenca i dijeljenje podataka*. U odnosu na metapodatkovnu klasifikaciju ovi elementi pokrivaju sljedeće klase: administrativnu (npr. suradnik / stvaratelj), deskriptivnu (npr. ime projekta, vrsta resursa) strukturnu (npr. povezani projekti, povezanost) i korisničku (npr. vlasnička prava, licence). Svi prethodno navedeni elementi u Tablici 7. korišteni su za daljnji tijek istraživanja, te su navedeni u istraživačkom instrumentu za prvi krug istraživanja. Opisi elemenata dani su kroz Prilog 2.

5.1.3. Elementi osnovne strukture

Metapodatkovni elementi entiteta osnovna struktura temelj su za sva arheološka istraživanja i istraživačka pitanja. Opisivanje kroz metapodatke u ovom dijelu služi identificiranju metapodataka koji omogućavaju razumijevanje, usporedbu i procjenu svrsishodnosti digitalnog objekta. U kontekstu arheologije navedeno možemo prepoznati ako za pojedini objekt postoje podatci koji se odnose na točnu identifikaciju objekta, vremensko određenje, prostorno određenje te tehnološku, funkcionalnu i stilističku dimenziju. Pojedina istraživanja opširno opisuju i definiraju što se očekuje od pojedinog arheološkog entiteta[159]. Kako bi digitalni objekt bio svrsishodan, mora istraživaču omogućiti identične podatke kao i arheološki entitet.

Elementi osnovne strukture identificirani su u okviru međunarodnog standarda CDSASM te metapodatkovnih shema tDAR, ADS i CARARE. Identificirani elementi, njihova imena i pripadnost područjima prikazani su u Tablici 8.

Tablica 8.: Relevantni metapodatkovni elementi osnovne strukture

Metapodatkovni element	**Izvor elementa**				**Područje**	**Uključen u daljnje istraživanje**
	CDSASM	*tDAR*	*ADS*	*CARARE*		
1	*2*	*3*	*4*	*5*	*6*	*7*
Identifikator	✓	✓	✓	✓	Osnovni podatci	Da
Ime	✓	✓	✓	✓		Da
Osnovni tip				✓		Da
Datum kreiranja	✓					Da
Datum ažuriranja	✓					Da
Opis (sažetak)	✓	✓	✓	✓		Da
Ključne riječi		✓	✓			Da
Ime arhivskog identifikatora		✓				Da
Vrijednost arhivskog identifikatora		✓	✓	✓		Da
Stvarno stanje objekta				✓		Da
Vrsta istraživanja		✓	✓			Da
Podrijetlo				✓		Da
Status		✓	✓			Da

[159] Arheološki entiteti prema istraživanju Djindiana (Djindjian, 2000) za analizu moraju omogućiti: identifikaciju i klasifikaciju, kulturnu identifikaciju (dobivanje podataka o vremenu i prostoru), kronologiju, internu prostornu raspršenost, identifikaciju materijala i centara proizvodnje, antropološke studije (npr. funkcionalne, društvene, individualne, simboličke) i mrežu rasprostranjenosti (razmjene i trgovine).

Metapodatkovni element	Izvor elementa				Područje	Uključen u daljnje istraživanje
	CDSASM	*tDAR*	*ADS*	*CARARE*		
1	*2*	*3*	*4*	*5*	*6*	*7*
Lokacija, Geografski ime prostora	✓	✓	✓	✓	Prostorno	Da
Lokacija, Mjesto	✓	✓	✓	✓		Da
Katastarska referenca	✓			✓		Da
Lokacija, Geografske koordinate (širina, visina, dužina)	✓	✓	✓	✓		Da
Ime nalazišta		✓	✓		Nalazište	Da
Vrsta nalazišta		✓	✓			Da
Dodatne ključne riječi nalazišta		✓	✓			Da
Tip objekta	✓				Tehnološko, funkcionalno i stilističko	Da
Kategorija objekta	✓					Da
Stanje objekta	✓			✓		Da
Vrsta materijala		✓	✓	✓		Da
Dodatne vrste materijala		✓				Da
Natpisi				✓		Da
Dimenzije - opseg				✓		Da
Dimenzije (vrsta i vrijednost)				✓		Da
Kulturno razdoblje	✓	✓	✓		Kulturno područje	Da
Dodatni kulturni pojam		✓	✓			Da
Vrsta datuma		✓	✓	✓	Vremensko razdoblje	Da
Početna godina	✓	✓	✓	✓		Da
Završna godina	✓	✓	✓	✓		Da
Stoljeće	✓					Da
Istraživački datum	✓	✓	✓	✓		Da
Metoda istraživačkog datuma	✓	✓	✓	✓		Da
Osoba		✓	✓	✓	Istraživač / autor	Da
Uloga osobe		✓	✓			Da
Institucija osobe		✓	✓			Da
Uloga institucije		✓	✓			Da
Institucija odgovorna za objekt	✓	✓			Označavanje i zaštita	Da
Vrsta oznake ili zaštite	✓			✓		Da
Datum označavanja ili zaštite	✓			✓		Da
Referentni broj označavanja i zaštite	✓					Da
Organizacija zaštite	✓					Da
Osoba ovlaštena za promjene digitalnog objekta		✓	✓		Ažuriranje sadržaja objekta	Da
Dozvole		✓	✓			Da
Kreiranje i identifikacija			✓		Administrativno područje	Da
Procjena			✓			Da
Uporaba i kontrola			✓			Da
Raspoloživost			✓			Da
Zaštita intelektualnog vlasništva			✓	✓	Pravni uvjeti korištenja	Da
Bilješke		✓			Ostalo	Da
Pružatelj usluge			✓			Da
Ime reference				✓	Reference	Da

Metapodatkovni element	Izvor elementa				Područje	Uključen u daljnje istraživanje
	CDSASM	*tDAR*	*ADS*	*CARARE*		
1	*2*	*3*	*4*	*5*	*6*	*7*
Vrsta reference				✓		Da
Reprezentacija				✓	Relacije	Da
Prethodni objekt				✓		Da
Aktivnosti				✓		Da
Ima dijelove				✓		Da
Dio je objekta				✓		Da
URL				✓		Da
Mjesto registracije				✓	Informacije o plovilu	Da
Država				✓		Da
Metoda konstrukcije				✓		Da
Tip pogona				✓		Da
Posljednja plovidba				✓		Da

Prema klasifikaciji metapodataka ovi elementi pripadaju sljedećima klasama: administrativnoj (npr. kreiranje, autor, vrsta istraživanja), deskriptivnoj (npr. ime, vremenski period, ključne riječi), strukturnoj (npr. povezanost s replikom) i korisničkoj (npr. kontrola verzije).

Pri identifikaciji elemenata i njihovom opisu, u obzir se uzela njihova opisna istoznačnost ili vrlo bliska sličnost, a ime elementa je dodijeljeno temeljem višestrukog navođenja (npr. Ime – tDAR, ADS, CARARE) ili temeljem pojma koji terminološki može najbolje pokriti njihovo značenje.

Element ključna riječ vezan je uz definiranje pojmova koji nisu prethodno navedeni kroz vrstu istraživanja i nalazišta. Stoga ovaj element možemo nazvati dodatnim jer ističe specifičnosti koje nisu spomenute prethodnim elementima i element po svojoj namjeni odstupa od klasičnog pojma ključne riječi.

Metapodatkovni elementi koji su vezani uz administrativno područje proizlaze iz ADS sheme. Ovi su elementi uzeti u obzir kako bi se osigurala pokrivenost životnog ciklusa digitalnog objekta i ispitala njihova važnost.

Elementi vezani uz reference uzeti su u obzir je ukazuju na međusobnu povezanost podataka. Također u obzir je uzeta i skupina elemenata povezanih uz informacije o plovilu kako bi se omogućilo detaljnije opisivanje pojedinih arheoloških entiteta.

Svi prethodno navedeni elementi u Tablici 8. važni su za daljnji tijek istraživanja, a opisi pojedinog elementa navedeni su kroz Prilog 3.

5.1.4. Elementi konteksta

Za potpuno znanstveno tumačenje arheološkog entiteta, osim podataka o samom arheološkom entitetu, istraživač mora imati na raspolaganju i podatke o arheološkom kontekstu. Općenito arheološki kontekst možemo definirati kao neposredno okruženje arheološkog entiteta, uključujući njegovo povezivanje s drugim entitetima, svojstvima kao i definiranje njegovog stratigrafskog položaja.

Kako u realnom svijetu tako i u okviru digitalnog svijeta, a posebno za ponovnu uporabu arheoloških podatka, značajan je kontekst. U svrhu ponovne uporabe istraživačkih podataka pojedina istraživanja (Ixchel *et al.*, 2013) ističu kako kontekst mora istraživaču osigurati sljedeće podatke o arheološkom entitetu: osnovne podatke (kada i gdje su pronađeni i od koga) te kronologiju nalazišta uključujući stratigrafske podatke za sve entitete i odnose između slojeva.

Elementi entiteta kontekst identificirani su u okviru međunarodnog standarda ICDSAO, a sama analiza napravljena je na temelju publikacije (CIDOC, 1992). Identificirani metapodatkovni elementi, njihov kratki opis te daljnja uključenost u istraživanje prikazani su u Tablici 9.

Tablica 9.: Relevantni metapodatkovni elementi konteksta

Metapodatkovni element	**Kratki opis**	**Uključenost u daljnje istraživanje**
1	*2*	*3*
Način otkrića	Na koji je način arheološki entitet pronađen (npr. slučajno, redovno istraživanje,..)	Da
Referenca mjesta otkrića	Detaljna referenca gdje je arheološki entitet pronađen	Da
Stratigrafska jedinica	Opis sloja u kojemu je pronađen arheološki entitet i njegova povezanost s ostalim slojevima	Da
Značajno pridruživanje	Značajno pridruživanje arheološkog entiteta (npr. pronađen u ognjištu, u grobnici,..)	Da

S obzirom na klasifikaciju metapodataka ovi elementi pripadaju klasi deskriptivnih podataka. Svi prethodno navedeni elementi u okviru Tablice 9. uzeti su u obzir za daljnji tijek istraživanja, te su navedeni u istraživačkom instrumentu za prvi krug istraživanja.

5.1.5. Elementi sadržajnih stavki

Sadržajne stavke identificirane su u okviru metapodatkovne sheme ADS. Popis metapodatkovnih elementa identificiranih entiteta sadržajnih stavki naveden je kroz Priloge od 5. do 20. Elementi su u prilogu prikazani u tablici u kojoj je navedeno sljedeće: ime metapodatkovnog elementa (stupac 1.), pripadnost području (stupac 2.), kratki opis (stupac 3.) te uključenost u daljnje istraživanje (stupac 4.).

Skupni prikaz entiteta i njihova analiza dana je u Tablici 10. Tablica sadrži ime entiteta, broj priloga, razinu, brojnost elemenata (broj elemenata iz shema i dokumentacije te broj elemenata uključenih u daljnje istraživanje) i objašnjenje za pojedini entitet.

Tablica 10.: Prikaz sadržajnih stavki i entiteta digitalnog objekta

Entitet	Prilog *(#)*	Područje	Elementi *(#)*		Objašnjenje
			Shema / Dokumentacija	Istraživanje	
1	*2*	*3*	*4*	*5*	*6*
Dokumenti i tekstovi	5.	Osnovno, specifično	19	14	NAP01
Publikacije	6.	Specifično	17	17	-
Tablice	7.	Osnovno, specifično	11	6	NAP01
Baze podataka	8.	Osnovno, specifično	11	6	NAP01
Vektorska grafika	9.	Osnovno, specifično	13	7	NAP02, NAP03
Rasterska grafika	10.	Osnovno, specifično, dodatno	18	12	NAP01, NAP02
Digitalni video	11.	Osnovno, specifično	16	11	NAP01
Digitalni zvuk	12.	Osnovno, specifično	12	7	NAP01
Prostorna istraživanja	13.	Osnovno, dodatno	13	13	NAP04

Entitet	Prilog (#)	Područje	Elementi (#)		Objašnjenje
			Shema / Dokumentacija	Istraživanje	
1	*2*	*3*	*4*	*5*	*6*
Istraživanje bespilotnim letjelicama	14.	Projektna / istraživačka, razina slike, razina procesiranja	14	14	NAP04, NAP05
Geofizička istraživanja	15.	Projektna, geofizička, izvještaj	45	26	NAP05, NAP06, NAP07
Istraživanja podmorja	16.	Projektna, istraživačke tehnike, istraživanje magnetometrom, istraživanje sonarom, metodologija istraživanje, postupanje podatcima, razina datoteke	4	0	NAP01, NAP08
Lasersko skeniranje	17.	Projektna, Skeniranje, Registriranje skupa podataka, Dodatni podatci	28	28	NAP09, NAP10
Kronološka istraživanja	18.	Projektna, objekt, element, uzorak, radijus, serija	24	32	NAP12
GIS	-	-	0	0	NAP11
CAD	19.	Projektna, Konvencija slojeva, Načina prikupljanja podataka istraživanja, GPS, Izvor podataka, Prethodno snimljeni podatci, Model, Vanjske baze podataka	76	76	-
3D modeli	20.	Projektna, Razina pojedine datoteke	14	14	NAP04
UKUPNI BROJ ELEMENATA SADRŽAJNIH STAVKI			335	283	

Entiteti sadrže različiti broj elemenata, a ukupno je za sve entitete utvrđeno 335 elemenata. Elementi u okviru entiteta navedeni su kroz nekoliko područja. Pojedini entiteti imaju zajedničko područje projekt, koje najčešće sadrži opće elemente povezane uz projekt, kao i elemente koji se odnose na datoteke. U nastavku se navode oznake i opisi povezani uz obrazloženje za smanjenje broja elemenata za pojedini entitet.

NAP01 - Elementi osnovne razine (npr. ime datoteke, format datoteke, veličina, programska podrška i verzija, povezanost s drugim datotekama) nisu uključeni u daljnji tijek istraživanja jer su obvezni za postojanje datoteke u digitalnom okruženju. NAP02 – Elementi čiji je sadržaj višestruko naveden (npr. identifikator / ime, format datoteke / format datoteke) i upućuje na isti sadržaj uzeti su u obzir samo jednom. NAP03 - Postoji element autor, koji nije postojao u prethodnim sadržajnim stavkama. NAP04 – Uz navedeni sadržaj treba evidentirati i projektne metapodatke. Osnovni generički projektni podatci navedeni su u okviru entiteta projekt. NAP05 – Elementi koji se odnose na ime datoteke, format datoteke, programsku podršku i verziju te povezanost s drugim datotekama su generički elementi i moraju biti obavezno navedeni, kao takvi nisu uzeti u obzir za daljnji tijek istraživanja. NAP06 – Za sadržaj je naveden veliki broj elemenata entiteta projekt, a u obzir su uzeti samo elementi koji do sada nisu navedeni u okviru entiteta projekt. NAP07 – entitet geofizička istraživanja sadrži pod razine koje ovise o vrsti istraživačkog uređaja. Elementi pod razina nisu uzeti u obzir u daljnje istraživanje. NAP08 – Elementi povezani uz entitet istraživanje podmorja u velikoj su ovisnosti od drugih istraživanja te za ovu skupinu osim za razinu datoteke nisu identificirani metapodatkovni elementi. Za daljnji tijek istraživanja bitni su samo nazivi razina. NAP09 – S obzirom na specifičnost podataka koji se prikupljaju skeniranjem, u obzir je uzet skup elemenata kojima se opisuje entitet projekt. NAP10 – Metapodatkovni elementi koji su vezani uz dodatni digitalni sadržaj nisu uzeti u obzir zbog vrlo različitog sadržaja (npr. poligonalne mreže, više dimenzijski modeli, video ili animacijski modeli). NAP11 – Metapodatkovni elementi za entitet GIS nisu navedeni u okviru postojećih shema. S obzirom na raznolikost podataka koji se prikupljaju putem GIS-a (npr. vektorske slike, rasterske slike, različiti uređaji, mape, numerički podatci), u okviru ADS-a navedene su samo preporuke za elemente bi se moglo primijeniti. Za potrebe GIS-a u okviru arheologije važna je primjena postojećih metapodatkovnih standarda i shema koje pokrivaju prostorne i deskriptivne podatke. NAP12 – Metapodatkovni elementi entiteta Dendrokronološka istraživanja pregledani su od strane stručnjaka iz područja te su napravljene modifikacije u odnosu na praksu u Hrvatskoj. Promijenjeno je ime iz Dendrokronološko u Kronološko te su nadodani pojedini elementi za opće kronološke objekte.

5.1.6. Zaključno razmatranje

Osnovna struktura digitalnog objekta uključuje entitete: povijest istraživanja, projekt, osnovna struktura i kontekst. Entitet povijest istraživanja ima 9 elemenata, entitet projekt ima 20 elemenata, entitet osnovna struktura ima 66 elemenata, a entitet kontekst ima 4 elementa. Ukupni broj elemenata je 99. Lista elemenata i njihov opis navedeni su u Prilogu 1., 2., 3. i 4.

Putem ovih entiteta moguće je opisati arheološki entitet u digitalnom okruženju osiguravajući podatke o projektu iz kojeg proizlazi arheološki entitet te sadržaju i kontekstu arheološkog entiteta. Utvrđeni elementi omogućavaju identifikaciju, prostorno i vremensko određenje, identifikaciju nalazišta, tehnološku, funkcionalnu i stilističku identifikaciju, identifikaciju autorstva, identifikaciju načina i oblika zaštite, identifikaciju pozicije u okviru životnog ciklusa te identifikaciju relacija u odnosu na druge objekte.

Sadržajne stavke pokrivaju osnovni sadržaj, sadržaj povezan uz prikupljanje arheoloških podataka i terenski rad te sadržaj koji se odnosi na podatkovne analize i vizualizaciju. Osnovni sadržaj obuhvaća entitete dokumenti i tekstovi, publikacije, tablice, baze podataka, vektorska grafika, rasterska grafika, digitalni video i digitalni zvuk. Sadržaj povezan uz prikupljanje arheoloških podataka i terenski rad sadrži entitete prostorno istraživanje, istraživanje bespilotnim letjelicama, geofizička istraživanja, istraživanja podmorja i kronološka istraživanja. Entiteti CAD i 3D modeli vezani su uz sadržaj podatkovne analize i vizualizacije. Kroz sheme je identificirano 335 elemenata, a nakon analize za daljnje istraživanje u obzir je uzeto 283 elementa. Identificirani elementi sadržajnih stavki i njihovi opisi prikazani su od Priloga 5. do 20. Pojedini elementi su isključeni jer se odnose na opće elemente entiteta projekt, razinu datoteke ili elemente koji se odnose na vrlo detaljne tehničke opise. Od sadržajnih stavki možemo izdvojiti entitet istraživanje podmorja za koji nisu identificirani elementi nego samo moguća područja te entitet GIS za koji je preporuka korištenje postojećih standarda.

Usporedimo li identificirane metapodatkovne elemente u odnosu na FAIR načela i funkcionalne zahtjeve za istraživačke repozitorije, putem ovih elemenata omogućen je pronalazak podataka, interoperabilnost sa drugim shemama, označavanje u okviru životnog ciklusa te veći broj relevantnih elemenata. Ovom fazom dani su odgovori na RQ1.

5.2. Važni metapodatkovni elementi za stručnjake iz područja

Metapodatkovni elementi važni za stručnjake iz područja arheologije u Hrvatskoj bit će preispitani i odabrani pomoću Delphi metode. Temeljem opisa provođenja istraživanja navedenog u cjelini Metodologija istraživanja (1.3.2. Druga faza), postupak istraživanja u okviru ovog rada prikazan je na Slici 2.

Inicijalno prikupljanje činitelja za istraživanje napravljeno je pregledom znanstvenih istraživanja te su definirani entiteti i metapodatkovni elementi koji su temelj za mjerni instrument. Pomoću mjernog instrumenta i uz pomoć stručnjaka iz područja arheologije provodi se sužavanje i dopunjavanje te vrjednovanje metapodatkovnih elemenata.

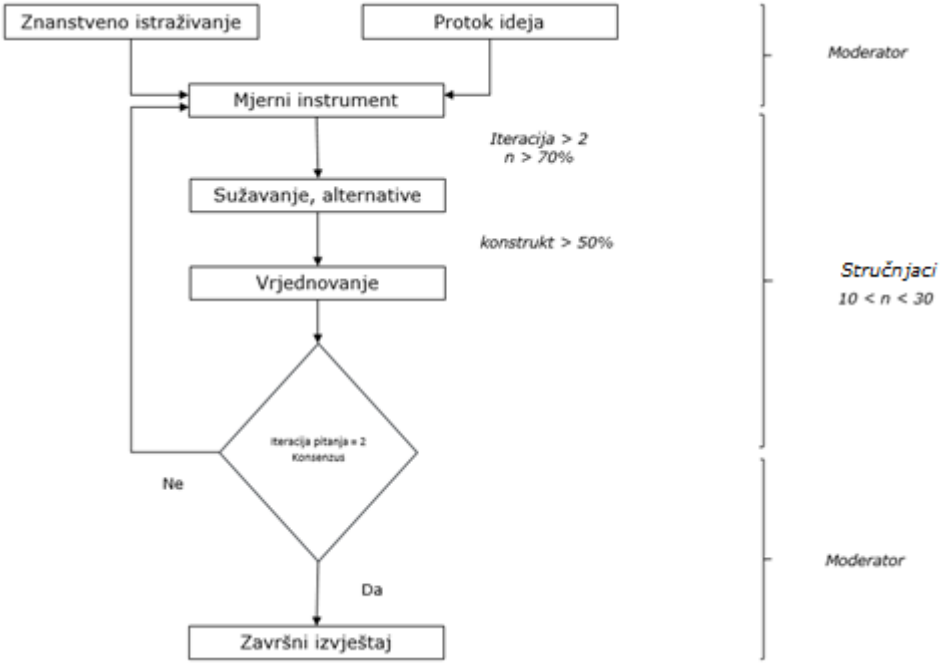

Slika 2.: Postupak istraživanja primjenom Delphi metode

Mjerni instrument možemo opisati kao mjerni postupak, tehniku ili postupak kojim se mjere određene značajke nekog obilježja, karakteristike nekog entiteta (konstrukta, predmeta mjerenja), a može biti varijabla, ljestvica, test ili bilo koji drugi

mjerni postupak (Milas, 2005). Mjerenja[160] u svakoj iteraciji izvest će se pomoću mjernog instrumenta. U prvoj iteraciji stručnjaci će dati povratnu informaciju o važnosti metapodatkovnih elemenata za njihov znanstveno-istraživački i stručni rad u području arheologije te o elementima koji trebaju biti navedeni kod digitalnog objekta. Druga iteracija je povezana uz utvrđivanje važnosti elemenata za pretraživanje i ponovnu uporabu kod stručnjaka. Treća iteracija je povezana uz osiguravanje grupnog mišljenja i konsenzusa o metapodatkovnim elementima.

Ključni indikatori kvalitete mjernog instrumenta su valjanost i pouzdanost (Kimberlin i Winterstein, 2008). Proces razvoja i validacije mjernog instrumenta usmjeren je na smanjenje mogućih pogrešaka u procesu mjerenja.

Pojam valjanosti odnosi se na prikladnost, smislenost i korisnost zaključaka i tumačenja izvedenih iz testnih rezultata. Validacija valjanosti može uključiti procjenu sadržajne, kriterijske i konstruktne valjanosti. Sadržajna valjanost je vrsta valjanosti koja adresira koliko dobro su definirana pitanja u svrhu mjerenja konstrukta od interesa. Za sadržajnu valjanost ne postoje statistički testovi i ona se provodi od strane stručnjaka, a u okviru ovog rada uzeta je u obzir za procjenu mjernog instrumenta.

Pouzdanost je usmjerena na: a.) stabilnost mjera koje se primjenjuju u različitim vremenima nad istim pojedincima ili korištenje istog standarda (re-testiranje) i b.) ekvivalentnost skupa pitanja iz istog testa (interna konzistentnost) ili kako različiti promatrači boduju ponašanje ili događaje koristeći isti instrument (pouzdanost između promatrača). Vrijednosti koeficijenta pouzdanosti kreću se u rasponu od 0,00 do 1,00, pri čemu više vrijednosti ukazuju na višu razinu pouzdanosti. U svrhu provjere pouzdanosti za ovaj će se rad koristiti interna konzistentnost. Interna konzistentnost polazi od toga da mjerenja zajedničkih konstrukata trebaju međusobno biti u korelaciji. Najčešće korištena metoda za procjenu pouzdanosti interne konzistentnosti je Cronbach alpha.

5.2.1. I. iteracija

Za I. će iteraciju biti opisan mjerni instrument, navedeni stručnjaci, postavljeni kriteriji te prikazani rezultati istraživanja.

[160] Mjerenje u okviru ovog rada možemo opisati kao primjenu skupa pravila za pridruživanje brojeva pojedinim konstruktima proučavanih entiteta.

5.2.1.1. Mjerni instrument

Za potrebe istraživanja definiran je mjerni instrument. Mjerni instrument u ovoj iteraciji sastoji se od tri cjeline: uvoda, osnovne strukture i sadržajnih stavki, a pitanja se temelje na rezultatima istraživanja[161] iz cjeline 5.1. i utvrđenim elementima za I. iteraciju.

U okviru uvoda naznačena je važnost digitalnog objekta za područje arheologije u okviru digitalnog okruženja te je dan konceptualni prikaz arheološkog entiteta u okviru fizičkog svijeta i digitalnog okruženja. Konceptualni prikaz dan je na Slici 3. Uvodni dio sadrži i opis kvantifikatora kojima se iskazuju važnost pojedinog elementa.

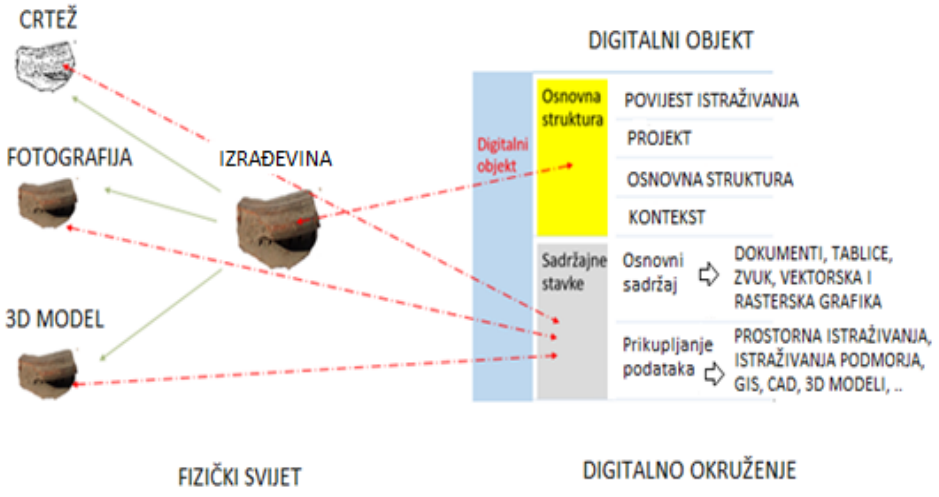

Slika 3.: Konceptualni prikaz arheološkog entiteta u fizičkom svijetu i digitalnom okruženju

Osnovna struktura sadrži pitanja povezana uz metapodatkovne elemente entiteta: *povijest istraživanja, projekt, osnovna struktura i kontekst*. Sadržajne stavke sadrže metapodatkovne elemente vezane uz područja i entitete. Područje osnovni sadržaj sadrži entitete: *dokumenti i tekstovi, publikacije, tablice, baze podataka, vektorska grafika, rasterska grafika, digitalni video i digitalni zvuk*, a područje prikupljanja podataka sadrži entitete: *prostorna istraživanja, istraživanja bespilotnim letjelicama, geofizička istraživanja, istraživanja podmorja, lasersko skeniranje, kronološka istraživanja, CAD i 3D modeli*. Elementi za entitet istraživanje podmorja nisu definirani, a nadopunit će ih stručnjaci.

[161] Entiteti i elementi su navedeni u Prilozima od 1. do 20.

Kako je cilj u prvom krugu od stručnjaka dobiti povratnu informaciju o važnosti metapodatkovnih elemenata za njihov znanstveni i stručni rad, svakom od elementa pridružen je kvantifikator učestalosti kojim se verbalnim putem izražava uporaba metapodatkovnog elementa tijekom znanstveno-istraživačkog rada kod opisa arheološkog entiteta i razumijevanja arheološkog entiteta / digitalnog objekta.

S obzirom na moguću varijaciju u procjenama, za upitnik je odabrana skala procjene sa četiri kvantifikatora (nikad, ponekad, obično i uvijek) prema znanstvenom istraživanju (Burušić, 1999). Skala kvantifikatora, vrijednost i njihovi opisi navedeni su u Tablici 11.

Tablica 11.: Skala kvantifikatora za I. iteraciju istraživanja

Kvantifikator	Opis
1	*2*
0 – nije važan	putem navedenog elementa ne radi se opis npr. arheološke izrađevine / projekta / konteksta, i ne uzima se u obzir kod razumijevanja, usporedbe i procjene svrsishodnosti arheološke izrađevine / digitalnog objekta.
1 – povremeno važan	putem navedenog elementa ponekad se radi opis npr. arheološke izrađevine / projekta / konteksta, i ponekad se uzima u obzir kod razumijevanja, usporedbe i procjene svrsishodnosti arheološke izrađevine / digitalnog objekta.
2 – vrlo važan	putem navedenog elemenata često se radi opis npr. arheološke izrađevine / projekta / konteksta, i često se uzima u obzir kod razumijevanja, usporedbe i procjene svrsishodnosti arheološke izrađevine / digitalnog objekta
3 – esencijalno važan	bez navedenog elementa nije moguće napraviti opis npr. arheološke izrađevine / projekta / konteksta te razumjeti, usporediti element i procijeniti svrsishodnost arheološke izrađevine / digitalnog objekta

Mjerni instrument sadrži 382 elementa za procjenu, od toga se 99 elemenata odnosi na entitete osnovne strukture, a 283 elementa na entitete sadržajnih stavki.

Sadržajna valjanost mjernog instrumenta provjerena je od strane stručnjaka iz područja arheologije s obzirom na sadržaj pitanja, te stručnjaka iz područja informacijskih i lingvističkih znanosti s obzirom na razumijevanje sadržaja.

Kako mjerni instrument sadrži veći broj entiteta i elemenata, navodimo primjer pitanja. Pitanje se odnosi na entitet kontekst i pripadajuće metapodatkovne elemente, a prikaz je dan na Slici 4.

1.4. Elementi konteksta

Područje	Metapodatkovni element	Kratki opis	Kvantifikatori važnosti				Napomena
			nije važan	povremeno važan	vrlo važan	esencijalno važan	
			0	1	2	3	
Kontekst	Način otkrića	Na koji način je arheološki entitet pronađen (npr. slučajni nalaz, sustavno istraživanje, zaštita istraživanja)					
	Mjesto istraživanja	Detaljna referenca gdje je arheološki entitet pronađen (koordinate)					
	Stratigrafska jedinica	Opis sloja u kojemu je pronađen arheološki entitet, i njegova povezanost s ostali slojevima					
	Značajno pridruživanje	Značajno pridruživanje arheološkog entiteta (npr. pronađen u ognjištu, u grobnici,..)					

Slika 4.: Primjer pitanja u mjernom instrumentu za I. iteraciju

Stručnjaci su imali mogućnost davanja komentara za svaki element, a nove su elemente s kratkim opisom mogli navesti ispod tablice.

Mjerni instrument je definiran i oblikovan kao upitnik putem programa za obradu teksta Microsoft Word te sadrži 29 stranica.

5.2.1.2. Stručna skupina

Za potrebe istraživanja odabrani su stručnjaci koji imaju duboko razumijevanje iz područja arheologije i korištenja digitalnih tehnologija te se može očekivati davanje učinkovitog doprinosa.

Kriteriji za stručnjake su: završen diplomski studij ili doktorat znanosti (kriterij - A), broj godina sudjelovanja na arheološkim istraživanjima, minimalno 10 godina (kriterij - B), znanstveno istraživački rad u području arheologije [Arh-Istr] ili rad na dokumentiranju i zaštiti arheološke građe [DOK] (kriterij - C) te rad s digitalnom tehnologijom (kriterij - D) duži od 5 godina. Vodilo se računa o odabiru stručnjaka iz različitih ustanova u Hrvatskoj koje se aktivno bave istraživanjem u području arheologije [sveučilište, institut, centar ili muzej] (kriterij - E).

Popis izabranih stručnjaka naveden je u Tablici 12. Za svakog je stručnjaka navedena oznaka korištena u istraživanju te ispunjenje kriterija. Planirani broj stručnjaka za I. iteraciju istraživanja bio je 15.

Tablica 12.: Stručna skupina za I. iteraciju

Redni broj	Oznaka stručnjaka	Ispunjenje kriterija				
		A	B (#)	C	D	E
1	*2*	*3*	*4*	*5*	*6*	*7*
1.	IOP01	Da	10	Arh-Istr	Da	Sveučilište
2.	IOP02	Da	10	DOK	Da	Sveučilište
3.	IOP03	Da	10	DOK	Da	Sveučilište
4.	IOP04	Da	30	Arh-Istr	Da	Sveučilište
5.	IOP05	Da	14	Arh-Istr	Da	Muzej
6.	IOP06	Da	15	DOK	Da	Muzej
7.	IOP07	Da	17	Arh-Istr	Da	Sveučilište
8.	IOP08	Da	14	Arh-Istr	Da	Sveučilište
9.	IOP09	Da	20	Arh-Istr	Da	Muzej
10.	IOP10	Da	12	Arh-Istr	Da	Muzej
11.	IOP11	Da	28	Arh-Istr	Da	Institut
12.	IOP12	Da	10	Arh-Istr	Da	Centar
13.	IOP13	Da	26	Arh-Istr	Da	Sveučilište
14.	IOP14	Da	10	Arh-Istr	Da	Muzej
15.	IOP15	Da	10	Arh-Istr	Da	Sveučilište

5.2.1.3. Kriteriji u I. iteraciji

Kroz ovu iteraciju postavljeni cilj je sužavanje broja metapodatkovnih elemenata, kao i nadopuna elementima za koje stručnjaci smatraju da su važni u njihovom radu. Osnovni kriteriji kojima se smanjivao broj metapodatkovnih elemenata je percipiranje metapodatkovnog elementa kvantifikatorom vrlo važan (3) ili esencijalno važan (4) za znanstveno-istraživački rad te njihovom prepoznavanju od strane stručnjaka za više od 50%.

U slučaju utvrđivanja većeg broj metapodatkovnih elemenata koji ne ispunjavaju osnovni kriterij za pojedini objekt istraživanja, provjerit će se u kojoj mjeri preostali metapodatkovni elementi ispunjavaju dodatni kriterij, a to je ispunjenje FAIR načela za pretraživanje i ponovnu uporabu podataka.

5.2.1.4. Rezultati I. iteracije

Stručnoj je skupini mjerni instrument poslan putem elektroničke pošte tijekom travnja 2018. godine, a vraćeni su tijekom svibnja 2018. godine. U istraživanju je sudjelovalo 11 stručnjaka, čime je ispunjen kriterij minimalnog broja stručnjaka prema Delphi metodi.

Pregledom upitnika utvrđeno je da za pojedine entitete i pripadajuće elemente u upitnicima nedostaju podatci koji se odnose na iskazivanje važnosti kvantifikatorom. Broj mogućih podataka i broj dobivenih podataka te postotak dobivenih podataka naveden je u Tablici 13.

U svrhu provjere pouzdanosti mjernog instrumenta, napravljena je provjera interne konzistencije. Za mjeru interne konzistencije uzet je koeficijent Cronbach alpha, a izračuni su napravljeni putem statističkog programa Statistica verzija 13.3. Kod izračuna se vodilo računa o podatcima koji nedostaju[162]. Kod entiteta koji sadrže više od 90% podataka, nadomjestak podataka je napravljen temeljem srednje vrijednosti. Za entitete koji imaju veći broj nedostatnih podataka, brisana je varijabla u kojoj nedostaju podatci.

Tablica 13.: Prikupljeni podatci i interna konzistentnost za I. iteraciju istraživanja

Područje		Entitet	Mogući podatci (#)	Dobiveni podatci (#)	Postotak (%)	Nadomjestak podataka	Cronbach alpha
1		2	3	4	5	6	7
Osnovna struktura		Povijest istraživanja	99	99	100,00%	Ne	0,868671
		Projekt	220	220	100,00%	Ne	0,956739
		Osnovna struktura	726	669	92,15%	Da, srednja vrijednost	0,890028
		Kontekst	44	44	100,00%	Ne	0,814815
Sadržajne stavke	Osnovni sadržaj	Dokumenti i tekstovi	154	154	100,00%	Ne	0,944259
		Publikacije	187	187	100,00%	Ne	0,953731
		Tablice	66	60	90,91%	Da, srednja vrijednost	0,908367
		Baze podataka	66	63	95,45%	Da, srednja vrijednost	0,908367
		Vektorska grafika	77	77	100,00%	Ne	0,701859
		Rasterska grafika	132	132	100,00%	Ne	0,860229
		Digitalni video	121	113	93,39%	Da, srednja vrijednost	0,962500
		Digitalni zvuk	77	71	92,21%	Da, srednja vrijednost	0,734568
	Prikupljanje podataka i terenski rad	Prostorna istraživanja	143	142	99,30%	Da, srednja vrijednost	0,843129
		Istraživanja bespilotnim letjelicama	154	150	97,40%	Da, srednja vrijednost	0,876920
		Geofizička istraživanja	286	284	99,30%	Da, srednja vrijednost	0,971587
		Istraživanja podmorja		0	0,00%	Ne	0,000000
		Lasersko skeniranje	480	308	64,17%	Ne, brisanje varijable	0,970190
		Kronološka istraživanja	352	294	83,52%	Ne, brisanje varijable	0,955232
		CAD	836	631	75,48%	Ne, brisanje varijable	0,949757
		3D modeli	154	112	72,73%	Ne, brisanje varijable	0,821154

[162] Znanstvena istraživanja ukazuju na različite metode nadomještanja podataka.

Koeficijenti Cronbach alpha za svaki entitet iz mjernog instrumenta dani su u Tablici 13., kroz stupac 7. Vrijednosti Cronbach alpha kreću se u rasponu od 0,701859 do 0,970190 što upućuje na dobru pouzdanost mjernog instrumenta.

Rezultati I. iteracije za svaki metapodatkovni element osnovne strukture i sadržajnih stavki prikazani su u Prilozima od 1. do 20. Unutar tablice navedeno je ime elementa (stupac 1.) te su navedeni rezultati za I. iteraciju. Za prvu iteraciju brojčano je navedeno koliko odgovora stručnjaka ispunjava kriterije vrlo važan i esencijalno važan (stupac 5.) kao i postotak prepoznatosti metapodatkovnog elementa od strane stručnjaka (stupac 6.).

OSNOVNA STRUKTURA

Svi elementi povezani uz entitet *povijest istraživanja* ispunjavaju postavljeni osnovni kriterij. Pojedini elementi entiteta *projektna razina* ne ispunjavaju osnovni kriterij. Elementi koji ne ispunjavaju kriterij odnose se na jezik za kreiranje skupa podataka, oznaku skupa podataka, detalji o organizaciji te dijeljenje podataka. Kako je identificiran veći broj elemenata koji ne ispunjavaju osnovni uvjet, primjenom dodatnog uvjeta vezanog uz FAIR načela preostali elementi mogu ispuniti potrebu pretraživanja i ponovne uporabe podataka npr. identifikator projekta, ime projekta, opis, lokacija.

U okviru entiteta *osnovna struktura* elementi koji ne ispunjavaju osnovni kriterij odnose se na podatke o arhivskom identifikatoru, ulozi institucije, a pojedini na podatke o označavanju i zaštiti te administriranju. Za skupinu elemenata Informacija o podvodnom nalazu (brodu), stručnjak IOP10 navodi argumentaciju za izostavljanje, jer ostali skup elemenata može dobro opisati podvodne arheološke entitete. Kroz Prilog 3. tim je elementima pridodana oznaka PR.

Svi elementi entiteta *kontekst* ispunjavaju zadani osnovni kriterij.

SADRŽAJNE STAVKE

Za entitet d*okumenti i tekstovi* od strane stručnjaka nisu prepoznati elementi koji se odnose na: datum povezan uz životni ciklus, identifikator formalnog sustava, element kojim se označava odnos prema srodnom izvoru te element vezan uz vlasnička prava.

Elementi povezani uz serijske brojeve publikacija (ISSN) i jedinstveni broj knjige (ISBN) ne ispunjavaju osnovni kriterij za entitet *publikacija*.

Kod entiteta *tablice* osnovni kriterij ne ispunjavaju elementi koji su povezani uz opis polja, broj stupaca i redaka te dokumentiranost funkcija. Kako se kod ovog entiteta radi o većem broju elemenata koji ne ispunjavaju osnovni kriterij, postojanje entiteta tablice dovedeno je u pitanje. Kako bi se utvrdilo može li se entitet tablice dalje koristiti u istraživanju, primijenjeni su dodatni kriteriji. Preostali elementi mogu ispuniti putem imena, svrhe i sadržaja načelo pronalaska metapodataka, međutim preostali elementi nisu dovoljni za ispunjavanje načela ponovne uporabe podataka. Nedostaju podatci koji se odnose na opise polja i funkcije, bez kojih nije moguće odrediti sadržaj. Entitet tablice nije uključen u daljnji postupak istraživanja.

Svi elementi entiteta *baze podataka* ispunjavaju osnovi kriterij. Elementi podrijetla i objašnjenja korištenih konvencija ne ispunjavaju osnovni kriterij kod entiteta *vektorska grafika*.

Utvrđen je već broj elemenata koji ne ispunjavaju osnovni kriterij kod entiteta *rasterska grafika*. Ti se elementi odnose na ključne riječi, rezoluciju, dimenziju, boje, dubinu boje te uređaj za slikanje. Kako bi se utvrdilo može li se entitet rasterska grafika koristiti dalje u istraživanju, primijenjen je dodatni kriteriji. Preostali elementi npr. ime, opis i lokacija mogu se koristi za ispunjenje uvjeta načela pronalaska metapodataka. Također navedeni se elementi mogu koristiti u svrhu ispunjenja načela ponovne uporabe podataka. Entitet rasterska grafika uzet je u daljnji postupak istraživanja.

Većina elemenata koji su identificirani iz postojećih metapodatkovnih shema ili istraživanja za entitete digitalni video ili digitalni zvuk ne ispunjavaju postavljeni osnovni uvjet. Kod digitalnog videa svega 3 elementa ispunjavaju osnovni uvjet, a kod digitalnog zvuka svega 2 elementa. Za navedene entitete, stručnjaci IOP10 i IOP13 daju argumentaciju o potrebi uvođenja dodatnih elemenata. Dodatni elementi za entitet digitalni video povezani su npr. uz ime videa, autora, autorska prava te vrijeme snimanja, a za digitalni zvuk povezani su uz ime zvučnog zapisa, autora, licencu, vrijeme nastanka i lokaciju čuvanja. U prilozima 11. i 12. dodijeljena im je oznaka nadopuna (NDP). Temeljem novih elemenata omogućeno je ispunjavanje FAIR načela o pretraživanju i ponovnoj uporabi te su entiteti digitalni video i digitalni zvuk uzeti u daljnji postupak istraživanja.

Za entitet *prostorna istraživanja* utvrđeno je da samo element tehnička specifikacija slike ne odgovara postavljenom osnovnom kriteriju, a dobivena je sugestija

od stručnjaka IOP10 o razdvajanju autorskih prava i prava korištenja. Dodan je element licence, u Prilogu 13. elementu je stavljena oznaka nadopuna (NDP).

Elementi povezani uz tehničke karakteristike za snimanje te opis generiranih podataka ne ispunjavaju osnovni kriterij kod entiteta *istraživanje bespilotnim letjelicama*. Provjerom ispunjavaju li preostali elementi dodatni kriterij, utvrđeno je da postojeći elementi npr. ime slike, prostorni podatci te elementi za procesiranje omogućavaju pretraživanje i ponovnu uporabu podataka za entitet istraživanje bespilotnim letjelicama.

Kod entiteta *geofizička istraživanja* svi elementi ispunjavaju osnovni uvjet. Stručnjak IOP10 dao je sugestiju o potrebi uvrštavanja elemenata povezanih uz projekt (npr. ime, opis). Za entitet *istraživanje podmorja* tijekom I. iteracije nije dobivena niti jedna sugestija za novim elementom. Entitet nema definiran niti jedan element, te nije uključen u daljnji tijek istraživanja. U daljnji tijek istraživanja nije uključen niti entitet *lasersko skeniranje* jer osnovni kriterij ispunjava samo devet elemenata povezanih npr. uz ime, opis, lokaciju i datum. Provjerom ispunjavanja dodatnog kriterija postojeći elementi mogu ispuniti kriterij za pretraživanje, ali i ne ponovnu uporabu podataka. Nedostaju elementi povezani uz tehničke i procesne karakteristike.

Osnovni uvjet za entitet *kronološka istraživanja* ne ispunjava samo element povezan uz kategoriju projekta.

Entitet CAD imao je 76 elemenata za istraživanje. Tijekom istraživanja utvrđeno je da 26 elemenata ne ispunjavaju osnovni kriterij. Ti se elementi odnose na opis pravne zaštite podataka te na pojedine elemente iz područja: način prikupljanja podataka istraživanja, podatci o GPS, prethodno snimljeni podatci, dokumentiranje modela i vanjskih baza podataka. Uvođenjem dodatnog kriterija postojeći podatci mogu ispuniti kriterij pronalaženja podataka te u manjoj mjeri ponovne uporabe podataka. Kako je kod otvorenih istraživačkih podataka cilj njihova ponovna uporaba, entitet CAD nije uzet u daljnji postupak istraživanja.

Za entitet 3D modeli samo jedan element i to povezan uz koordinatni sustav ispunjava osnovni uvjet. Stoga entitet nije uzet u daljnji postupak istraživanja.

Skupni rezultati za I. iteraciju prikazani su u Tablici 14. U njoj je naveden pregled područja, entiteta, broj elemenata za I. iteraciju, broj elemenata nakon I. iteracije koji ispunjavaju postavljene uvjete ili su sugerirani od strane stručnjaka te uključenost entiteta u II. iteraciju istraživanja.

Tablica 14.: Identificirani elementi I. iteracije

Područje		Entitet	Elemenati za I. iteraciju (#)	Elementi nakon I. iteracije (#)	Uključenost u II. iteraciju istraživanja
1		2	3	4	5
Osnovna struktura		Povijest istraživanja	9	9	Da
		Projekt	20	11	Da
		Osnovna struktura	66	49	Da
		Kontekst	4	4	Da
Sadržajne stavke	Osnovni sadržaj	Dokumenti i tekstovi	14	10	Da
		Publikacije	17	15	Da
		Tablice	6	3	Ne
		Baze podataka	6	6	Da
		Vektorska grafika	7	5	Da
		Rasterska grafika	12	6	Da
		Digitalni video	11	7	Da
		Digitalni zvuk	7	7	Da
	Prikupljanje podataka i terenski rad	Prostorna istraživanja	13	13	Da
		Istraživanja bespilotnim letjelicama	14	9	Da
		Geofizička istraživanja	26	26	Da
		Istraživanja podmorja	0	0	Ne
		Lasersko skeniranje	28	9	Ne
		Kronološka istraživanja	32	31	Da
		CAD	76	50	Ne
		3D modeli	14	1	Ne
		UKUPNO	**382**	**271**	

U sljedećoj iteraciji u istraživanje neće biti uključeni elementi koji se odnose na entitete: tablice, istraživanje podmorja, lasersko skeniranje, CAD i 3D modeli.

5.2.2. II. iteracija

Ova iteracija slijedi I. iteraciju, a nadalje se daje opis mjernog instrumenta, stručne skupine te ostvarenih rezultata za II. iteraciju. Cilj ove iteracije je dobivanje grupnog mišljenja o važnosti elemenata za pretraživanje i ponovnu uporabu.

5.2.2.1. Mjerni instrument

Za potrebe provedbe II. iteracije istraživanja definiran je novi mjerni instrument. Mjerni instrument za II. iteraciju sastoji se od tri cjeline: uvoda, osnovne strukture i sadržajnih stavki, a pitanja se temelje na rezultatima istraživanja I. iteracije.

U okviru uvoda ukratko je opisano pretraživanje u kontekstu otvorenosti, te uloga metapodataka. Uvodni dio sadrži i opis skale kvantifikatora kojima se iskazuju učestalost korištenja pojedinog elementa u pretraživanju digitalnog objekta kao i za ponovnu uporabu u okviru znanstveno-istraživačkog rada. Kvantifikatori i pridruženi opisi prikazani su u Tablici 15.

Tablica 15.: Skala kvantifikatora za II. iteraciju

Kvantifikator	Opis
1	*2*
1 – nikad	navedeni element nikada ne koristite za pretraživanje digitalnih objekata (npr. arheoloških entiteta, izrađevina, arheoloških podataka) i nije važan za vašu ponovnu uporabu podataka
2 – rijetko	putem navedenog elementa rijetko radite pretraživanje digitalnih objekata (npr. arheoloških entiteta, izrađevina, arheoloških podataka) i vrlo rijetko je važan za ponovnu uporabu podataka
3 – ponekad	putem navedenog elemenata ponekad radite pretraživanje digitalnih objekata (npr. arheoloških entiteta, izrađevina, arheoloških podataka) i ponekad je važan za ponovnu uporabu podataka
4 – često	navedeni element često koristite za pretraživanje digitalnih objekata (npr. arheoloških entiteta, izrađevina, arheoloških podataka) i važan je za ponovnu uporabu podataka
5 – uvijek	navedeni element uvijek koristite za pretraživanje digitalnih objekata (npr. arheoloških entiteta, izrađevina, arheoloških podataka) i presudan je za ponovnu uporabu podataka

Za osnovnu strukturu u obzir su uzeti elementi entiteta povijest istraživanja, projekt, osnovna struktura i kontekst, a kod sadržajnih stavki u daljnji su postupak uključeni elementi entiteta dokumenti i tekstovi, publikacije, baze podataka, vektorska grafika, rasterska grafika, digitalni video, digitalni zvuk, prostorna istraživanja, istraživanje bespilotnim letjelicama, geofizička istraživanja i kronološka istraživanja.

Ukupni broj metapodatkovnih elemenata za II. iteraciju istraživanja bio je 271. Od toga broja 73 metapodatkovna elementa odnosilo se na entitete osnovne strukture, a 198 na entitete sadržajnih stavki.

Za svaki je entitet definirana tablica koja sadrži metapodatkovni element, njegov kratki opis, kvantifikator učestalosti te primjer. Kako mjerni instrument sadrži veći broj entiteta i elemenata, u okviru ovog rada naveden je primjer pitanja. Pitanje se odnosi na entitet povijest istraživanja i pripadajuće metapodatkovne elemente, a prikaz se nalazi na Slici 5.

1.1. Elementi povijesti istraživanja (poveznica primjera ili izvora za primjer: https://doi.org/10.15291/archeo.1181)

Područje	Metapodatkovni element	Kratki opis	Kvantifikator učestalosti					Primjer
			nikad	rijetko	ponekad	Često	uvijek	
			1	2	3	4	5	
-	Ime istraživanja	Ime istraživanja						Neolitički keramički predmeti
	Svrha istraživanja	Kratki opis svrhe						Određivanje funkcije neolitičkih keramičkih predmeta
	Metode	Planirane metode istraživanja						Analiza, Usporedba, Sinteza, Rekonstrukcija
	Vrsta dokumentacije	Vrsta dokumentacije koje nastaje istraživanjem						Crteži, Model, Članak
	Planirana lokacija istraživanja	Županija, Općina, Mjesto, Adresa						Zadarska, Smilčić
	Kronološki period i razdoblje	Pripadnost kronološkom razdoblju i periodu						Neolitik (6500-3500 g. pr. Kr.)
	Istraživač	Glavni istraživač, voditelj istraživanja						Brunislav Marijanović
	Godina	Godina ili vremenski interval istraživanja						2015
	Izvor	Važni prethodni izvori (resursi) na temelju koji nastaje ovaj projekt						Keramički predmeti (inv. broj P12319), nalazi iz Platie Magoula Zarkou, Topolnice

Slika 5.: Primjer pitanja u mjernom instrumentu za II. iteraciju

Sadržajna valjanost mjernog instrumenta provjerena je od strane stručnjaka iz područja arheologije s obzirom na sadržaj pitanja, te stručnjaka iz područja informacijskih znanosti s obzirom na razumijevanje sadržaja. U svrhu bolje predodžbe pitanja i elementa, za svaki je element definiran primjer. Primjer za element proizlazi iz stvarnih arheoloških entiteta i njegove moguće realizacije u okviru digitalnog repozitorija. Uz ime svakog entiteta navedena je i poveznica na izvor sadržaja za primjer.

5.2.2.2. Stručna skupina

Stručna skupina za II. iteraciju istraživanja uvjetovana je Delphi metodom. Delphi metoda zahtijeva da minimalno 70% stručnjaka mora ostati u postupku istraživanja po pojedinoj iteraciji. Ovaj uvjet je definiran kao dodatni kriterij te je u okviru tablice prikazan kroz stupac F, a pridružena je oznaka „✓“ za stručnjake koji su sudjelovali u I.

iteraciji. Stručna skupina za II. krug istraživanja prikazana je Tablicom 16. Kriteriji koji su primijenjeni istovjetni su kriterijima za stručnjake iz I. iteracije istraživanja.

Tablica 16.: Stručna skupina za II. iteraciju istraživanja

Redni broj	Oznaka stručnjaka	Ispunjenje kriterija					
		A	B (#)	C	D	E	F
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*
1.	IOP01	Da	10	Arh-Istr	Da	Sveučilište	✓
2.	IOP02	Da	10	DOK	Da	Sveučilište	✓
3.	IOP03	Da	10	DOK	Da	Sveučilište	✓
4.	IOP04	Da	30	Arh-Istr	Da	Sveučilište	✓
5.	IOP05	Da	14	Arh-Istr	Da	Muzej	✓
6.	IOP06	Da	15	DOK	Da	Muzej	✓
7.	IOP07	Da	17	Arh-Istr	Da	Sveučilište	-
8.	IOP08	Da	14	Arh-Istr	Da	Sveučilište	-
9.	IOP09	Da	20	Arh-Istr	Da	Muzej	✓
10.	IOP10	Da	12	Arh-Istr	Da	Muzej	✓
11.	IOP11	Da	28	Arh-Istr	Da	Institut	-
12.	IOP12	Da	10	Arh-Istr	Da	Centar	✓
13.	IOP13	Da	26	Arh-Istr	Da	Sveučilište	✓
14.	IOP14	Da	10	Arh-Istr	Da	Muzej	-
15.	IOP15	Da	10	Arh-Istr	Da	Sveučilište	✓
16.	IOP16	Da	10	Arh-Istr	Da	Institut	-

5.2.2.3. Kriteriji II. iteracije

Ova iteracija nema definirane kriterije temeljem kojih bi se provodilo sužavanje pojedinih metapodatkovnih elemenata.

5.2.2.4. Rezultati II. iteracije

Mjerni instrument poslan je stručnoj skupini putem elektroničke pošte krajem studenog 2018. godine. Stručnjaci su mjerni instrument vratili tijekom prosinca 2018. godine i siječnja 2019. godine. Ukupno je vraćeno 12 ispunjenih mjernih instrumenata, s time da

je od navedenog broja 10 vraćeno od stručnjaka koji su sudjelovali u I. iteraciji. Ovime su ispunjeni kriteriji potrebnog broja stručnjaka te broja stalnih stručnjaka po pojedinoj iteraciji.

Pregledom upitnika utvrđeno je da za pojedine entitete i pripadajuće elemente u upitnicima nedostaju podatci koji se odnose na iskazivanje važnosti kvantifikatorom. Broj mogućih podataka i broj dobivenih podataka, te postotak dobivenih podataka naveden je u Tablici 17. Provjera pouzdanosti mjernog instrumenta napravljena je temeljem mjera i postupaka iz I. iteracije. Vrijednosti koeficijenta Cronbach alphe za pojedini entitet navedeni su u Tablici 17.

Tablica 17.: Prikupljeni podatci i interna konzistentnost za II. iteraciju istraživanja

Područje		Entitet	Mogući podatci (#)	Dobiveni podatci (#)	Postotak (%)	Nadomjestak podataka	Cronbach alpha
1		2	3	4	5	6	7
Osnovna struktura		Povijest istraživanja	108	108	100,00%	Ne	0,873382
		Projekt	132	132	100,00%	Ne	0,887392
		Osnovna struktura	588	588	100,00%	Ne	0,949197
		Kontekst	48	48	100,00%	Ne	0,730072
Sadržajne stavke	Osnovni sadržaj	Dokumenti i tekstovi	120	120	100,00%	Ne	0,873048
		Publikacije	180	180	100,00%	Ne	0,937737
		Baze podataka	72	66	91,67%	Ne, brisanje varijable	0,914137
		Vektorska grafika	60	60	100,00%	Ne	0,364345
		Rasterska grafika	72	72	100,00%	Ne	0,859958
		Digitalni video	84	84	100,00%	Ne	0,827676
		Digitalni zvuk	84	84	100,00%	Ne	0,913002
	Prikupljanje podataka i terenski rad	Prostorna istraživanja	156	156	100,00%	Ne	0,860722
		Istraživanja bespilotnim letjelicama	108	104	96,30%	Ne, brisanje varijable	0,923620
		Geofizička istraživanja	312	305	97,76%	Ne, brisanje varijable	0,988029
		Kronološka istraživanja	372	354	95,16%	Ne, brisanje varijable	0,985011

Vrijednosti Cronbach alpha kreću se u rasponu od 0,730072 do 0,988029 što upućuje na dobru pouzdanost mjernog instrumenta, osim kod entiteta vektorska grafika kod kojeg je utvrđena vrijednost Cronbach alphe od 0,364345. Entitet vektorska grafika i pripadajući metapodatkovni elementi nisu uključeni u daljnji postupak istraživanja.

Istraživanja pokazuju da se za povratnu informaciju stručnjacima u iteracijama najčešće koristi centralna vrijednost i vrijednost sa najvećom frekvencijom pojavljivanja (Ameyaw *et al.*, 2016).

Centralna vrijednost (medijan) za svaki metapodatkovni element prikazana je u stupcu 7. u Prilozima od 1. do 20.

5.2.3. III. iteracija

Ovo je završna iteracija Delphi istraživanja. U nastavku je naveden opis mjernog instrumenta, stručne skupine te ostvarenih rezultata za III. iteraciju. Cilj ove iteracije je utvrđivanje ostvarenog konsenzusa o metapodatkovnim elementima pojedinih entiteta.

5.2.3.1. Mjerni instrument

Za potrebe provedbe III. iteracije istraživanja koristi se modificirani mjerni instrument iz II. iteracije koji se sastoji od tri cjeline: uvoda, osnovne strukture i sadržajnih stavki. U okviru uvoda ukratko su opisani dosadašnji rezultati istraživanja, ukratko je opisan pojam konsenzusa, navedeni su kvantifikatori i njihov opis.

Za svaki je entitet definirana tablica koja sadrži metapodatkovni element, njegov kratki opis, primjer, centralnu vrijednost te odgovor stručnjaka iz II. iteracije. Kako mjerni instrument sadrži veći broj entiteta i elemenata, navodi se primjer pitanja.

Pitanje se odnosi na entitet povijest istraživanja i pripadajuće metapodatkovne elemente, a prikazano je na Slici 6.

Područje	Metapodatkovni element / Opis	Kratki opis	*Centralna vrijednost (eksperti)*	**Vaša procjena iz II. kruga**	**Završna procjena** (centralna vrijednosti ili Vaša procjena)	Primjer
-	Ime istraživanja	Ime istraživanja	**5**	**5**		Neolitički keramički predmeti
	Svrha istraživanja	Kratki opis svrhe	**3**	**2**		Određivanje funkcije neolitičkih keramičkih predmeta
	Metode	Planirane metode istraživanja	**3**	**4**		Analiza, Usporedba, Sinteza, Rekonstrukcija
	Vrsta dokumentacije	Vrsta dokumentacije koje nastaje istraživanjem	**3**	**4**		Crteži, Model, Članak
	Planirana lokacija istraživanja	Županija, Općina, Mjesto, Adresa	**4,5**	**5**		Zadarska, Smilčić
	Kronološki period i razdoblje	Pripadnost kronološkom razdoblju i periodu	**4,5**	**5**		Neolitik (6500-3500 g. pr. Kr.)
	Istraživač	Glavni istraživač, voditelj istraživanja	**4**	**5**		Brunislav Marijanović
	Godina	Godina ili vremenski interval istraživanja	**3,5**	**5**		2015
	Izvor	Važni prethodni izvori (resursi) na temelju koji nastaje ovaj projekt	**3**	**3**		Keramički predmeti (inv. broj P12319), nalazi iz Platie Magoula Zarkou, Topolnice

Slika 6.: Primjer pitanja u mjernom instrumentu za III. iteraciju

5.2.3.2. Stručna skupina

Stručna skupina za III. iteraciju sastoji se od članova koji su dali odgovor u okviru II. iteracije istraživanja. Kriteriji za sudjelovanje ispunjeni su već u prethodnim iteracijama i nisu posebno prikazani. Stručna skupina za III. krug sastoji se od sljedećih stručnjaka:

IOP01, IOP02, IOP03, IOP04, IOP05, IOP06, IOP09, IOP10, IOP12, IOP13, IOP15 i IOP16.

5.2.3.3. Kriteriji III. iteracije

U okviru ovog istraživanja koristi se Likertova ljestvica s 5 kategorija. Kako su podatci iz Likertove ljestvice ordinalni podatci, u svrhu utvrđivanja konsenzusa (Kns) kod pojedinog elementa koristi se Tastle i Wiermanova metrika Konsenzus (Cns). Ostvarenje konsenzusa primjenom Likertove ljestvice i ordinalnih podataka, konsenzus je opisan kao sporazum prema deklarativnoj izjavi pojedinca iz istraživačkog uzorka (Tastle i Wierman, 2007). Prema ovom opisu puni je konsenzus (Kns = 1) postignut ukoliko svi sudionici odaberu istu kategoriju iz Likertove ljestvice, a nema uopće konsenzusa (Kns = 0) ukoliko jednak broj sudionika za svoj odgovor odabere dvije ekstremne kategorije iz Likertove ljestvice. Ostale kombinacije odgovora sudionika rezultiraju vrijednošću konsenzusa u intervalu $[0,1]$.

Metrika Konsenzus definirana je sljedećim matematičkim izrazom:

$$Cns(X) = 1 + \sum_{i=1}^{n} p_i log_2\left(1 - \frac{|x_i - \mu_X|}{d_x}\right)$$

Jednadžba 1.: Metrika Konsenzus *Cns (X)*

pri čemu je X odgovor, n je broj kategorija s ordinalne ljestvice, x_i je stupanj slaganja u kategoriji i, p_i je vjerojatnost pojave od x_i; $dx=x_{max}-x_{min}$ je širina kategorija mjerne ljestvice, u_x je srednja vrijednost ukupnog slaganja. U okviru ovog istraživanja $n = 5$, i je u rangu od 1 do 5 i $d_x = 5 – 1 = 4$. Metrikom Cns (X) moguće je izračunati konsenzus za bilo koju kategoriju, a postoji ograničenje ukoliko je usredotočenost na krajnjim kategorijama.

U okviru ovog istraživanja kvantifikatorima *često (4)* i *uvijek (5)* iskazuje se važnost metapodatkovnih elemenata u kontekstu pretraživanja i ponovne uporabe podataka. Usmjerenost je na kategoriju *uvijek (5)* i ostvarenje konsenzusa uz ovu kategoriju.

Varijacijom metrike Cns(X) Tastle i Tastle (Tastle i Tastle, 2006), proširuju d_x, na $2(d_x)$, a μ_x zamjenjuju sa stalnom kategorijom[163]. Ove promjene omogućavaju izračun snage konsenzusa i pokazuju nam koliko su podatci raspršeni u odnosu na stalnu kategoriju. Snaga Konsenzusa sCns(X) dana je sljedećim matematičkim izrazom:

$$sCns(X) = 1 + \sum_{i=1}^{n} p_i log_2 \left(1 - \frac{|X_i - 5|}{2d_x}\right)$$

Jednadžba 2.: Snaga Konsenzusa Cns (x)

Iz istraživanja je vidljivo da nema opće prihvaćene vrijednosti temeljem koje se ostvaruje konsenzus. U istraživanju o ostvarenju konsenzusa Landis i Koch definiraju ljestvicu kojom se iskazuje jačina ostvarenja konsenzusa (Landis i Koch, 1977). Ljestvica ima šest kategorija konsenzusa: „skoro savršen“ (0,81-1,00), „znatan“ (0,61-0,80), „umjeren“ (0,41-0,60), „primjetan“ (0,21-0,40), „blag“ (0,00-0,20), „nikakav“ (<0,00). U istraživanjima je u primjeni i ljestvica sa tri kategorije: „nije za primjenu“ (<0,40), „prihvatljiva“ (0,41-0,60), „odgovarajuća ili izvrsna“ (0,75≤) (Schaer, 2012).

Opća statistička mjera konsenzusa između promatrača Krippendorff alpha (α), ima vrijednosti ostvarenja konsenzusa u intervalu od [0,1], gdje je 1 potpuni konsenzus. Najčešće se smatra da je konsenzus ostvaren ukoliko je vrijednost koeficijenta α > 0,80, a kao najniža donja prihvatljiva granica uspostavljena je na α ≥ 0,667 (Krippendorff, 2004).

U okviru istraživanja o metrici Konsenzus Tasle i Wierman ne navode kategorije niti mjere za iskazivanje jačine ostvarenja konsenzusa. Iz primjene metrike Konsenzus u okvirima znanstvenih istraživanja identificirano je sljedeće:

- primjenom ove metrike u istraživanju s Delphi metodom za donju granicu ostvarivanja konsenzusa definirana je vrijednost od 0,75 (Howard *et al.*, 2018)
- u istraživanju o jačini ostvarenja konsenzusa temeljem Likertove skale s 5 kategorija identificirane su dvije ljestvice. Prva je ljestvica s tri kategorije:

[163] Stalna kategorija u okviru ove iteracije je uvijek (5).

„dobar“ (0,4-0,49), „uvjerljiv“ (0,5-0,7), „nadmoćan“ (0,7-1,0) (Lopez, Mazzuci i Sarkani, 2014), a druga ljestvica ima sedam kategorija „vrlo jako neslaganje“ (≤0,09), „jako neslaganje“ (0,10-0,19), „umjereno neslaganje“ (0,20-0,39), „ravnoteža“ (0,40-0,59), „umjereni konsenzus“ (0,60-0,79), „jaki konsenzus“ (0,80-0,88), „vrlo jaki konsenzus“ (0,90≥) (Hein, Kroenke i Rodrigues Junior, 2015)

- istraživanja (Biel i Gatica-Perez, 2013), (Snyder, 2010) definiraju donju granicu ostvarivanja konsenzusa na vrijednost od 0,80.

U nastavku je istraživanja kao donja granica za ostvarivanje konsenzusa kod metrike Konsenzus Cns(X) definirana vrijednost 0,80. Donja granica prihvatljivosti za snagu Konsenzusa sCns(X) uz stalnu kategoriju uvijek (5) definirana je vrijednost 0,80.

5.2.3.4. Rezultati III. iteracije

Mjerni instrument u obliku tekstualnog dokumenta poslan je putem elektroničke pošte stručnoj skupini tijekom veljače 2019. godine, a rezultate su stručnjaci poslali tijekom veljače i ožujka 2019. godine. Vraćeno je 11 ispunjenih mjernih instrumenata od strane stručnjaka. Svih 11 stručnjaka je sudjelovalo i u II. iteraciji. Ispunjeni su kriteriji potrebnog broja stručnjaka, kao i potrebnog broja stalnih stručnjaka koji moraju sudjelovati po pojedinoj iteraciji.

Pregledom upitnika utvrđeno je da su za sve entitete i pripadajuće elemente stručnjaci evidentirali podatke. Provjera pouzdanosti mjernog instrumenta napravljena je temeljem mjera i postupka iz I. iteracije. Vrijednosti koeficijenta Cronbach alphe za pojedini entitet navedene su u okviru Tablice 18.

Vrijednosti Cronbach alpha kreću se u rasponu od 0,649906 do 0,979209 što upućuje na prihvatljivu i dobru pouzdanost mjernog instrumenta.

Izračuni konsenzusa za svaki metapodatkovni element napravljeni su temeljem metrike Konsenzus Cns(X) i snage Konsenzusa sCns(X) putem programa Excel. Za svaki metapodatkovni element vrijednosti Cns(X) i sCns(X) prikazane su u stupcima 8. i 9. u Prilogu 1. do 20.

Tablica 18.: Prikupljeni podatci i interna konzistentnost za III. iteraciju istraživanja

Područje		Entitet	Mogući podatci (#)	Dobiveni podatci (#)	Postotak (%)	Nadomjestak podataka	Cronbach alpha
1		2	3	4	5	6	7
Osnovna struktura		Povijest istraživanja	99	99	100,00%	Ne	0,869147
		Projekt	121	121	100,00%	Ne	0,824498
		Osnovna struktura	539	539	100,00%	Ne	0,940099
		Kontekst	44	44	100,00%	Ne	0,794118
Sadržajne stavke	Osnovni sadržaj	Dokumenti i tekstovi	110	110	100,00%	Ne	0,908016
		Publikacije	165	165	100,00%	Ne	0,920849
		Baze podataka	66	66	100,00%	Ne	0,908539
		Rasterska grafika	66	66	100,00%	Ne	0,877673
		Digitalni video	77	77	100,00%	Ne	0,649906
		Digitalni zvuk	77	77	100,00%	Ne	0,904417
	Prikupljanje podataka i terenski rad	Prostorna istraživanja	143	143	100,00%	Ne	0,822492
		Istraživanja bespilotnim letjelicama	99	99	100,00%	Ne	0,909890
		Geofizička istraživanja	286	286	100,00%	Ne	0,979209
		Kronološka istraživanja	341	341	100,00%	Ne	0,977595

Za daljnji tijek istraživanja kvalificiran je svaki metapodatkovni element kod kojega je sCns(X) > 0,80. Broj metapodatkovnih elemenata koji ispunjavaju ovaj uvjet naveden je u Tablici 19.

Tablica 19.: Metapodatkovni elementi s ostvarenim konsenzusom

Područje		Entitet	Elementi (#)
1		2	3
Osnovna struktura		Povijest istraživanja	4
		Projekt	2
		Osnovna struktura	11
		Kontekst	2
Sadržajne stavke	Osnovni sadržaj	Dokumenti i tekstovi	0
		Publikacije	1
		Baze podataka	1
		Rasterska grafika	1
		Digitalni video	1
		Digitalni zvuk	1
	Prikupljanje podataka i terenski rad	Prostorna istraživanja	1
		Istraživanja bespilotnim letjelicama	1
		Geofizička istraživanja	2
		Kronološka istraživanja	2

Najveći broj konsenzusa ostvaren je kod entiteta osnovna struktura, a mali broj konsenzusa ostvaren je kod sadržajnih stavki.

Usporedimo li dobivene brojeve metapodatkovnih elemenata s ostvarenim konsenzusom i polaznim brojevima metapodatkovnih elemenata, kod osnovne strukture imamo prepoznatost 19,19 % metapodatkovnih elemenata kao važnih, a kod sadržajnih stavki svega 3,88 %.

5.2.4. Zaključno razmatranje

U svrhu utvrđivanja važnih metapodatkovnih elemenata za opisivanje i pretraživanje arheoloških entiteta za stručnjake iz područja arheologije u Hrvatskoj u kontekstu otvorenih istraživačkih podataka primijenjena je Delphi metoda. Delphi metoda u okviru ovog istraživanja provedena je uz pomoć stručnjaka iz područja arheologije i tri iteracije.

Cilj prve iteracije bilo je utvrđivanje važnih metapodatkovnih elemenata za digitalni objekt, a koji su potrebni stručnjacima za znanstveni i stručni rad. U obzir su uzeti metapodatkovni elementi utvrđeni u okviru pregleda znanstvenih istraživanja i postojećih metapodatkovnih shema. Za procjenu stručnjacima uključeno je 382 elementa, od čega se 99 elementa odnosilo na entitete osnovne strukture, a 283 elementa na entitete sadržajnih stavki. U okviru prve iteracije sudjelovalo je 11 stručnjaka. Provedenom procjenom stručnjaka i primjenom postavljenih kriterija utvrđen je 271 važan metapodatkovni element. Metapodatkovni elementi entiteta: tablice, istraživanje podmorja, lasersko skeniranje, CAD i 3D modeli nisu ispunili postavljene kriterije te nisu uključeni u drugu iteraciju.

Druga je iteracija usmjerena na dobivanje mišljenja o važnosti pojedinog metapodatkovnog elementa u svrhu pretraživanja i ponovne uporabe digitalnog objekta. U okviru ove iteracije sudjelovalo je 12 stručnjaka. Prikupljanjem podataka i njihovom obradom utvrđeno je da entitet vektorska grafika ne ispunjava minimalnu vrijednost pokazatelja interne konzistentnosti te nije uključen u daljnji postupak istraživanja. Za svaki metapodatkovni element izračunata je centralna vrijednost u svrhu osiguravanja povratne informacije prema stručnjacima o grupnom mišljenju.

U trećem krugu cilj je bio ostvariti konsenzus stručnjaka vezan uz metapodatkovne elemente bitne kod pretraživanja digitalnih objekta i njihove ponovne uporabe. Za mjeru ostvarenja konsenzusa uzeta je metrika snaga konsenzusa sCns (X), a kao donja granica ostvarenja konsenzusa stavljena je vrijednost 0,80 uz stalnu kategoriju procjene *uvijek (5)*.

Konsenzus je postignut kod sljedećih entiteta i metapodatkovnih elemenata:

- povijest istraživanja – *ime istraživanja; planirana lokacija istraživanja; kronološki period i razdoblje; istraživač*
- projekt – *ime projekta; lokacija projekta*
- osnovna struktura – *ime; ključne riječi; lokacija (geografsko ime prostora); lokacija (mjesto); ime nalazišta; tip objekta; vrsta materijala; kulturno razdoblje; uža kulturna odrednica; vremensko razdoblje; stoljeće*
- kontekst – *referenca mjesta otkrića; stratigrafska jedinica*
- publikacije – *naslov*
- baze podataka – *svrha i sadržaj baze*
- rasterska grafika – *ime slike*
- digitalni video – *ime videa*
- digitalni zvuk – *ime zvučnog zapisa*
- prostorna istraživanja – *predmet*
- istraživanja bespilotnim letjelicama – *prostor*
- geofizička istraživanja – *geološki kontekst; stanje tla*
- kronološka istraživanja – *ime projekta, vrsta uzorka*.

Metapodatkovni elementi nisu utvrđeni kod sljedećih entiteta: dokumenti i tekstovi, tablice, vektorska grafika, istraživanje podmorja, lasersko skeniranje, GIS, CAD, 3D modeli.

Usporedimo li entitete i metapodatke s ostvarenim konsenzusom u odnosu na FAIR načela za otvorene istraživačke podatke, onda samo osnovna struktura kao cijelo područje s entitetima povijest istraživanja, projekt, osnovna struktura i kontekst može ispuniti uspostavljena načela. Od strane stručnjaka u njihovom znanstveno-istraživačkom radu nisu prepoznati važni metapodatkovni elementi kao što su jedinstveni identifikatori, niti elementi povezani uz autorska prava i licence. Elemente osnovne strukture možemo

povezati uz opis istraživačkog sadržaja. Na razini svih sadržajnih stavki uz istraživački sadržaj možemo povezati element ime.

U nastavku istraživanja temelj za izradu aplikacijskog profila bit će metapodatkovni elementi područja osnovna struktura, a od sadržajnih stavki u obzir će biti uzet element ime.

Ovom fazom dani su odgovori na RQ2.

5.3. Modeliranje aplikacijskog profila

Općenito se izrada aplikacijskog profila sastoji od definiranja funkcionalnih zahtjeva, opisa zahtjeva i njihovog prikaza te identifikacije i opisa elemenata. Zahtjevi su već jednim dijelom prethodno utvrđeni i definirani te su dani iz dvije perspektive: perspektive izvornog istraživača i njegovog prikupljanja, analize te očuvanja istraživačkih podataka, te perspektive istraživača korisnika, njegovog pronalaženja, preuzimanja i ponovne uporabe podatka u istraživanjima. Za prethodno navedene korisničke zahtjeve bitni su entiteti i metapodatci koji su istraženi i utvrđeni u prethodnoj cjelini. Aplikacijskim profilom opisujemo digitalni objekt čija se konkretna realizacija ostvaruje u okviru istraživačkog podatkovnog repozitorija kojem pristupaju i s njim rade izvorni istraživač i istraživač korisnik. Kako bi digitalni objekt mogao biti korišten u znanstveno-istraživačke aktivnosti, aplikacijski profil mora sadržavati metapodatkovne elemente kojima se može napraviti jednoznačna i trajna identifikacija digitalnog objekta, omogućiti njegovo pronalaženje i citiranje u digitalnom okruženju te uvidjeti na koji se način digitalni objekt i pripadajući podatci mogu koristiti dalje u okvirima znanstvenog istraživanja.

U nastavku će biti detaljnije istraženi i opisani pojedini funkcionalni zahtjevi i pripadajući metapodatkovni elementi koji su bitni za istraživački ciklus, objedinit će se svi identificirani metapodatkovni elementi te na temelju njih izraditi aplikacijski profil. Aplikacijski profil biti će prikazan putem XML dokumenta i Scheme.

5.3.1. Funkcionalni zahtjevi

Funkcionalne zahtjeve u kontekstu otvorenih istraživačkih podataka analiziramo u tri temeljna funkcionalna zahtjeva. Prvi se zahtjev odnosi na opis arheološkog entiteta, arheološkog zapisa i kreiranje digitalnog objekata. Drugi zahtjev odnosi se na otkrivanje i pretraživanje digitalnog objekata. Treći se zahtjev odnosi na dijeljenje i ponovnu uporabu podataka. Temeljni funkcionalni zahtjevi, njihovi opisi i povezanost na utvrđene metapodatke biti će prikazani u Tablici 20.

Tablica 20.: Povezanost funkcionalnih zahtjeva za aplikacijski profil i utvrđenih metapodatkovnih elemenata

Temeljni funkcionalni zahtjev	Opis	Povezanost	
		Primarna	Dopunska
1	*2*	*3*	*4*
Kreiranje digitalnog objekta	- evidentiranje povijesti istraživanja i projekta	5.2.4.	5.1.1. i 5.1.2.
	- evidentiranje i opisivanje tehnoloških, funkcionalnih, morfoloških i stilističkih svojstva	5.2.4.	5.1.3. i 5.1.5.
	- evidentiranje i opisivanje konteksta	5.2.4.	5.1.4.
	- evidentiranje autora i organizacije	5.2.4.	5.1.3.
	- evidentiranje i opisivanje različitih sadržajnih stavki	5.2.4.	5.1.5.
	- evidentiranje i opisivanje različitih vrsta pojavnih oblika te razina evidentiranja	sadržajne stavke, razina datoteke	-
Otkrivanje i pronalaženje objekta	- pretraživanje i pronalazak objekta od strane čovjeka i stroja	5.2.4., 4.4., 4.2.5. (citiranje)	-
	- pronalaženje temeljem selekcijskih elemenata (npr. naziv, geografska referenca)	5.2.4.	-
	- određivanje relevantnih digitalnih objekata	5.2.4.	-
Dijeljenje i ponovna uporaba podataka	- prava čitljiva od strane korisnika i od strane strojeva	3.3., 5.1.3.	-
	- označavanje načina pristupa i korištenja	5.1.3.	-

.

Identificirano je 11 funkcionalnih zahtjeva. Zahtjevi su povezani uz postojeće rezultate iz istraživanja u okviru ovog rada. Definirana su dva tipa povezanosti. Primarna povezanost se odnosi na metapodatkovne elemente koji su utvrđeni temeljem istraživanja sa stručnjacima ili proizlaze iz znanstvenih istraživanja iz specifičnih područja (npr. citiranje, autorska prava). Dopunska povezanost se odnosi na segmente kreiranja digitalnog objekta, gdje se osim evidentiranja metapodatkovnih elemenata radi i evidentiranje ostalih svojstava arheoloških entiteta.

5.3.2. Modeliranje domene

Definiranu funkcionalnu specifikaciju u okviru pod poglavlja 5.3.1. konceptualiziramo u dva dijela. Prvi se dio odnosi na konceptualizaciju u kontekstu kreiranja digitalnog objekta u području arheologije, drugi dio se odnosi na konceptualizaciju digitalnog objekta koji je rezultat znanstveno-istraživačkih aktivnosti i evidentiranja istraživačkih metapodataka te na omogućavanje dijeljenja i ponovne uporabe podataka.

Konceptualizacija u kontekstu kreiranja digitalnog objekta temelji se na opisima u okviru pod poglavlja 2.1., 2.2.2. i 4.1.1. i prikazana je na Slici 7.

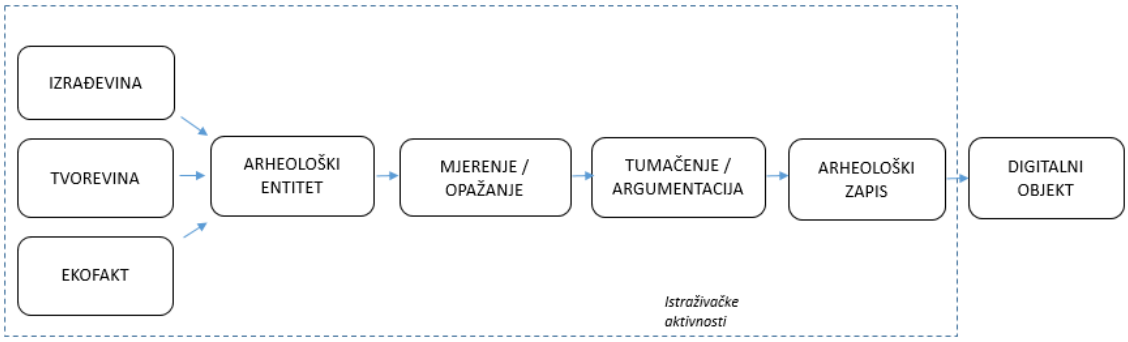

Slika 7.: Konceptualni model kreiranja digitalnog objekta

Iz arheoloških istraživačkih aktivnosti proizlaze izrađevine, tvorevine i ekofakti. Njihovom apstrakcijom nastaje trajni arheološki entitet koji ima svoje atribute i vrijednosti. Istraživač tijekom istraživanja provodi mjerenja i opažanja entiteta te daje njihovo tumačenje i argumentaciju. Nadalje provodi opisivanje i prikazivanje putem arheološkog zapisa. Arheološki zapis može biti realiziran kroz skup podataka, tekst, sliku

itd. Realizacijom arheološkog zapisa u digitalnom okruženju nastaje digitalni objekt. Digitalni objekt opisan je metapodatcima i namijenjen je širem krugu korisnika.

Model domene na razini znanstveno-istraživačkih aktivnosti i digitalnog objekta temelji se na entitetima FRBR koji karakteriziraju digitalni objekt. U okviru ovog rada imamo sljedeće entitete: *istraživački rad, izraz, pojavni oblik, digitalnu jedinicu i činitelja*. Istraživački rad je izrazito intelektualna i istraživačka stvaralačka aktivnost. On je apstraktni entitet, ali konkretiziran kroz izraz. Izraz je realizacija entiteta istraživački rad u obliku skupa istraživačkih podatka. Svaka promjena sadržaja istraživačkog skupa podataka stvara novi izraz. Entitet pojavni oblik je konkretno digitalno ostvarenje entiteta izraz. Pojavni oblik označava različite digitalne verzije izraza stvorenog tijekom životnog ciklusa, njegove različite jezične verzije kao i različite sastavne dijelove. Digitalna jedinica odnosi se na primjer pojavnog oblika, značajke digitalnog objekta i njegovu lokaciju. Prethodni opis dan je kroz primjer i prikazan na Slici 8.

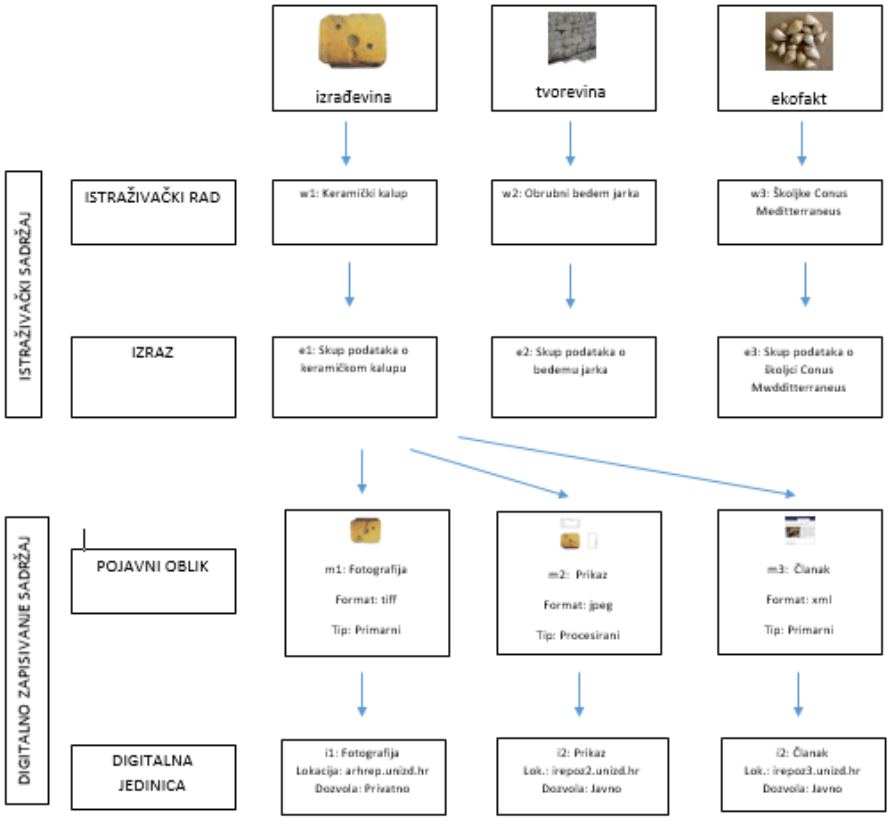

Slika 8.: Konceptualni model digitalnog objekta pomoću FRBR

Istraživački sadržaj obuhvaća entitete istraživački rad, izraz i činitelj, a entitete pojavni oblik i digitalnu jedinicu povezujemo uz digitalno zapisivanje sadržaja.

Činitelj je osoba (ili skup osoba) ili organizacija koja tijekom znanstvenog istraživačkog ciklusa utječe na digitalni objekt kroz njegovo stvaranje, validaciju i objavu. U kontekstu otvorenih istraživačkih podataka važan entitet je i istraživač (širi krug korisnika). Istraživač pristupa digitalnoj jedinici i ima mogućnost provjere dostupnosti. Po utvrđivanju dostupnosti slijedi provjera uporabljivosti i svrsishodnosti. Model domene dan je kroz model entitet i veza, izrađen je prema modelima danim u okviru radova (Carlyle, 2006) (Žumer, Zeng i Salaba, 2010), a njegova prilagođena inačica prikazana je na Slici 9.

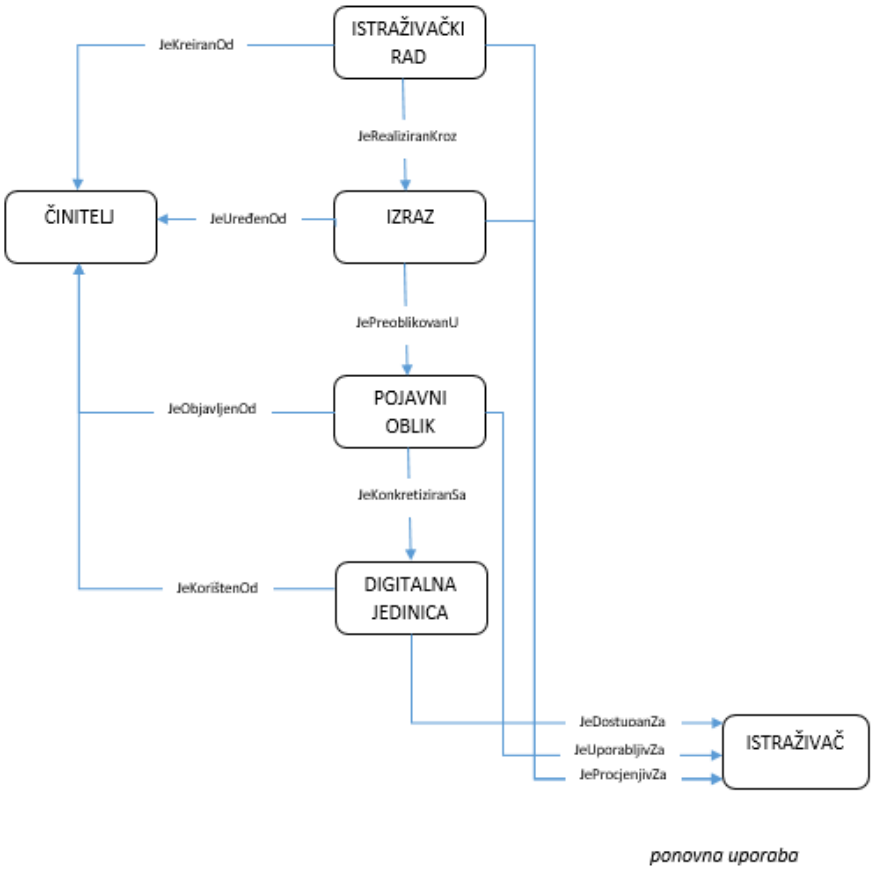

Slika 9.: Model domene aplikacijskog profila

Entiteti istraživački rad i izraz prezentiraju sadržaj koji proizlazi iz istraživačkih aktivnosti, a kreirani su od autora ili su objavljeni od organizacije. Metapodatke za ove entitete povezujemo uz metapodatke koji su utvrđeni u okviru poglavlja 5.2. za osnovnu

strukturu. Na razini entiteta pojavni oblik i digitalna jedinica od strane stručnjaka je postignuti konsenzus oko metapodatkovnog elementa ime. Metapodatkovni elementi koji se odnose na pojavni oblik i digitalnu jedinicu nisu prepoznati od strane stručnjaka, te je za aplikacijski profil uzeti minimalni skup elemenata kojima se može opisati pojedini entitet. Izvori elemenata entiteta su metapodatkovni elementi na razini datoteke, elementi za citiranje, elementi povezani uz pravo te elementi iz istraživanja (Chen, Lin i Chen, 2005), (Madison *et al.*, 2009). Elementi su prilagođeni prema digitalnom objektu i njegovom okruženju te kontekstu rada. Kod pojavnog oblika u obzir su uzeti elementi: ime pojavnog oblika, format, inačica, datum pojavnosti, jezik i organizacija, a za digitalnu jedinicu: ime jedinice, pravne informacije, prava pristupa i lokacija.

Konkretniji prikaz pojedinih entiteta i veza aplikacijskog profila dan je na Slici 10. Osnovni entitet je osnovna struktura koji može biti opisan sa više entiteta povijesti istraživanja, pripada jednom projektu, može biti kreiran od više činitelja (autora, organizacija) i ima samo jedan kontekst. Svi ovi entiteti pripadaju istraživačkom sadržaju.

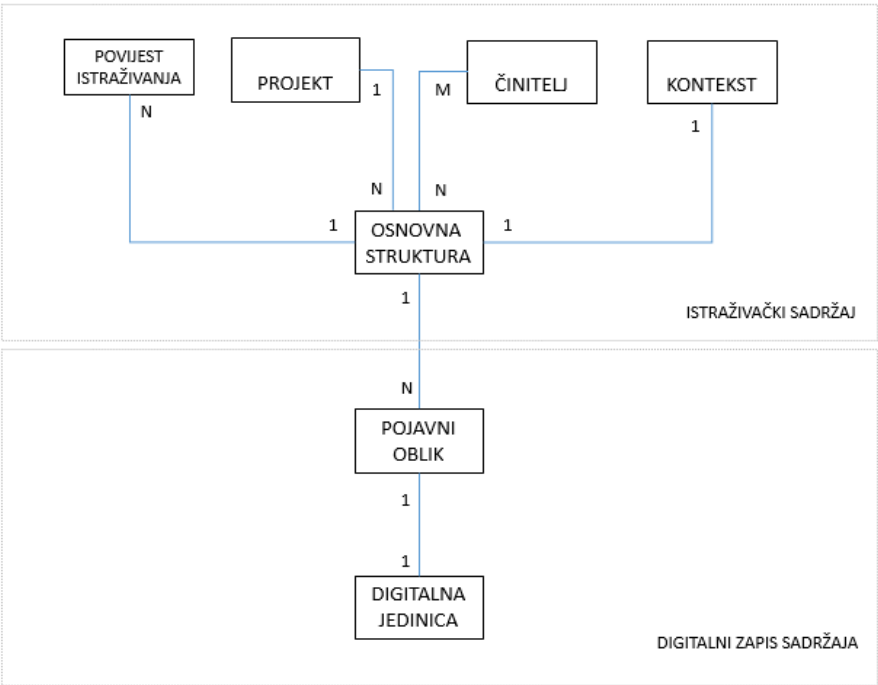

Slika 10.: Entiteti i veze aplikacijskog profila

Entitet osnovna struktura može imati više pojavnih oblika koji može biti konkretiziran samo sa jednom digitalnom jedinicom. Entiteti pojavni oblik i digitalna jedinica pripadaju digitalnom zapisivanju sadržaja.

5.3.3. Metapodatkovni elementi aplikacijskog profila

U okviru ovog dijela doktorskog rada detaljno će se opisati svaki metapodatkovni element za aplikacijski profil. Opis pojedinog metapodatkovnog elementa izradit će se temeljem definiranog modela domena, entiteta i veza, a biti će opisani putem definirane strukture i tablice na temelju sljedećih elemenata: oznaka, ime, definicija, obveznost, pojavnost, vrsta podataka, primjer. Oznakom se bilježi pripadnost pojedinoj kategoriji (Istraživački sadržaj i Digitalni zapis sadržaja) i grupi (Osnovna struktura, Povijest istraživanja, Projekt, Kontekst, Pojavni oblik i Digitalna jedinica). Putem imena jednoznačno određujemo naziv pojedinog metapodatkovnog elementa. Definicija se odnosi na opis imena iz prostora metapodatkovnog elementa. Obveznost označava je li potrebno unijeti vrijednost ili ne. Moguće vrijednosti obveznosti su: obvezan (mora biti unesena vrijednost), preporučen (vrijednost je potrebno unijeti ukoliko je dostupna), opcionalni (vrijednost nije potrebno navesti). Pojavnost označava je li potrebno unijeti jednu vrijednost ili je moguće koristiti više vrijednosti. Vrijednosti pojavnosti su: višestruka (može se unijeti više od jedne vrijednosti, a njih označavamo sa *), pojedinačna (dozvoljena je samo jedna vrijednost, koju označavamo sa 1). Tip podataka označava koji tip podataka unosimo kod elementa. Moguće vrijednosti su: string[164], datum[165] , URI[166], langstring[167], geo location[168]. Primjer daje prikaz pojedinačnih relevantnih podataka u svrhu razumijevanja elementa. Kako je ovo prva inačica aplikacijskog profila svi elementi imaju inačicu 1 i nije posebno navedena unutar tablice. Elementi aplikacijskog profila prikazani su u Tablici 21.

[164] tekstualni opis
[165] datum po standardu ISO 8601
[166] string vrijednost u svrhu identifikacije resursa na internetu
[167] oznaka države prema standardu RFC 3066
[168] oznaka latitude, longitude i adrese

Tablica 21.: Metapodatkovni elementi aplikacijskog profila

Oznaka	Ime	Definicija	Obveznost	Pojavnost (maksimalna)	Tip podataka	Primjer
1	*2*	*3*	*4*	*5*	*6*	*7*
1.	**Istraživački sadržaj**	**Ova kategorija grupira podatke kojima se opisuje istraživački sadržaj arheološkog entiteta u cjelini**	**-**	**-**	**-**	**-**
1.1.	***Osnovna struktura***	***Ova grupa opisuje podatke kojima možemo razumjeti arheološki entitet i omogućiti njegovo citiranje***		*		
1.1.1.	Jedinstveni identifikator	Globalno jedinstveni numerički ili znakovni niz koji je pridružen arheološkom entitetu u digitalnom okruženju (digitalnom objektu)	Obvezan	1	URI	https://doi.org/10.15291/archeo.1504
1.1.2.	Ime	Deskriptivno ime arheološkog entiteta po kojemu se prepoznaje	Obvezan	1	String	Ulomak zdjelice
1.1.3.	Ključne riječi	Ključne riječi kojima opisujemo arheološki entitet	Obvezan	*	String	Keramika, Arhajsko Padanska keramika, Babac
1.1.4.	Autor	Osoba koja je znanstveno opisala arheološki entitet i odredila značenje	Obvezan	*	String	Ime i prezime
1.1.5.	Geografsko ime prostora	Geografski termin koji pomaže kod pronalaženja i identificiranja arheološkog entiteta	Obvezan	1	String	Babac, Otok
1.1.6.	Mjesto	Identifikacija točne lokacije pronalaska arheološkog entiteta (država, županija, mjesto, adresa) ili lokacija na temelju nacionalnog referalnog sustava (koordinate)	Obvezan	1	Geo Location	Hrvatska, Zadarska županija, otok Babac, N 43°79'16.09"; E 16°03'59.36"
1.1.7.	Ime nalazišta	Ime nalazišta arheološkog entiteta	Obvezan	1	String	Babac, uvala, zapadni prolaz
1.1.8.	Tip objekta	Termin po kojemu će se arheološki entitet indeksirati i interpretirati temeljem funkcionalnog ili deskriptivnog kriterija	Obvezan	1	String	Zdjela
1.1.9.	Vrsta materijala	Glavni materijal iz kojeg je napravljen arheološki entitet	Obvezan	1	String	Glina

Oznaka	Ime	Definicija	Obveznost	Pojavnost (maksimalna)	Tip podataka	Primjer
1	*2*	*3*	*4*	*5*	*6*	*7*
1.1.10.	Kulturno razdoblje	Kulturno razdoblje kojem pripada arheološki entitet	Obvezan	1	String	Kasniji srednji vijek
1.1.11.	Uža kulturna odrednica	Dodatni kulturni pojam	Obvezan	1	String	Arhajski glazirana keramika
1.1.12.	Vremensko razdoblje	Identifikacija načina računanja vremena za arheološki entitet	Obvezan	1	String	st. pos. Kr.
1.1.13.	Stoljeće	Identifikacija stoljeća kojemu pripada arheološki entitet	Obvezan	1	String	Kraj 14. st. – prva pol. 15. st.
1.2.	***Povijest istraživanja***	***Ova grupa opisuje podatke kojima možemo razumjeti pripremnu fazu istraživanja iz kojeg proizlaze arheološki entiteti***	**-**	*	**-**	**-**
1.2.1.	Ime istraživanja	Ime dano pripremnoj fazi istraživanja	Opcionalni	1	String	Istraživanje o neolitičkim keramičkim predmetima
1.2.2.	Istraživač	Identifikacija osobe koja je provela pripremnu fazu istraživanja	Opcionalni	*	String	Ime i prezime
1.2.3.	Planirana lokacija istraživanja	Identifikacija geografske lokacije (općina, grad) predviđene za istraživanje	Opcionalni	1	String	Zadar, Smilčić
1.2.4.	Kronološki period i razdoblje	Identifikacija kronološkog razdoblja i perioda	Opcionalni	1	String	Neolitik (6500-3500 g.pr.Kr.)
1.3.	***Projekt***	***Ova grupa opisuje podatke kojima možemo razumjeti pripadnost arheološkog entiteta projektu***	**-**	***1***	**-**	**-**
1.3.1.	Ime projekta	Ime dano projektu u okviru kojeg je prikupljen arheološki entitet	Preporučeni	1	String	Tranzicija i tradicija u špilji Vlakno: Model prijelaza
1.3.2.	Lokacija projekta	Identifikacija točne lokacije provedbe projekta i istraživanja (država, županija, mjesto, adresa) ili lokacija na temelju nacionalnog referalnog sustava (koordinate)	Preporučeni	1	Geo Location	Hrvatska, Zadarska županija, Dugi otok - N 43°59'11.323"; E 15°3'30.834"; H:584 ft
1.4.	***Kontekst***	***Ova grupa opisuje podatke kojima možemo razumjeti kontekst arheološkog entiteta***		***1***		

Oznaka	Ime	Definicija	Obveznost	Pojavnost (maksimalna)	Tip podataka	Primjer
1	*2*	*3*	*4*	*5*	*6*	*7*
1.4.1.	Referenca mjesta otkrića	Detaljna referenca gdje je arheološki entitet pronađen na lokaciji nalazišta	Obvezan	1	String	Pećina Vlakno, sonda B, kvadrat G3
1.4.2.	Stratigrafska jedinica	Opis sloja u kojemu je pronađen arheološki entitet i njegova povezanost s ostalim slojevima	Obvezan	1	String	Entitet pronađen u sloju S.J. 18 Horizont I (slojevi od 16 do 22).
2.	**Digitalni zapis sadržaja**	**Ova kategorija grupira podatke kojima se opisuje digitalna konkretizacija istraživačkog sadržaja**	**-**	*****	**-**	**-**
2.1.	***Pojavni oblik***	**Ova kategorija sadrži podatke kojima se opisuje pojavni oblik arheološkog entiteta u digitalnom okruženju**		*****		
2.1.1.	Ime pojavnog oblika	Jednoznačno ime pojavnog oblika	Obvezan	1	String	Ulomak zdjelice
2.1.2.	Format	Oblik u kojem je prezentiran arheološki entitet	Obvezan	1	Lista	xml
2.1.3.	Inačica	Jedinstveni broj koji je dodijeljen arheološkom entitetu (digitalnom objektu)	Obvezan	1	Integer	1.0
2.1.4.	Datum pojavnosti	Datum kreiranja pojavnog oblika	Obvezan	1	Date	2020-26-03
2.1.5.	Jezik	Jezik opisa arheološkog entiteta u pojavnom obliku	Obvezan	1	Langstring	HR
2.1.6.	Organizacija	Organizacija koja je kreirala digitalni oblik	Obvezan	1	String	Sveučilište u Zadru
2.2.	***Digitalna jedinica***	**Ova kategorija sadrži podatke kojima se daje opis pojedinog digitalnog objekta**		***1***		
2.2.1	Ime jedinice	Jednoznačno ime digitalne jedinice	Obvezan	1	String	Ulomak zdjelice
2.2.2.	Pravne informacije	Jednoznačna identifikacija akcija za rad sa digitalnim objektom	Obvezan	1	URI	In Copyright – Non Commercial Use Only
2.2.3.	Prava pristupa	Jednoznačna identifikacija načina pristupa digitalnom objektu	Obvezan	1	Lista	Otvoreni pristup
2.2.4.	Lokacija	Lokacija na kojoj se nalazi digitalni objekt	Obvezan	1	URI	Digitalni istraživački repozitorij

5.3.4. Aplikacijski profil označen i opisan putem XML

XML je proširivi jezik za označavanje podataka i dokumenata. U proteklom razdoblju XML je prihvaćen kao univerzalni sustav i mehanizam za objavu i razmjenu podataka između različitih računalnih sustava i programa. Pojedini radovi ukazuju na korištenje XML u kontekstu otvorenosti i razmjene istraživačkih podataka u području arheologije (Monteil i Bouletreau, 2015), (Schloen, 2001), (Kansa i Kansa, 2011). Osim u istraživačkim radovima upotreba XML vidljiva je i u okvirima projekata npr. projekt Stellar (May *et al.*, 2012) i CARARE (CARARE, 2015).

XML je neovisan o računalnoj platformi kao i operacijskom sustavu koji koristimo, a sastoji se od elemenata (npr. <ime> </ime>), deklaracija (npr. <?xml version="1.0", encoding="UTF-8"?>), komentara, procesorske naredbe, definicije tipa dokumenata (DTD)[169], reference na entitete i sekcije teksta posebne namjene (CDATA)[170] (Kirasić, 2005). On može biti pročitan od strane ljudi ili procesiran od strane računalnih programa, koji mogu stvoriti nove skupove podataka.

XML opisujemo podatke i njihov značaj putem oznaka i one nisu unaprijed definirane. Oznake reprezentiraju bilo koji entitet bez obzira radi li se o fizičkom, apstraktnom ili konstruktu računalnog jezika. Korisnici sami definiraju oznake za označavanje. Oznake koje su definirane opisuju se DTD ili sa XML Schemom. DTD ima pojedina ograničenja u odnosu na XML Schemu (Bosančić, 2011). XLM Schema je najčešće poznata kao „XML Schema Definition" (XSD), koristi se za opis i validaciju strukture XML podataka, a putem nje se definiraju elementi, atributi te tip podataka.

Dokument u XML mora biti ispravno oblikovan (npr. postojanje vršnih elementa, elementi moraju imati oznaku zatvaranja, ispravno napisani, odgovarajuće smješteni, a vrijednosti atributa ispravno zapisane) i važeći (mora odgovarati DTD).

Aplikacijski profil u okviru ovog istraživanja opisan je putem XML dokumenta i scheme. Prilikom izrade opisa korišteni su izvori (Harold, 2004), sadržaj o XML sa web stranica W3C[171], a validacija ispravnosti opisa napravljena je putem programa Liquid Studio 2019 – Community Edition.

---

[169] Document Type Definition, https://www.w3schools.com/xml/xml_dtd.asp
[170] Character Data, https://www.w3resource.com/xml/CDATA-sections.php
[171] World Wide Web Consortium, https://www.w3.org/XML/

5.3.4.1. XML dokument


```xml
<?xml version="1.0" encoding="utf-8"?>
<!--Aplikacijski profil prikazan putem XML Dokumenta-->
<AplikacijskiProfil>
    <!--Metapodatkovni elementi koji se odnose na kategoriju Istrazivacki sadrzaj-->
    <KategorijaIstrazivackiSadrzaj>
        <!--Metapodatkovni elementi koji se odnose na grupe Osnovna struktura, Povijest istrazivanja, Projekt i Kontekst--
>
        <GrupaOsnovnaStruktura>
            <JedinstveniIdentifikator>
            <TipIdentifikatora>DOI</TipIdentifikatora>
            <VrijednostURI>doi.org/10.15291/primjer1</VrijednostURI>
        </JedinstveniIdentifikator>
            <Ime>Ulomak oboda i vrata grubog lonca</Ime>
            <KljucneRijeci>keramika</KljucneRijeci>
            <KljucneRijeci>obod</KljucneRijeci>
            <KljucneRijeci>lonac</KljucneRijeci>
            <Autor>Dario Vujević</Autor>
            <Autor>Karla Gusar</Autor>
            <GeografskoImeProstora>Zemunik Donji, Gradina</GeografskoImeProstora>
            <Mjesto>
            <Drzava>Hrvatska</Drzava>
            <Zupanija>Zadarska županija</Zupanija>
            <ImeMjesta>Zemunik Donji</ImeMjesta>
            <Latitude>44.111961</Latitude>
            <Longitude>15.384371</Longitude>
            </Mjesto>
            <ImeNalazista>Gradina</ImeNalazista>
            <TipObjekta>Lonac</TipObjekta>
            <VrstaMaterijala>Glina</VrstaMaterijala>
            <KulturnoRazdoblje>Kasniji srednji vijek</KulturnoRazdoblje>
            <UzaKulturnaOdrednica>-</UzaKulturnaOdrednica>
            <VremenskoRazdoblje>st. pos. Kr.</VremenskoRazdoblje>
```

```
        <Stoljece>Kraj 14. st. - prva pol. 15. st.</Stoljece>
    </GrupaOsnovnaStruktura>
    <GrupaPovijestIstrazivanja>
        <ImeIstrazivanja>Gradina u Donjem Zemuniku</ImeIstrazivanja>
        <Istrazivac>Brunislav Marijanović</Istrazivac>
        <Istrazivac>Kristina Horvat</Istrazivac>
        <PlaniranaLokacijaIstrazivanja>Zemunik Donji</PlaniranaLokacijaIstrazivanja>
        <KronoloskiPeriodRazdoblje>Srednji vijek</KronoloskiPeriodRazdoblje>
    </GrupaPovijestIstrazivanja>
    <GrupaProjekt>
        <ImeProjekta>Utvrda u Zemuniku Donjem u srednjem i novom vijeku</ImeProjekta>
        <LokacijaProjekta>
        <Drzava>Hrvatska</Drzava>
        <Zupanija>Zadarska županija</Zupanija>
        <ImeMjesta>Zemunik Donji</ImeMjesta>
        <Latitude>44.111961</Latitude>
        <Longitude>15.384371</Longitude>
        </LokacijaProjekta>
    </GrupaProjekt>
    <GrupaKontekst>
        <ReferencaMjestaOtkrica>Gradina: Kv. 4</ReferencaMjestaOtkrica>
        <StratigrafskaJedinica>24</StratigrafskaJedinica>
    </GrupaKontekst>
</KategorijaIstrazivackiSadrzaj>
<!--Metapodatkovni elementi koji se odnose na kategoriju Digitalni zapis sadrzaja-->
<KategorijaDigitalniZapisSadrzaja>
<!--Metapodatkovni elementi koji se odnose na grupe Pojavni oblik i Digitalna jedinica-->
<GrupaPojavniOblik>
    <ImePojavnogOblika>Ulomak oboda i vrata grubog lonca</ImePojavnogOblika>
    <Format>Skup podataka</Format>
    <Inacica>1</Inacica>
    <DatumPojavnosti>2019-05-01</DatumPojavnosti>
    <Jezik>HR</Jezik>
    <Organizacija>Sveučilište u Zadru</Organizacija>
    <!--Metapodatkovni elementi koji se odnose na grupu Digitalna jedinica-->
    <GrupaDigitalnaJedinica>
```

```
            <ImeJedinice>Ulomak oboda i vrata grubog lonca</ImeJedinice>
            <PravneInformacije>http://rightsstatements.org/vocab/InC-NC/1.0/</PravneInformacije>
            <PravaPristupa>Otvoreni pristup</PravaPristupa>
            <Lokacija>https://rep-a.unizd.hr</Lokacija>
        </GrupaDigitalnaJedinica>
    </GrupaPojavniOblik>
    <!--Metapodatkovni elementi koji se odnose na grupe Pojavni oblik i Digitalna jedinica-->
    <GrupaPojavniOblik>
        <ImePojavnogOblika>Ulomak oboda i vrata grubog lonca</ImePojavnogOblika>
        <Format>Vektorska grafika</Format>
        <Inacica>1</Inacica>
        <DatumPojavnosti>2019-02-07</DatumPojavnosti>
        <Jezik>HR</Jezik>
        <Organizacija>Sveučilište u Zadru</Organizacija>
        <!--Metapodatkovni elementi koji se odnose na grupu Digitalna jedinica-->
        <GrupaDigitalnaJedinica>
            <ImeJedinice>Ulomak oboda i vrata grubog lonca</ImeJedinice>
            <PravneInformacije>https://rightsstatements.org/page/NoC-CR/1.0/?language=en</PravneInformacije>
            <PravaPristupa>Pristup na razini projekta</PravaPristupa>
            <Lokacija>https://rep-b.unizd.hr</Lokacija>
        </GrupaDigitalnaJedinica>
    </GrupaPojavniOblik>
    </KategorijaDigitalniZapisSadrzaja>
</AplikacijskiProfil>
```


5.3.4.2. XML Schema


```
<?xml version="1.0" encoding="utf-8" ?>
<xs:schema attributeFormDefault="unqualified"
           elementFormDefault="qualified"
           xmlns:xs="http://www.w3.org/2001/XMLSchema">
    <xs:element name="AplikacijskiProfil">
        <xs:complexType>
```

```
<xs:sequence>
    <xs:element name="KategorijaIstrazivackiSadrzaj"
                minOccurs="1"
                maxOccurs="unbounded">
        <xs:complexType>
            <xs:sequence>
                <xs:element name="GrupaOsnovnaStruktura"
                            minOccurs="1"
                            maxOccurs="unbounded">
                    <xs:complexType>
                        <xs:sequence>
                            <xs:element minOccurs="0" name="JedinstveniIdentifikator">
                                <xs:complexType>
                                    <xs:sequence>
                                        <xs:element minOccurs="0" name="TipIdentifikatora" type="xs:string" />
                                        <xs:element minOccurs="0" name="VrijednostURI" type="xs:string" />
                                    </xs:sequence>
                                </xs:complexType>
                            </xs:element>
                            <xs:element name="Ime"
                                        type="xs:string"
                                        minOccurs="1" />
                            <xs:element name="KljucneRijeci"
                                        type="xs:string"
                                        minOccurs="0"
                                        maxOccurs="unbounded" />
                            <xs:element name="Autor"
                                        type="xs:string"
                                        minOccurs="0"
                                        maxOccurs="unbounded" />
                            <xs:element name="GeografskoImeProstora"
                                        type="xs:string"
                                        minOccurs="1" />
                            <xs:element name="Mjesto"
                                        minOccurs="1">
                                <xs:complexType>
```

```
        <xs:sequence>
            <xs:element name="Drzava"
                        type="xs:string"
                        minOccurs="0" />
            <xs:element name="Zupanija"
                        type="xs:string"
                        minOccurs="0" />
            <xs:element name="ImeMjesta"
                        type="xs:string"
                        minOccurs="1" />
            <xs:element name="Latitude"
                        type="xs:decimal"
                        minOccurs="1" />
            <xs:element name="Longitude"
                        type="xs:decimal"
                        minOccurs="1" />
        </xs:sequence>
    </xs:complexType>
</xs:element>
<xs:element name="ImeNalazista"
            type="xs:string"
            minOccurs="1" />
<xs:element name="TipObjekta"
            type="xs:string"
            minOccurs="1" />
<xs:element name="VrstaMaterijala"
            type="xs:string"
            minOccurs="1" />
<xs:element name="KulturnoRazdoblje"
            type="xs:string"
            minOccurs="1" />
<xs:element name="UzaKulturnaOdrednica"
            type="xs:string"
            minOccurs="0" />
<xs:element name="VremenskoRazdoblje"
            type="xs:string"
```

```
                        minOccurs="1" />
            <xs:element name="Stoljece"
                        type="xs:string"
                        minOccurs="1" />
        </xs:sequence>
    </xs:complexType>
</xs:element>
<xs:element name="GrupaPovijestIstrazivanja"
            minOccurs="1"
            maxOccurs="unbounded">
    <xs:complexType>
        <xs:sequence>
            <xs:element name="ImeIstrazivanja"
                        type="xs:string"
                        minOccurs="1"
                        maxOccurs="1" />
            <xs:element name="Istrazivac"
                        type="xs:string"
                        minOccurs="1"
                        maxOccurs="unbounded" />
            <xs:element name="PlaniranaLokacijaIstrazivanja"
                        type="xs:string"
                        minOccurs="1"
                        maxOccurs="1" />
            <xs:element name="KronoloskiPeriodRazdoblje"
                        type="xs:string"
                        minOccurs="1"
                        maxOccurs="1" />
        </xs:sequence>
    </xs:complexType>
</xs:element>
<xs:element name="GrupaProjekt"
            minOccurs="0"
            maxOccurs="1">
    <xs:complexType>
        <xs:sequence>
```

```
                <xs:element name="ImeProjekta"
                            type="xs:string"
                            minOccurs="0" />
                <xs:element name="LokacijaProjekta"
                            minOccurs="0">
                    <xs:complexType>
                        <xs:sequence>
                            <xs:element name="Drzava"
                                        type="xs:string"
                                        minOccurs="0" />
                            <xs:element name="Zupanija"
                                        type="xs:string"
                                        minOccurs="0" />
                            <xs:element name="ImeMjesta"
                                        type="xs:string"
                                        minOccurs="1" />
                            <xs:element name="Latitude"
                                        type="xs:decimal"
                                        minOccurs="1" />
                            <xs:element name="Longitude"
                                        type="xs:decimal"
                                        minOccurs="1" />
                        </xs:sequence>
                    </xs:complexType>
                </xs:element>
            </xs:sequence>
        </xs:complexType>
    </xs:element>
    <xs:element name="GrupaKontekst"
                minOccurs="1"
                maxOccurs="1">
        <xs:complexType>
            <xs:sequence>
                <xs:element name="ReferencaMjestaOtkrica"
                            type="xs:string"
                            minOccurs="1" />
```

```
                        <xs:element name="StratigrafskaJedinica"
                                    type="xs:unsignedByte"
                                    minOccurs="1" />
                    </xs:sequence>
                </xs:complexType>
            </xs:element>
        </xs:sequence>
    </xs:complexType>
</xs:element>
<xs:element name="KategorijaDigitalniZapisSadrzaja"
            minOccurs="1"
            maxOccurs="unbounded">
    <xs:complexType>
        <xs:sequence>
            <xs:element name="GrupaPojavniOblik"
                        minOccurs="1"
                        maxOccurs="unbounded">
                <xs:complexType>
                    <xs:sequence>
                        <xs:element name="ImePojavnogOblika"
                                    type="xs:string"
                                    minOccurs="1"
                                    maxOccurs="1" />
                        <xs:element name="Format"
                                    minOccurs="1">
                            <xs:simpleType>
                                <xs:restriction base="xs:string">
                                    <xs:enumeration value="Skup podataka" />
                                    <xs:enumeration value="Dokumenti i tekstovi" />
                                    <xs:enumeration value="Publikacija" />
                                    <xs:enumeration value="Tablica" />
                                    <xs:enumeration value="Baza podataka" />
                                    <xs:enumeration value="Vektorska grafika" />
                                    <xs:enumeration value="Rasterska grafika" />
                                    <xs:enumeration value="Digitalni video" />
                                    <xs:enumeration value="Digitalni zvuk" />
```

```
            <xs:enumeration value="3D Model" />
        </xs:restriction>
    </xs:simpleType>
</xs:element>
<xs:element name="Inacica"
            type="xs:integer"
            minOccurs="1" />
<xs:element name="DatumPojavnosti"
            type="xs:date"
            minOccurs="1" />
<xs:element name="Jezik"
            type="xs:language"
            minOccurs="1" />
<xs:element name="Organizacija"
            type="xs:string"
            minOccurs="1" />
<xs:element name="GrupaDigitalnaJedinica"
            minOccurs="1">
    <xs:complexType>
        <xs:sequence>
            <xs:element name="ImeJedinice"
                        type="xs:string"
                        minOccurs="1" />
            <xs:element name="PravneInformacije"
                        type="xs:anyURI"
                        minOccurs="1" />
            <xs:element name="PravaPristupa"
                        minOccurs="1">
                <xs:simpleType>
                    <xs:restriction base="xs:string">
                        <xs:enumeration value="Otvoreni pristup" />
                        <xs:enumeration value="Pristup na razini ustanove" />
                        <xs:enumeration value="Pristup na razini projekta" />
                    </xs:restriction>
                </xs:simpleType>
            </xs:element>
```

```
                                                    <xs:element name="Lokacija"
                                                                type="xs:anyURI"
                                                                minOccurs="1" />
                                                </xs:sequence>
                                            </xs:complexType>
                                        </xs:element>
                                    </xs:sequence>
                                </xs:complexType>
                            </xs:element>
                        </xs:sequence>
                    </xs:complexType>
                </xs:element>
            </xs:sequence>
        </xs:complexType>
    </xs:element>
</xs:schema>
```

5.3.5. Zaključno razmatranje

Modeliranje aplikacijskog profila je provedeno temeljem definiranja funkcionalnih zahtjeva, modeliranjem domene, utvrđivanjem entiteta i njihovih povezanosti, te definiranjem elemenata.

U kontekstu ovog rada i otvorenih istraživačkih podataka identificirana su tri temeljna funkcionalna zahtjeva. Prvi zahtjev je povezan uz opis arheološkog entiteta i zapisa te kreiranje digitalnog objekta. Drugi zahtjev se odnosi na otkrivanje i pretraživanje digitalnog objekta. Treći zahtjev je povezan uz dijeljenje i ponovnu uporabu podataka. Opis arheološkog entiteta i kreiranje digitalnog objekta povezano je uz entitete povijest istraživanja, projekt, osnovna struktura, kontekst, autor i organizacija te entitete sadržajnih stavki. Elementi za ove entitete proizlaze iz prethodnih faza rada (utvrđeni i navedeni su u okviru cjeline 5.2.4.) te potrebom evidentiranja podataka i na razini datoteke. Otkrivanje i pretraživanje digitalnog objekta povezano je uz otkrivanje od strane čovjeka i stroja, upotrebi selekcijskih elemenata, te prepoznavanju (identifikaciji) relevantnih digitalnih objekata. Elementi za ovu funkcionalnost utvrđeni su u cjelinama 4.2.5., 4.4. i 5.2.4. Dijeljenje i ponovna uporaba podataka povezana je uz identifikaciju prava pristupa i korištenja koja moraju biti čitljiva od strane korisnika i stroja (elementi su utvrđeni u okviru cjelina 3.3. i 5.1.3.) te načinu pristupa i korištenju (elementi su utvrđeni uz okviru cjeline 5.1.3.).

Temeljem funkcionalne specifikacije dane su dvije konceptualizacije. Prva se odnosi na kreiranje digitalnog objekta u području arheologije, a druga se odnosi na konceptualizaciju digitalnog objekta koji je rezultat znanstveno-istraživačkih aktivnosti i evidentiranja istraživačkih metapodataka te na omogućavanje dijeljenja i ponovne uporabe podataka.

Model domene na razini znanstveno-istraživačkih aktivnosti i digitalnog objekta povezan je uz FRBR koncept te su utvrđeni sljedeći entiteti: istraživački rad, izraz, činitelj, pojavni oblik i digitalna jedinica. Entiteti istraživački rad, izraz i činitelj su povezani uz kategoriju istraživački sadržaj, a entiteti pojavni oblik i digitalna jedinica uz kategoriju digitalno zapisivanje sadržaja.

Za kategoriju istraživački sadržaj metapodatkovni elementi su povezani uz utvrđene elemente za osnovnu strukturu iz cjeline 5.2., a za kategoriju digitalno

zapisivanje sadržaja uzeti je osnovni skup elementa sa razine datoteke, elementi citiranja, elementi povezani uz pravo i iz istraživanja.

Za aplikacijski profil utvrđeni su sljedeće kategorije, entiteti i pripadajući elementi:

- istraživački sadržaj
    - osnovna struktura - jedinstveni identifikator, ime, ključne riječi, autor, geografski ime prostora, mjesto, ime nalazišta, tip objekta, vrsta materijala, kulturno razdoblje, uža kulturan odrednica, vremensko razdoblje i stoljeće
    - povijest istraživanja – ime istraživanja, istraživač, planirana lokacija istraživanja, kronološki period i razdoblje
    - projekt – ime projekta i lokacija projekta
    - kontekst – referenca mjesta otkrića, stratigrafska jedinica
- digitalni zapis sadržaja
    - pojavni oblik – ime pojavnog oblika, format, inačica, datum pojavnosti, jezik, organizacija
    - digitalna jedinica – ime jedinice, pravne informacije, prava pristupa, lokacija

Aplikacijski profil prikazan je putem tablice i strukture, a za svaki element je navedena oznaka, ime, definicija, obveznost, pojavnost, vrsta podataka i primjer. U svrhu omogućavanja dijeljenja i razmjene podataka aplikacijski profil je označen i opisan putem XML dokumenta i Scheme.

5.4. Prepoznatljivost i jednoznačnost u aplikacijskom profilu

Arheološki entitet u okviru digitalnog okruženja predstavljen je temeljem digitalnog objekta, a opisan putem metapodatkovnih elemenata aplikacijskog profila. Objavom različitih arheoloških entiteta, stvorit će se veći broj digitalnih objekata, koji će biti na raspolaganju istraživačima za različite oblike ponovne uporabe. Trajni i pouzdani identifikator za digitalne objekte (apstraktne, fizičke) omogućava njihovu točnu i trajnu identifikaciju, razmjenu između različitih sustava kao i podršku za istraživački proces (npr. omogućavajući jednostavnije pretraživanje, pristup i suradnju). Prethodno je utvrđeno da je TI globalno jedinstveni numerički ili znakovni niz pridružen digitalnom objektu i ne može biti pridružen niti jednom drugom digitalnom ili fizičkom objektu.

Kako bi se ovo moglo ostvariti za arheološki entitet i pripadajući digitalni objekt u okviru razvijenog aplikacijskog profila definiran je element Jedinstveni identifikator koji je namijenjen za trajnu identifikaciju digitalnog objekta u mrežnom okruženju.

Pridruživanje TI u okviru kulturnih institucija pokazuje na različitu praksu dodjele TI digitalnoj manifestaciji (IALHI, 2013). Pristupi koji se upotrebljavaju je dodjela jednog TI primarnom digitalnom objektu bez obzira na broj digitalnih manifestacija te dodjela TI svakoj digitalnoj manifestaciji.

Definirani aplikacijski profil dijelimo na osnovna dva dijela: prvi je dio istraživački sadržaj, a drugi se dio odnosi na digitalno zapisivanje sadržaja. Prvi dio objedinjuje entitete istraživački rad i izraz, a sadrži metapodatkovne kategorije osnovna struktura i grupa povijest istraživanja, projekt, osnovna struktura i kontekst. Jedinstveni identifikator je metapodatkovni element definiran unutar grupe osnovna struktura, te osigurava jednoznačnost sadržaja istraživačkog rada. Promjena istraživačkog sadržaja u obliku nadopune postojećih istraživačkih podataka ne stvara novi istraživački rad i izraz. Oni se stvaraju sadržajem o novom objektu, značajnim sadržajnim izmjenama ili značajnim nadopunama.

U okviru aplikacijskog profila definiran je entitet pojavni oblik koji je digitalna manifestacija istraživačkog rada i pripadajućeg izraza. Promjena u digitalnom obliku (ili u formatu) u okviru FRBR rezultira novim pojavnim oblikom (El-Sherbini, 2013). Uzimajući moguće načine dodjele TI te u cilju kreiranje sustava koji bi mogao biti održiv i primjenjiv, u svrhu jednoznačne identifikacije pojavnog oblika u okviru definiranog

aplikacijskog profila pridodan je opcionalni metapodatkovni element – Jedinstveni identifikator pojavnog oblika. Kako je digitalna jedinica pojedinačna manifestacija pojavnog oblika i usmjerena na opis pojavnog oblika ona u okviru ovog aplikacijskog profila ne dobiva jednoznačni identifikator.

5.4.1. Usporedba i odabir trajnog identifikatora

Usporedba trajnih identifikatora URN, Handle sustav, DOI, ePIC i ARK prikazana je u Tablici 22. Identifikatoru koji u potpunosti ispunjava dani uvjet pridružena je oznaka ✓, za djelomično ispunjavanje uvjeta pridružena je oznaka ½, a za neispunjavanje uvjeta pridružena je oznaka -. Na kraju tablice naveden je broj potpuno ispunjenih uvjeta, broj djelomično ispunjenih uvjeta i broj neispunjenih uvjeta.

Tablica 22.: Usporedba funkcionalnih zahtjeva trajnih identifikatora

Redni broj	Funkcionalni zahtjevi za trajni identifikator	Trajni identifikator				
		URN	Handle	DOI	ePIC	ARK
1	*2*	*3*	*4*	*5*	*6*	*7*
1.	Globalni opseg	✓	✓	✓	✓	✓
2.	Globalna jedinstvenost	✓	✓	✓	✓	✓
3.	Trajnost	✓	✓	✓	✓	✓
4.	Skalabilnost	✓	✓	✓	✓	✓
5.	Podrška postojećih shema i standarda	✓	-	✓	-	-
6.	Proširivost	✓	✓	✓	✓	✓
7.	Nezavisnost	✓	✓	✓	✓	✓
8.	Utemeljenost na standardu	✓	✓	✓	½	½
9.	Podržavanje istraživačkih aktivnosti kroz životni ciklus	½	½	✓	✓	½
10.	Metapodatci	½	✓	✓	✓	✓
11.	Interoperabilnost	✓	✓	✓	✓	✓
12.	Referenciranje	✓	✓	✓	✓	✓
13.	Granularnost	✓	✓	✓	✓	✓
14.	Vjerodostojnost i održivost registracijskog autoriteta	✓	-	✓	½	✓
	POTPUNO ISPUNJENI UVJETI *(∑)*	12	11	14	11	11
	DJELOMIČNO ISPUNJENI UVJETI *(∑)*	2	1	0	2	2
	NEISPUNJENI UVJETI *(∑)*	0	2	0	1	1

Prvi uvjet globalnog opsega ispunjavaju svi analizirani identifikatori. Kako se radi o identifikatorima koji se pridružuju točno određenom digitalnom objektu svi analizirani identifikatori ispunjavaju i uvjet globalne jedinstvenosti. Uvjet trajnosti u postupku korištenja digitalnih objekata ispunjavaju svi identifikatori. Uvjet skalabilnosti ispunjavaju svi identifikatori.

Uvjet podrška postojećih shema i standarda u potpunosti ispunjava URN (npr. omogućava druge sheme ISBN i CHE) i DOI. Drugi identifikatori za sada ovaj uvjet ne ispunjavaju. Kako je uvjet proširivosti široko definiran, ispunjavaju ga svi identifikatori (npr. URN može uključiti druge sheme, a svi identifikatori omogućavaju proširenje kroz veći broj metapodatkovnih elemenata). Svaki od analiziranih identifikatora omogućava nezavisno i samostalno imenovanje tako da ovaj uvjet ispunjavaju svi identifikatori. Trenutačno je samo identifikator DOI potpuno pokriven standardom (ISO 26324:2012), URN i Handle sustav su potpuno definirane sheme i usluge, a ePIC i ARK su identifikatori koji su još u razvoju i za njih se može zaključiti kako djelomično ispunjavaju uvjet utemeljenosti na dokumentiranom standardu ili usluzi. Podržavanje istraživačkih aktivnosti kroz životni ciklus kao uvjet u svojim opisima u potpunosti ispunjava ePIC, DOI (npr. Sveučilište u Bristolu koristi DOI za istraživačke podatke), ostali identifikatori pokrivaju samo pojedine faze istraživanja (npr. citiranje). Uvjet veza uz metapodatke u potpunosti ispunjavaju ePIC, DOI, ARK, Handle dok ga URN djelomično ispunjava (potrebno je uključiti druga imena i metapodatkovne sheme). Uvjet interoperabilnosti u potpunosti ispunjavaju URN (od sredine 90-ih), Handle sustav, DOI, ePIC i ARK. Referenciranje kao uvjet ispunjavaju svi identifikatori, svi se često primjenjuju u okviru istraživačkog publiciranja. Kako digitalni objekt može imati dodatne sadržaje (objekte), granularnost je jedan od važnijih uvjeta. Ovaj uvjet ispunjavaju URN (npr. proširena i detaljnija sintaksa), Handle sustav, DOI (omogućava kreiranje posebnih vrsta kao i podvrsta) kao i ePIC i ARC. Za opstojnost i održivost istraživačkih podataka (otvorenih istraživačkih podataka) i pripadajućih repozitorija presudan uvjet je vjerodostojnost i održivost registracijskog autoriteta. Identifikator URN najčešće je osiguran putem nacionalnih institucija (npr. nacionalne knjižnice) ili repozitorija (npr. DANS), što osigurava održivost sustava. Handle sustav mogu uspostaviti različite institucije, čime se otvara pitanje opstojnosti takvih sustava ukoliko ih ne financira ili njime ne upravlja država ili globalna razina. Izgradnja Handle sustava od pojedinačnih

organizacija (udruženja) ne garantira dugotrajnu dostupnost. DOI sustav je uspostavljen na globalnoj razini od međunarodne neprofitne organizacije koja u proteklih 20 godina uspješno osigurava trajni identifikator. Identifikator ePIC uspostavljen je od konzorcija, i u proteklih je 10 godina zaživio u istraživačkom prostoru. S obzirom na kratak vremenski period postojanja ovaj identifikator u ovom trenutku djelomično ispunjava postavljeni uvjet. ARK svojim konceptom omogućava laganu promjenu registracijskog autoriteta te na taj način omogućava dugotrajnu dostupnost.

Provedena analiza TI ukazuje da DOI identifikator ispunjava sve tražene uvjete.

5.4.2. Zaključno razmatranje

U okviru ove cjeline, u svrhu osiguravanja prepoznatljivosti i jednoznačnosti arheološkog entiteta u digitalnom okruženju te u kontekstu otvorenosti (dijeljenje, ponovna uporaba) za aplikacijski profil su definirani su trajni identifikatori i analizirani mogući trajni identifikatori prema utvrđenim elementima usporedbe. Za aplikacijski profil predviđena su dva trajna identifikatora. Prvi trajni identifikator se odnosi na identifikaciju cijelog digitalnog objekta koji je opisan putem aplikacijskog profila (grupe osnovna struktura, pojavni oblik, digitalna jedinica), a dodatni (opcionalni) trajni identifikator je predviđen ukoliko postoje različite manifestacije pojavnog oblika.

Napravljena je usporedba trajnih identifikatora: URN, Handle sustav, DOI, ePIC i ARK. Na temelju 14 utvrđenih elemenata usporedbe, cjelovitim identifikatorom se pokazao DOI. Osnovna prednost DOI-a proizlazi iz standardiziranosti, podržavanja istraživačkog ciklusa te vjerodostojnosti i dugotrajnosti.

Ovime je dan odgovor na istraživačko pitanje RQ3.

5.5. Mapiranje istraživačkih baza i aplikacijskog profila

Uspostava arheoloških baza podataka jedan je od ciljeva arheoloških istraživanja. Podatci iz arheoloških istraživanja pogodni su za digitalizaciju i kreiranje različitih baza podataka. Namjenu arheoloških baza podataka možemo tražiti u bilježenju podataka koje su arheolozi prikupili istraživanjima na terenu ili u laboratoriju, korištenjem kao istraživački resurs za buduće arheološke projekte, praćenjem stanja i raspolaganjem objektima prikupljenima u administrativne i pravne svrhe (Miller, 2012).

Pojedina istraživanja u području arheologije bazu podataka opisuju kao model ili prikaz promatrane i interpretirane stvarnosti (Kansa, 2005). Banning razmatra bazu podataka kao spremnik informacija koji korisnicima omogućava podatke za donošenje odluka, zaključke, tumačenje, istraživanje obrazaca ili testiranje hipoteza, te zaključuje da se njezin pojam odnosi na zbirku međusobno povezanih i pohranjenih podataka, s kontroliranom redundancijom (Banning, 2002). Pogled na bazu podataka kao dijeljenu i integrirajuću računalnu strukturu daje istraživanje Schladera (Schlader, 2002), koje utvrđuje da baza podataka sadrži kolekcije podataka korisnika te metapodatke.

Baze podataka najčešće su kreirane s različitim istraživačkim ciljevima i strukturama. Najčešće vrste baza podataka u području arheologije su plošne baze, hijerarhijske baze, relacijske baze i objektno orijentirane baze.

Relevantni koncepti (konkretni ili apstraktni) bitni za baze podataka iskazani su putem entiteta. U poglavlju 2.1. ukratko je opisano što je entitet te je utvrđeno da svaki entitet ima svoje atribute (obilježja). Atribut možemo opisati kao čestu i opću karakteristiku entiteta, čije vrijednosti u arheologiji proizlaze npr. iz funkcionalne, morfološke, tehnološke i stilističke dimenzije. Vrijednosti atributa proizlaze iz točno određene domene. Odabir atributa u svrhu evidentiranja arheoloških entiteta (npr. vrsta keramike, lokacija) ima dugoročni utjecaj na ponovnu uporabu za istraživanja, kao i za znanstvene analize i zaštitu (Gattiglia, 2018).

U okviru ove faze rada napravit će se mapiranje[172] elemenata aplikacijskog profila s atributima baza podataka koji proizlaze iz arheoloških istraživačkih projekata. Mapiranje će se napraviti temeljem definirane metodologije iz cjeline 1.3.4.

[172] Mapiranje se odnosi na pridruživanje skupa atributa ili elemenata iz jedne sheme ili baze podataka odgovarajućim atributima ili elementima druge sheme ili baze podataka.

5.5.1. Opis postojećih istraživačkih baza podataka iz područja arheologije

Projekt „Tranzicija i tradicija u špilji Vlakno: Model prijelaza paleolitika u mezolitik na prostoru Sjeverne Dalmacije“ inicirao je istraživač Dario Vujević i Odjel za arheologiju Sveučilišta u Zadru. Cilj projekta bilo je istraživanje i proučavanje prijelaza paleolitika u mezolitik te kontinuiteta i diskontinuiteta naseljavanja prostora na području Sjeverne Dalmacije.

Projekt je proveden u razdoblju od svibnja 2015. godine do travnja 2018. godine, na lokalitetu špilja Vlakno. Špilja Vlakno nalazi se na središnjem dijelu Dugog otoka, a njezina su specifičnost kulturni slojevi koji se u kontinuitetu mogu pratiti sve do 17.530 kal. god. pr. Kr. Tijekom istraživanja pronađen je veći broj izrađevina tipa grebala, dubila, svrdla, sječiva, šiljka koji su evidentirani putem baze podataka.

Baza podataka o izrađevinama napravljena je u programu MS Access. Jezik baze podataka je hrvatski. Sastoji se od pet tablica (Vlakno, tipologija, tehnologija, sirovina i plohak), obrasca za unos podataka (Vlakno), nekoliko upita (npr. izrađevine po tipu i sloju, izrađevine po tipu, tehnologiji i sloju, brojnost izrađevina po sloju, brojnost izrađevina s obzirom na tehnologiju i tip) i izvješća (popis izrađevina).

Po tipu baza podatka je relacijska, uspostavljene su relacije između tablice plohak i vlakno te tablice vlakno i tipologija. Tablica Vlakno sadrži 254 zapisa povezana uz evidentiranje izrađevina tipa šiljak, blanja, obrađenih komadića, dubila, gravetica, grebala, pločica i strugalica. Tablica tipologija sadrži 94 zapisa povezana uz tip izrađevine (npr. jednostavno grebalo, grebalica, blanja, svrdlo, itd.). Tablica tehnologija sadrži 22 zapisa o fazi izrade (npr. gomolj ili oblutak, prvotni odbojak, pločice, itd.) izrađevine. Tablica sirovina sadrži 4 zapisa (rožnjak, radiolaritski rožnjak, zamjenski rožnjak i tuf). Tablica plohak sadrži 7 zapisa o vrsti (npr. ravan, dvoplošan, višeplošan, itd.). Osnovna tablica o izrađevinama je Vlakno, koja sadrži 12 atributa, koji su prikazani u Tablici 23. Vrijednosti u tablici odnose se na zapise iz baze koji se vode pod rednim brojevima 58 i 108.

Tablica 23.: Atributi istraživačke baze podataka „Tranzicija i tradicija u špilji Vlakno: Model prijelaza paleolitika u mezolitik na prostoru Sjeverne Dalmacije“

Ime atributa	Opis atributa	Primjer vrijednosti
1	*2*	*3*
Redni broj	Označava jedinstvenu identifikaciju zapisa u bazi	108; 58
Tipologija	Ovim atributom se označava tip izrađevine	azilijenski šiljak; djelomično obrađen komadić; dubilo s izbočeno obrađenim zarupkom
Tehnologija	Atributa označava položaj predmeta u procesu izrade izrađevine	Pločica; odbojak
Plohak	Odnosi se na dio udarne plohe koji je ostao na odbojku	-; -
Dužina	Odnosi se na vrijednosti mjere dužine izrađevine izražene u mm	32; 31
Širina	Odnosi se na vrijednost širine izrađevine izražene u mm	10; 15
Debljina	Odnosi se na debljinu izrađevine izražene u mm	3; 7
Težina	Odnosi se na težinu izrađevine izražene u gr.	0,7; 3,6
Sirovina	Vrsta kamena koja je uporabljena za izradu pojedine izrađevine	Rožnjak; Rožnjak
Stratigrafska jedinica	Arheološki kontekst u kojem je pronađena izrađevina	3; 11
Sloj	Poveznica na arheološki kontekst iz prethodnih istraživanja	1; 3
Napomena	U okvirima ovog atributa naveden je opis izrađevine	Tanka pločica sa hrbatom na dorzalnoj i tragovima kolobara na ventralnoj strani. Dio sa plohkom odstranjen je naknadno, skupa s većim dijelom lijeve bočne strane ..; Nepravilan odbojak s dva izbočena zarupka,

Projekt „Utvrda u Zemuniku Donjem u srednjem i novom vijeku“ pokrenut je od strane Sveučilišta u Zadru, a realiziran je tijekom 2014. godine u sklopu terenske nastave Odjela za arheologiju. Cilj projekta bilo je dobivanje jasnog uvida u stratigrafiju nalazišta te uspostava što preciznije kronologije naseobinskih aktivnosti na lokalitetu Gradina u Zemuniku Donjem. Provedenim arheološkim istraživanjem dobivena je potpuna stratigrafska slika istraženog lokaliteta, pri čemu su pronađeni arhitektonski ostaci srednjeg i novog vijeka, i veća količina sitnih nalaza (keramike, stakla, kosti, metala i kamena). Sitni nalazi pripadaju izrađevinama i evidentirani su putem baze podataka.

Baza podataka je plošnog tipa i izrađena je programom Excel. Jezik baze je hrvatski. Sadrži ukupno 541 zapis o izrađevinama pronađenim u okviru projekta. Izrađevine pripadaju prapovijesti; neolitiku i željeznom dobu, antici te srednjem i novom vijeku. Baza sadrži tekstualne i slikovne podatke. Temeljem atributa i vrijednosti baze podataka moguće je identificirati sljedeće povezane entitete: izrađevina, autor (istraživač), lokalitet istraživanja, kontekst, publikacija i slika.

Predmetna baza podataka sadrži 20 atributa, a njihovo ime, opis i primjer vrijednosti navedeni su u Tablici 24.

Tablica 24.: Atributi druge istraživačke baze podataka „Utvrda u Zemuniku Donjem u srednjem i novom vijeku“

Ime atributa	Opis atributa	Primjer vrijednosti
1	*2*	*3*
Inventarni broj	Ima ulogu povezivanja izrađevine i svih oblika dokumentacije o izrađevini	ZEM-G459
Vrsta / naziv	Identifikacija vrste izrađevine, a najčešće se odnosi na fizički oblik, funkciju ili medij izrađevine	Sječivo
Naslov	Označava izvorni naziv izrađevine	kremeno sječivo
Razdoblje / datacija	Odnosi se na vrijeme / razdoblje stvaranja izrađevine	neolitik
Autor	Ovim atributom definira se istraživač ili grupa istraživača te organizacija odgovorna za izrađevinu; ukoliko autor nije poznat može označavati i kulturu	danilska kultura

Ime atributa	Opis atributa	Primjer vrijednosti
1	*2*	*3*
Opis	Odnosi se na kratki opis izrađevine	Ulomak kremenog sječiva s obradom na oba ruba i vidljivim tragovima sjaja srpa.
Dimenzije	Ovim se atributom evidentiraju sve dimenzije i masa izrađevine	duž. (sač.) 4,2 cm; šir. 1,4 cm; deblj. 0,5 cm
Materijal	Odnosi se na materijal iz kojeg je napravljena izrađevina	kremen
Tehnika	Pokriva iskaze povezane uz materijal te tehniku izrade izrađevina	lomljenje kamena
Stanje	Ovaj atribut služi kako bi se izrađevina opisala s obzirom na fizičko stanje npr. cjelovito, u ulomcima, u dijelovima	cjelovito
Broj ulomaka	Povezano je uz atribut stanje i odnosi se na broj fizičkih ulomaka ili dijelova	1
Mjesto	Atribut se odnosi na navođenje geografskog imena prostora na području kojeg se nalazi lokalitet	Zemunik Donji
Lokalitet	Odnosi se na mjesto pronalaska izrađevine	Zemunik - Gradina
Datum	Datum kada je izrađevina pronađena	13.10.2014.
Kvadrat	Oznaka osnovne istraživačke jedinice	8
Stratigrafska jedinica	Arheološki kontekst u kojem je pronađena izrađevina	43A
Broj kutije	Broj kutije u kojoj se izrađevina čuva	10
Objava	Publikacija u kojoj je izrađevina objavljena	B. Marijanović, K. Horvat, 2016, Početci naseljavanja na području Zemunika, Zemunik u prostoru i vremenu (T 1.5)
Napomena	Bitne napomene uz izrađevinu	kanal uz objekt
Slika	Služi za vizualnu identifikaciju izrađevine	

Sve vrijednosti u tablici odnose se na zapis iz baze koji se vodi pod inventarnim brojem ZM-G459. U bazi se uz sliku se ne navodi autor.

5.5.2. Mapiranje atributa baza podataka i metapodatkovnih elemenata aplikacijskog profila

Mapiranje između atributa istraživačkih baza podataka i metapodatkovnih elemenata aplikacijskog profila provedeno je temeljem semantičkog povezivanja. Međusobna povezanost između atributa i metapodatkovnih elemenata prikazana je Tablicom 25. U tablici su navedena imena atributa istraživačkih baza te imena elemenata aplikacijskog profila. Oznakom + označeni su atributi i elementi koji su međusobno povezani.

Tablica 25.: Mapiranje atributa baza podataka i elemenata aplikacijskog profila

BAZA PODATAKA	IME ATRIBUTA	ELEMENTI APLIKACIJSKOG PROFILA																														
		Jedinstveni identifikator	Ime	Ključne riječi	Autor	Geografsko ime prostora	Mjesto	Ime nalazišta	Tip objekta	Vrsta materijala	Kulturno razdoblje	Uža kulturna odrednica	Vremensko razdoblje	Stoljeće	Ime istraživanja	Istraživač	Planirana lokacija istraživanja	Kronološki period i razdoblje	Ime projekta	Lokacija projekta	Referenca mjesta otkrića	Stratigrafska jedinica	Ime pojavnog oblika	Format	Inačica	Datum pojavnosti	Jezik	Organizacija	Ime jedinice	Pravne informacije	Prava pristupa	Lokacija
A	*B*	*C*	*D*	*E*	*F*	*G*	*H*	*I*	*J*	*K*	*L*	*M*	*N*	*O*	*P*	*R*	*S*	*T*	*U*	*V*	*Z*	*X*	*Y*	*W*	*1*	*2*	*3*	*4*	*5*	*6*	*7*	*8*
Istraživačka baza „Tranzicija i tradicija u špilji Vlakno: Model prijelaza paleolitika u mezolitik na prostoru Sjeverne Dalmacije“	Redni broj	+																														
	Tipologija								+																							
	Tehnologija																															
	Plohak																															
	Dužina																															
	Širina																															
	Debljina																															
	Težina																															
	Sirovina									+																						
	Stratigrafska jedinica																					+										

BAZA PODATAKA	IME ATRIBUTA	ELEMENTI APLIKACIJSKOG PROFILA																														
		Jedinstveni identifikator	Ime	Ključne riječi	Autor	Geografsko ime prostora	Mjesto	Ime nalazišta	Tip objekta	Vrsta materijala	Kulturno razdoblje	Uža kulturna odrednica	Vremensko razdoblje	Stoljeće	Ime istraživanja	Istraživač	Planirana lokacija istraživanja	Kronološki period i razdoblje	Ime projekta	Lokacija projekta	Referenca mjesta otkrića	Stratigrafska jedinica	Ime pojavnog oblika	Format	Inačica	Datum pojavnosti	Jezik	Organizacija	Ime jedinice	Pravne informacije	Prava pristupa	Lokacija
A	*B*	*C*	*D*	*E*	*F*	*G*	*H*	*I*	*J*	*K*	*L*	*M*	*N*	*O*	*P*	*R*	*S*	*T*	*U*	*V*	*Z*	*X*	*Y*	*W*	*1*	*2*	*3*	*4*	*5*	*6*	*7*	*8*
	Sloj																				+											
	Napomena																															
Istraživačka baza „Utvrda u Zemuniku Donjem u srednjem i novom vijeku“	Inventarni broj	+																														
	Vrsta / naziv								+																							
	Naslov		+								+																					
	Razdoblje / datacija										+		+	+																		
	Autor				+																											
	Opis																															
	Dimenzije																															
	Materijal									+																						
	Tehnika																															
	Stanje																															
	Broj ulomaka																															
	Mjesto						+																									
	Lokalitet							+																								
	Datum																															
	Kvadrat																				+											
	Stratigrafska jedinica																					+										
	Broj kutije																															
	Objava																															
	Napomena																															
	Slika																															

5.5.3. Zaključno razmatranje

U mapiranje između atributa istraživačkih baza i metapodatkovnih elemenata aplikacijskog profila uključene su dvije baze podataka. Prva baza podataka (BP1) kreirana je u okviru istraživačkog projekta „Tranzicija i tradicija u špilji Vlakno: Model prijelaza paleolitika u mezolitik na prostoru Sjeverne Dalmacije“, a druga baza podataka (BP2) je kreirana nakon provedenog istraživačkog projekta „Utvrda u Zemuniku Donjem u srednjem i novom vijeku“.

Prva baza je relacijska baza podataka, koja se sastoji od pet osnovnih tablica / entiteta (Vlakno, tipologija, tehnologija, sirovina i plohak), obrasca za unos podataka, upita povezanih uz statističke analize za istraživanje te osnovnog izvještaja. Osnovna tablica je tablica Vlakno koja sadrži 254 zapisa povezanih uz izrađevine. U okviru tablice identificirano je dvanaest atributa za opis izrađevina.

Druga baza je plošnog tipa te je identificirano šest povezanih entiteta (izrađevina, autor, lokalitet istraživanja, kontekst, publikacija i slika). Ova baza podataka sadrži 541 zapis o izrađevinama pronađenim u okviru istraživanja. U ovoj bazi identificirano je dvadeset atributa za opis izrađevina.

Identificirani atributi iz istraživačkih baza podataka mapirani su s metapodatkovnim elementima aplikacijskog profila iz ovog istraživanja kako bi se spoznalo u kojoj mjeri postojeće baze podataka odgovaraju razvijenom aplikacijskom profilu. Međusobno mapiranje napravljeno je na semantičkoj razini.

Mapiranjem prve baze podataka i aplikacijskog profila utvrđeno je da se mogu povezati pet atributa i metapodatkovnih elemenata, i to: BP1: Redni broj i AP: Jedinstveni identifikator, BP1: Tipologija i AP: Tip objekta, BP1: Sirovina i AP: Vrsta materijala, BP1: Stratigrafska jedinica i AP: Stratigrafska jedinica te BP1: Sloj i AP: Referenca mjesta otkrića. Mapiranjem druge baze podataka i aplikacijskog profila utvrđen je veći broj povezanosti između atributa i metapodatkovnih elemenata aplikacijskog profila. Povezanost je utvrđena za: BP2: Inventarni broj i AP: Jedinstveni identifikator; BP2: Vrsta / naziv i AP: Tip objekta; BP2: Autor i AP: Autor, BP2: Materijal i AP: Vrsta materijala, BP2: Mjesto i AP: Mjesto, BP2: Lokalitet i AP: Ime nalazišta, BP2: Kvadrat i AP: Referenca mjesta otkrića te BP2: Stratigrafska jedinica i AP: Stratigrafska jedinica. Kod atributa BP2: Naslov i BP2: Razdoblje / datacija utvrđeno je da ih možemo povezati

s više od jednim elementom iz aplikacijskog profila. Tako BP2: Naslov možemo povezati s AP: Ime i AP: Kulturno razdoblje, a BP2: Razdoblje / dataciju možemo povezati s AP: Kulturno razdoblje, AP: Vremensko razdoblje i AP: Stoljeće.

U okviru prve baze podataka od 12 identificiranih atributa, 5 atributa možemo povezati uz elemente aplikacijskog profila (5/12 = 41,66%), a kod druge baze podataka od 20 identificiranih atributa, uz elemente aplikacijskog profila možemo povezati 10 atributa (10/20 = 50%).

Ovim poglavljem dan je odgovor na postavljeno RQ4.

5.6. Korisnička percepcija razvijenog aplikacijskog profila

Istraživanje u ovom dijelu rada usmjereno je na korisničku percepciju definiranog aplikacijskog profila, a provest će se temeljem definirane metodologije iz cjeline 1.3.5. Sastoji se od utvrđivanja demografskih podataka i digitalne kompetencije[173] ispitanika, identificiranja elemenata za koje korisnici smatraju da su im korisni za pretraživanje digitalnih objekata i korištenje u kontekstu otvorenih istraživačkih podataka te prosudbu korisnosti[174] definiranih elemenata aplikacijskog profila temeljem konkretnih situacija.

Analizom teoretskog dijela o pretraživanju u okviru poglavlja 4.3. utvrđen je Višedimenzionalni model interakcije korisnika i weba, koji se sastoji od tri komponente: korisnika, sučelja i web prostora. Ovo je istraživanje primarno usmjereno na istraživanje korisnika i web prostora, a korisnik je student/ica preddiplomskog ili diplomskog studija. Putem sučelja ostvaruje se interakcija između korisnika i web prostora (digitalnog repozitorija i digitalnih objekata). Web prostor se odnosi na digitalni repozitorij. On sadrži digitalne objekte i sadržajne stavke koji su opisani metapodatcima. Putem metapodataka moguće je ostvariti pretraživanje digitalnih objekata i sadržajnih stavki.

U procesu pretraživanja korisnik primjenjuje taktike (poteze), kod kojih je strategija pretraživanja usmjerena na način primjene pojmova kod pretraživanja. Generički zadatci koje korisnik izvodi odnose se na pronalazak, identifikaciju, odabir i ponovnu uporabu objekta od interesa. Korisnik na temelju prosudbe opisa elemenata digitalnog objekata kao i pripadajućeg imena metapodatkovnih elemenata procjenjuje jesu li podatci koje je dobio relevantni te može li ih koristiti. U okviru cjeline 4.3. utvrđeno je da relevantnost i korisnost možemo povezati putem situacijske relevantnosti koja uspostavlja relaciju između situacije (zadatka, situacije) i digitalnog objekta.

U okviru teoretskog dijela rada utvrđene su digitalne kompetencije kao jedan od bitnih elemenata kod korisničkog pretraživanja. Važnost digitalnih kompetencije za širi

[173] Opću definiciju digitalnih kompetencija daje Ferrari (Ferrari, 2013). Digitalne kompetencije u kontekstu otvorene znanosti možemo opisati kao skup znanja, vještina, stavova i odgovornosti pri korištenju različite digitalne tehnologije i povezanih programskih rješenja u svrhu obavljanja svakodnevnih zadataka, rješavanja problema, komunikacije, upravljanja informacijama i podatcima, suradnje, stvaranja i dijeljenja sadržaja te stvaranja znanja.

[174] Korisnost u okviru ovog rada opisujemo kao korisničku namjeru korištenja pojedinog elementa ili skupa metapodatkovnih elementa u svrhu poduzimanja generičkih zadataka (pronalaska, identifikacije, odabira i ponovne uporabe) za dobivanje podataka potrebnih npr. za razrješenje pojedinih istraživačkih pitanja, prikupljanje podataka u svrhu pisanja rada, za donošenje odluka ili ispunjenje postavljenih ciljeva.

krug korisnika možemo tražiti u omogućavanju kompetencija za kreiranje podataka i informacija, pretraživanje podataka, vrjednovanje i dijeljenje podataka.

Na razini Europe u primjeni je metodološki okvir Digitalnih kompetencija (DigComp), koji pokriva pet osnovnih područja (informacijska i podatkovna pismenost, komunikacija i suradnja, digitalno kreiranje sadržaja, sigurnost i rješavanje problema) i 21 kompetenciju[175]. Povezanost temeljnih funkcionalnih zahtjeva za aplikacijski profil i DigComp digitalnih kompetencija prikazana je u Tablici 26.

Tablica 26.: Povezanost temeljnih funkcionalnih zahtjeva i digitalnih kompetencija

Temeljni funkcionalni zahtjev	DigComp kompetencije
1	*2*
Kreiranje digitalnog objekta	1.3. Upravljati podatcima, informacijama i digitalnim sadržajem 2.4. Surađivati putem digitalne tehnologije 3.1. Razviti digitalni sadržaj 3.2. Integrirati i ponovno razviti digitalni sadržaj 5.1. Prepoznati potrebe i pronalaziti tehnološka rješenja
Otkrivanje i pronalaženje objekta	1.1. Pregledati, pretražiti i filtrirati podatke, informacije i digitalni sadržaj 1.2. Vrjednovati podatke, informacije i digitalni sadržaj
Dijeljenje i ponovna uporaba podataka	2.2. Dijeliti podatke, informacije i sadržaj putem digitalne tehnologije 3.3. Uvažavati te primijeniti autorska prava i dozvole

Digitalne kompetencije u okviru 2. stupca imaju oznake koji su navedene i u okviru metodološkog pristupa DigComp. Svaka kompetencija u okviru DigCompa iskazana je kroz osam razina. Početna razina povezana je uz osnovno znanje, vještine i odgovornost, a najviša je razina povezana uz znanja, vještine i odgovornosti razine doktorata. Razine su grupirane u četiri grupe. Prva i druga razina su u osnovnoj grupi, treća i četvrta razina su u srednjoj grupi, peta i šesta razina su u naprednoj grupi, a sedma i osma razina su u visoko specijaliziranoj grupi.

5.6.1. Uzorak

U ovom su istraživanju kao širi krug korisnika izabrani su studenti/ce preddiplomskog i diplomskog studija. Naime, tijekom istraživanja utvrđeno je da je za

[175] Više o digitalnim kompetencijama može se vidjeti u okviru izvještaja (Vuorikari *et al.*, 2016)

postupke pretraživanja potrebno posjedovati digitalne kompetencije te se od ovog šireg kruga korisnika očekuje primjena otvorenih istraživačkih podataka tijekom budućeg stručnog ili znanstvenog rada. Ciljna populacija šireg kruga korisnika su svi studenti/ce koji studiraju na preddiplomskom i diplomskom studiju arheologije na Sveučilištu u Zadru u akademskoj godini 2018./19., stariji od 18 godina na dan 15. svibnja 2019. Ukupna populacija studenata preddiplomskog i diplomskog studija na preddiplomskom i diplomskom studiju na Sveučilištu u Zadru prema evidenciji iz Informacijskog sustava visokih učilišta je 204 osobe.

Kako je u okviru ovog istraživanja cilj dobivanje detaljnijih podataka o korisničkoj interpretaciji i razumijevanju, odabran je prigodan uzorak. Planirani uzorak ispitanika po pojedinoj grupi je 10 +/- 2. Uzorak čine studenti koji u svom obrazovanju nemaju predviđene teme iz područja digitalnih kompetencija, otvorene znanosti i otvorenih istraživačkih podataka, a pretpostavka je da će svoje stavove izražavati na temelju vlastitog iskustva.

5.6.2. Mjerni instrument i provedba istraživanja

Za potrebe istraživanja korisničke percepcije aplikacijskog profila definiran je novi mjerni instrument, koji se sastoji od četiri cjeline. Prva cjelina povezana je uz istraživanje demografskih podataka i digitalnih kompetencija ispitanika. Druga cjelina povezana je uz istraživanje važnih elemenata za korisnike u kontekstu otvorenih istraživačkih podataka. Treća cjelina povezana je uz prosudbu važnosti elemenata aplikacijskog profila. Četvrta cjelina vezana je uz prosudbu korisnosti aplikacijskog profila na temelju konkretnih zadataka.

U okviru prve cjeline od demografskih će se podataka ispitati: spol, pripadnost dobnoj skupini, koliko vremenski dugo ispitanici koriste osobno računalo / prijenosno računalo kao i druge digitalne uređaje. U svrhu dobivanja uvida u dnevno korištenje ispitat će se koliko ispitanici dnevno koriste uređaje digitalnih tehnologija.

Prva cjelina uključuje i istraživanje digitalnih kompetencija korisnika temeljem samo procjene i njihovim povezivanjem opisa pojedine kompetencije i razine. Za digitalnu kompetenciju je navedeno: ime, kratki opis kompetencije te iskazi povezani uz znanja, vještine i odgovornosti za pojedinu razinu. Opis pojedine razine i iskaza

napravljen je prema opisima iz izvora (Carretero, Vourikari i Punie, 2017) te stavljanjem u kontekst za ispitanike. Za svaku od kompetencija koja je navedena u okviru Tablice 26. stupac br. 2, definirani su opisi te pripadajući iskazi povezani uz znanja, vještine i odgovornost. Opis digitalnih kompetencija dan je kroz Priloge 21., 22., 23., 24., 25. 26., 27., 28. i 29. Ukupno je opisano 9 digitalnih kompetencija.

U okviru druge cjeline cilj je prikupiti podatke o važnim elementima arheoloških entiteta za pretraživanje i ponovnu uporabu iz perspektive šireg kruga korisnika. Korisnicima su dani slikovni primjeri izrađevina i ekofakta, definiran je kratki sadržaj u kojem je navedeno u koju bi se svrhu koristili elementi. Korisnicima je ponuđena tablica s dva stupca. Prvi stupac je namijenjen za upisivanje elementa, a drugi za opisivanje zašto je element bitan.

Treća se cjelina odnosi na prosudbu relevantnosti elemenata aplikacijskog profila od strane šireg kruga korisnika na temelju dosadašnjeg znanja i spoznaja te dobivanje podataka o njihovoj varijabilnosti. Svakom od elemenata iz aplikacijskog profila pridružen je kvantifikator važnosti kojim se verbalno izražava važnost elementa u svrhu evidentiranja, pretraživanja i ponovne uporabe. Odabrana je skala procjene s pet kvantifikatora (nije uopće važan, ponekad važan, umjereno važan, vrlo važan i presudno važan). Primjer metapodatkovnih elemenata i kvantifikatora prikazan je na Slici 11.

METAPODATKOVNI ELEMENTI		MJERNA SKALA				
1.0.	Istraživački sadržaj	nije uopće važan	ponekad važan	umjereno važan	vrlo važan	presudno važan
1.1.	Osnovna struktura					
1.1.1	Jedinstveni identifikator	1	2	3	4	5
1.1.2	Ime	1	2	3	4	5
1.1.3	Ključne riječi	1	2	3	4	5
1.1.4	Autor	1	2	3	4	5
1.1.5	Geografsko ime prostora	1	2	3	4	5

Slika 11.: Primjer povezanosti metapodatkovnih elemenata i kvantifikatora

U procjenu su uključeni svi elementi koji su navedeni u okviru cjeline 5.3.3. Metapodatkovni elementi aplikacijskog profila, ukupno 31 element.

Cilj četvrte cjeline je utvrđivanje korisnosti pojedinog metapodatkovnog elementa u stvarnom okruženju. U uvodnom dijelu ove cjeline navedeno je da će se korisnost istražiti temeljem situacijske relevantnosti, koja podrazumijeva postojanje povezanosti između definiranog zadatka i digitalnog objekta.

Mjerni instrument za četvrtu cjelinu uključuje definiranje konkretnih situacija, sučelja s nazivima elemenata metapodataka te digitalni objekt s pripadajućim podatcima. Situacije proizlaze iz opisa arheoloških entiteta, koji su navedeni u okviru publikacije (Gusar i Vujević, 2016), a njihov pregled je dan Tablicom 27.

Tablica 27.: Pregled pet definiranih situacija korištenih za utvrđivanje korisničke percepcije korisnosti metapodatkovnih elemenata

Situacija	Opis zadatka	Arheološki entitet
1	*2*	*3*
Prva situacija	Radite seminarski rad. Potrebno je pronaći sve arheološke entitete tipa tanjur, koji su nastali temeljem kategorije „Povijest istraživanja“ i pripadaju istraživanju *B. Marijanović, Gradina u Donjem Zemuniku*, odabrati jedan i opisati u radu.	br. 1, str. 44
Druga situacija	Potrebno je pronaći sve arheološke entitete koji pripadaju projektu Utvrda u Zemuniku Donjem u srednjem i novom vijeku, čije se istraživanje odvija na području Zemunik Donji.	br. 48, str. 48
Treća situacija	Za potrebe istraživanja potrebno je pronaći arheološki entitet keramički kalup za olovni projektil, koji je pronađen na Gradini i pripada razdoblju od kraja 15. st. do početka 16. st., u stratigrafskoj jedinici 26, čiji prikazi su dani kroz pdf.	br. 26, str. 46
Četvrta situacija	Radite seminarski rad o Gradini. Poznato vam je da su istraživanje na tu temu radili Gusar Karla i Dario Vujević Njihovo je istraživanje tijekom 2014. godine provedeno na području Zemunik Donji. Sadržaj koji su objavili je u otvorenom pristupu, a dozvolili su upotrebu sadržaja u svrhu znanstvenih istraživanja. Potreban sadržaj se nalazi u repozitoriju u okviru Excel datoteke. Pristupate repozitoriju i radite njegovo pretraživanje.	-
Peta situacija	Radite seminarski rad o keramici koja je pronađena na prostoru Gradine, Zemunik Donji, koja pripada u vremensko razdoblje između 14. i 16. stoljeća, te joj se može pristupiti u otvorenom pristupu. Seminarski rad smije sadržavati samo arheološke entitete koji imaju dozvolu za korištenje uz obavezno navođenje autora i izvora.	-

Ispitanicima je opisana situacija koja nastaje postavljanjem upita te koje sve entitete i elemente korisnik dobiva provedbom upita. Rezultat provedbe upita je digitalni objekt. Digitalni objekt je prikazan putem podataka i metapodatkovnih elemenata aplikacijskog profila. Primjer za prvu situaciju dan je kroz Prilog 30. Ispitanicima je ostavljena mogućnost davanja navoda o elementima koji nedostaju ili za koje smatraju da su suvišni.

Za prikazani digitalni objekt korisnici moraju označiti najvažnije metapodatkovne elemente koje bi oni koristili za pronalazak, identifikaciju, odabir i ponovnu uporabu. Ispitanici su za svaki generički zadatak dobili njegov opis te oznaku koja ga reprezentira (pronalazak – F; identifikacija – I; odabir – S i ponovna uporaba - RU).

5.6.3. Rezultati istraživanja

Provedbu istraživanja sa studentima odobrilo je Etičko povjerenstvo Sveučilišta u Zadru. Istraživanje je provedeno tijekom svibnja 2019. godine. Prije početka ispunjavanja ispitanicima je ukratko objašnjeno u koju se svrhu prikupljaju podatci, na koji će se način štiti njihova anonimnost te na koji način ispunjavaju mjerni instrument. Provedeno je istovremeno za grupu preddiplomskih studenata i grupu diplomskih studenata na Sveučilištu u Zadru. Studenti su podijeljeni u dvije grupe. Grupu A čine studenti preddiplomskog studija, a grupu B studenti diplomskog studija. U nastavku je su prikazani rezultati istraživanja.

5.6.3.1. Demografski podatci

U istraživanju je sudjelovalo 20 studentica/a preddiplomskog (pd) i diplomskog (ds) sveučilišnog studija arheologije Sveučilišta u Zadru ($N_ž = 8$, $N_m = 12$, $N_{pd=} 8$, $N_{ds=} 12$).

Sudionici u ovom prigodnom uzorku pripadaju dobnom rasponu od 18 do 29 godina, najveći broj sudionika pripada dobnom rasponu od 22 do 23 godine (N=7), a pripadnost ispitanika ostalim skupinama navedena je u Tablici 28. Studenti preddiplomskog studija imaju modalnu vrijednost M_{opd}=20,5 godina, a studenti diplomskog studija imaju modalnu vrijednost M_{ods}=23.

Tablica 28.: Distribucija ispitanika po dobi

Grupa	Dobne skupine ispitanika *(N)*							Ukupno
	18 - 19	20 - 21	22-23	24-25	26-27	28-29	29-30	
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
A	2	4	2	0	0	0	0	8
B	0	0	5	5	1	0	1	12
Ukupno	**2**	**4**	**7**	**5**	**1**	**0**	**1**	**20**

U Tablici 29. prikazani su podatci o korištenju digitalne tehnologije (u godinama) od strane ispitanika. Kod studenata preddiplomske razine aktivno korištenje mobilnih uređaja (mu) i osobnih računala (or) ima najveću frekvenciju pojavljivanja za vremensko razdoblje od 9 do 10 godina (N_{mu}=5, N_{or}=3), a kod studenata diplomske razine najveću frekvenciju pojavljivanja ima razdoblje 10 i više godina (N_{mu}=8, N_{or}=7). Ovi nam podatci pokazuju da ispitanici digitalnu tehnologiju aktivno koriste duži niz godina.

Tablica 29.: Distribucija ispitanika s obzirom na korištenje digitalnih tehnologija

Grupa	Vrsta uređaja	Aktivno korištenje digitalnih tehnologija u godinama *(N)*							Ukupno
		<1	1-2	3-4	5-6	7-8	9-10	>10	
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*	*10*
A	Mobilni uređaji	0	0	0	1	1	5	1	8
A	Osobno računalo	0	0	1	0	2	3	2	8
B	Mobilni uređaji	0	0	0	0	2	2	8	12
B	Osobno računalo	0	0	0	0	2	2	7	11
	Ukupno mobilni uređaji	**0**	**0**	**0**	**1**	**3**	**7**	**9**	**20**
	Ukupno osobna računala	**0**	**0**	**1**	**0**	**4**	**5**	**9**	**19**

Rezultati istraživanja dnevnog korištenja digitalnih tehnologija od strane svih ispitanika pokazuju da najveći broj ispitanika dnevno koristi digitalne tehnologije od 3 do 4 sata (N_{3-4}=8), pri čemu je ovo vremensko razdoblje ujedno i minimalno razdoblje dnevnog korištenja digitalnih tehnologija od strane ispitanika. Sljedeće vremensko razdoblje dnevnog korištenja digitalnih tehnologija je od 5 do 6 sati (N_{5-6}=5). Studenti preddiplomskog i diplomskog studija imaju istu modalnu vrijednost dnevnog korištenja digitalne tehnologije od M_o=4 sata.

5.6.3.2. Digitalne kompetencije ispitanika

Prikupljeni podatci o digitalnim kompetencijama ispitanika preddiplomske razine prikazani su u Tablici 30., a diplomske razine u Tablici 31. U tablicama su navedeni

pokazatelji minimalne i maksimalne vrijednosti digitalnih kompetencija te aritmetička sredina za pojedinu digitalnu kompetenciju.

Tablica 30.: Digitalne kompetencije ispitanika preddiplomske razine

Digitalna kompetencija	Razina digitalne kompetencije ispitanika								Deskriptivna statistika		
	A2	A3	A1	A6	A7	A5	A4	A10	min.	max.	M
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*	*10*	*11*	*12*
1.1.	4	2	5	3	5	3	5	4	2	5	3,8750
1.2.	6	3	4	3	5	3	3	4	3	6	3,8750
1.3.	4	3	3	5	4	3	4	4	3	5	3,7500
2.2.	3	2	6	5	3	2	5	3	2	6	3,6250
2.4.	3	2	6	4	5	4	4	4	2	6	4,0000
3.1.	3	2	5	2	5	4	4	3	2	5	3,5000
3.2.	3	1	5	4	5	3	3	3	1	5	3,3750
3.3.	6	2	3	3	4	6	3	4	2	6	3,8750
5.1.	5	3	3	5	5	4	5	3	3	5	4,1250

Na preddiplomskoj razini najviša aritmetička sredina razina utvrđena je za kompetencije: *5.1. Prepoznati potrebe i pronalaziti tehnološka rješenja, 2.4. Surađivati putem digitalne tehnologije, 1.1. Pregledati, pretražiti i filtrirati podatke, informacije i digitalni sadržaj, 1.2. Vrjednovati podatke, informacije i digitalni sadržaj* i *3.3. Uvažavati te primijeniti autorska prava*. Najniža razina aritmetičke sredine utvrđena je za digitalnu kompetenciju *3.1. Razviti digitalni sadržaj*.

Tablica 31.: Digitalne kompetencije ispitanika diplomske razine

Digitalna kompetencija	Razina digitalne kompetencije ispitanika												Deskriptivna statistika		
	B9	B3	B11	B2	B5	B10	B1	B6	B8	B4	B7	B12	min.	max.	M
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*	*10*	*11*	*12*	*13*	*14*	*15*	*16*
1.1.	5	5	4	5	5	3	4	4	4	5	6	3	3	6	4,4167
1.2.	5	4	3	3	5	2	5	4	6	4	4	3	2	6	4,0000
1.3.	3	5	3	3	4	3	4	4	3	5	3	2	2	5	3,5000
2.2.	2	3	4	3	3	3	4	4	2	5	3	2	2	5	3,1667
2.4.	4	4	4	4	4	2	4	4	3	4	4	2	2	4	3,5833
3.1.	4	4	4	4	4	2	3	4	3	3	4	1	1	4	3,3333
3.2.	2	3	3	3	3	2	2	4	2	4	4	2	2	4	2,8333
3.3.	4	5	6	6	5	4	3	4	3	3	4	3	3	6	4,1667
5.1.	5	5	4	5	4	4	3	4	4	4	4	2	2	5	4,0000

Za diplomsku razinu najviše aritmetičke sredine razina utvrđene su za: *1.1. Pregledati, pretražiti i filtrirati podatke, informacije i digitalni sadržaj*, *1.2. Vrjednovati podatke, informacije i digitalni sadržaj, 3.3. Uvažavati te primijeniti autorska prava i 5.1. Prepoznati potrebe i pronalaziti tehnološka rješenja.* Najniža razina aritmetičke sredine utvrđena je za digitalnu kompetenciju *3.2. Integrirati i ponovno razviti digitalni sadržaj*.

Usporedba aritmetičkih sredina digitalnih kompetencija prikazana je pomoću radar grafikona na Slici. 12.

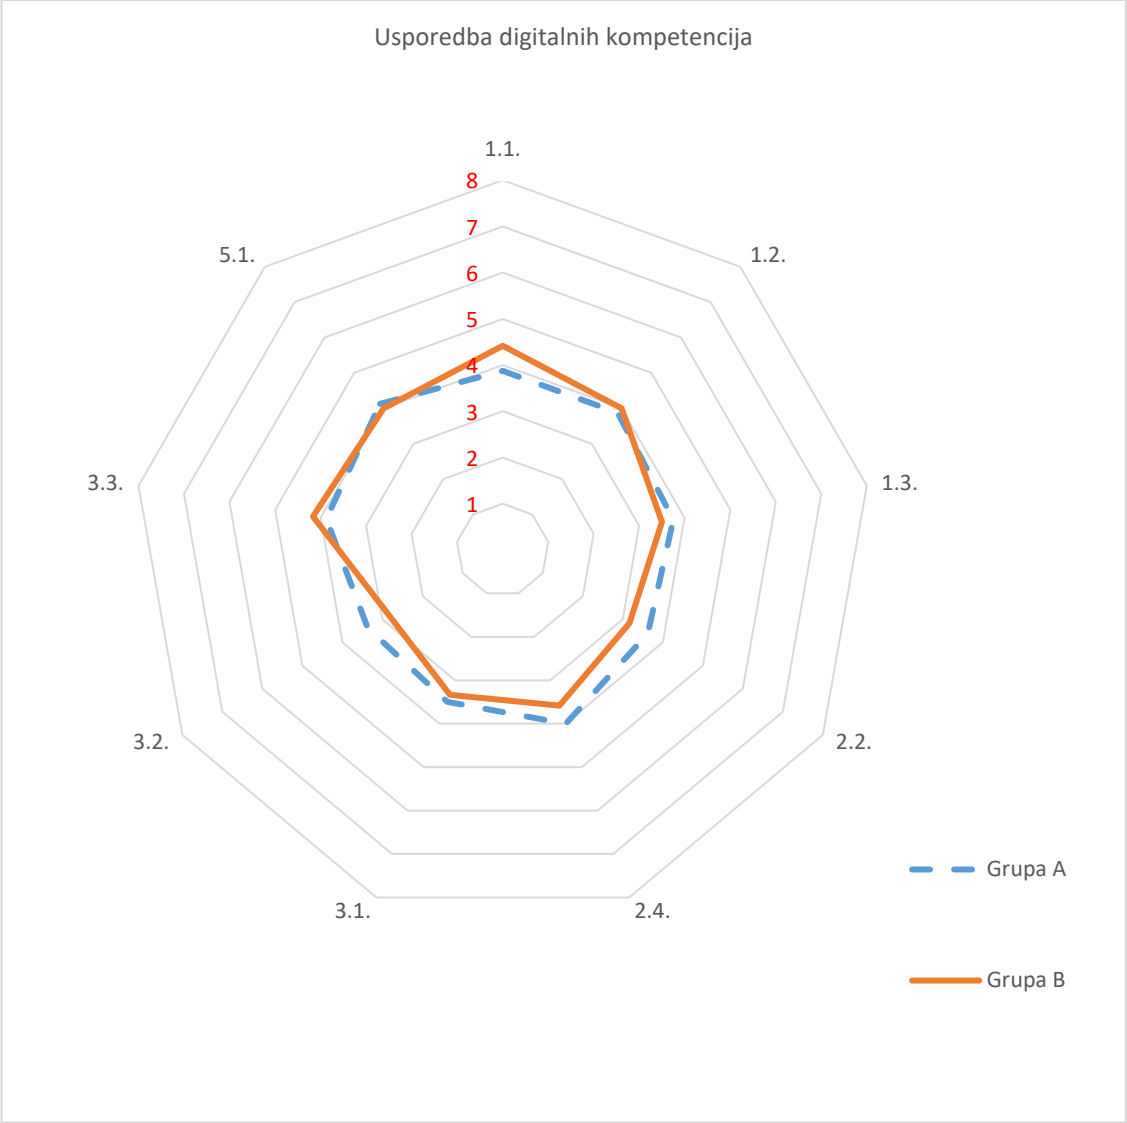

Slika 12.: Usporedba razina digitalnih kompetencija ispitanika

Ispitanici preddiplomskog studija imaju veću razinu digitalnih kompetencija kod kompetencija 1.3., 2.2., 2.4. i 3.2., a ispitanici diplomskog studija imaju veću razinu digitalnih kompetencija kod kompetencija 1.1., 1.2., 3.3. i 5.1.

Kako bi dobili uvid u značaj digitalnih kompetencija za rad s digitalnim objektima i definiranom funkcionalnošću za aplikacijski profil, povezane su utvrđene aritmetičke sredine digitalnih kompetencija s tablicom povezanosti funkcionalnih zahtjeva za aplikacijski profil i digitalne kompetencije. Povezivanje je prikazano u Tablici 32. Za svaki od funkcionalnih zahtjeva izračunata je aritmetička sredina aritmetičkih sredina.

Tablica 32.: Funkcionalni zahtjevi i razine digitalnih kompetencija

Funkcionalni zahtjev	Digitalna kompetencija	Grupa A *(M)*	Grupa B *(M)*	Grupa A *(M)*	Grupa B *(M)*
1	*2*	*3*	*4*	*5*	*6*
Kreiranje digitalnog objekta	1.3.	3,7500	3,5000	3,7500	3,4500
	2.4.	4,0000	3,5833		
	3.1.	3,5000	3,3333		
	3.2.	3,3750	2,8333		
	5.1.	4,1250	4,0000		
Otkrivanje i pronalaženje objekta	1.1.	3,8750	4,4167	3,8750	4,2084
	1.2.	3,8750	4,0000		
Dijeljenje i ponovna uporaba podataka	2.2.	3,6250	3,1667	3,7500	3,6667
	3.3.	3,8750	4,1667		

Usporedbom grupa vidljivo je kako preddiplomski ispitanici imaju nešto višu razinu digitalnih kompetencija za kreiranje digitalnog objekta te dijeljenje i ponovnu uporabu podataka, a ispitanici diplomskog studija imaju nešto višu razinu digitalnih kompetencija povezanu uz otkrivanje i pronalaženje objekata.

5.6.3.3. Važni elementi za ispitanike

Ispitanici su tijekom istraživanja identificirali elemente za koje smatraju da su im korisni za pretraživanje arheološkog entiteta u digitalnom okruženju i u kontekstu otvorenih istraživačkih podataka (ponovna uporaba). Pregled identificiranih elementa kao i njihova frekvencija prikazani su na Slici 13. Slikovni prikaz elemenata i njihovih frekvencija napravljen je uz pomoć digitalnog alata sa stranice TagCrowd[176].

[176] https://tagcrowd.com

Slika 13.: Važni elementi ispitanika

Najznačajnijih 10 elemenata za ispitanike su lokalitet, materijal, vremensko razdoblje, istraživač, ime, tip, dimenzije, kontekst, izgled i opis. Razlozi njihovog imenovanja navedeni su u Tablici 33., u kojoj je navedeno ime elementa ta razlog imenovanja elementa, a u zagradama je dana oznaka ispitanika.

Tablica 33.: Argumentacija ispitanika o imenovanim elementima

Ime elementa	Obrazloženje
Lokalitet	za pretraživanje (A4; A7; A2; B2; B3; B5); identifikacija područja pronalaska (A3; A6; B10); radi usporedbe s ostalim entitetima (B4; B9); određivanje konteksta (B12)
Materijal	za dataciju i određivanje postanka (A5); spoznaja od čega je napravljen entitet (A3; B7; B9; B12); određivanje vrste (A10); za pretraživanje (B1; B3; B5)
Vremensko razdoblje	za pretraživanje (A2; B1; B3; B5); za prepoznavanje entiteta (A1); za određivanje vremenskog okvira (B10; B12)
Istraživač	tko je pronašao entitet (A5); za pretraživanje (A2; B2; B6); za povezivanje entiteta s lokacijom (A6); za objavu i publiciranje (B9)
Ime	za pretraživanje (A4, A7; A6; B3; B6; B9); smještaj u skupinu (A5); za jedinstveno identificiranje (B4); za imenovanje entiteta (B12)
Tip	daje specifičnosti (A4); određivanje vrste (A6); pripadnost (B10)

Ime elementa	Obrazloženje
Dimenzije	procjena veličine (A10; B9); za pretraživanje (B2; B5); klasifikaciju (B7); za procjenu stvarnog izgleda (B10); procjena obilježja (B11)
Kontekst	spoznaja odnosa s drugim entitetima (A10; B3; B10)
Izgled	za pretraživanje (A2)
Opis	za pretraživanje (B2; B5)
Ukrasi	za pretraživanje (B2)
Uporaba	za određivanje svrhe (A1); određivanje namjene (B10)
Kultura	za pretraživanje (B3)
Stanje	fizičko stanje (A5); za pretraživanje (B1)

Za elemente godina nalaska, kvadrat, sloj, prethodna primjena i usporedba nisu dana obrazloženja. Obrazloženje s najvećom frekvencijom pojavljivanja je pretraživanje i pojavljuje se kod 11 elemenata, a ostala obrazloženja pojavljuju se kod pojedinog elementa i vezana su uz funkcionalnu, morfološku, tehnološku i stilističku dimenziju.

5.6.3.4. Procjena elemenata aplikacijskog profila od strane ispitanika

Ispitanici su na temelju dosadašnjeg znanja i spoznaja procijenili relevantnost elemenata aplikacijskog profila u svrhu evidentiranja, pretraživanja i ponovne uporabe. Varijabilnost procjene je izražena frekvencijom. Rezultati su prikazani kroz Prilog 31., a u nastavku su navedeni po kategorijama i grupama aplikacijskog profila.

Kategorija Istraživački sadržaj uključuje grupe osnovna struktura, povijest istraživanja, projekt i kontekst. U okviru grupe osnovna struktura kao presudno važni elementi prepoznati su Kulturno razdoblje (N=16), Vremensko razdoblje (N=15), Vrsta materijala (N=13), Tip objekta (N=12), Ime nalazišta (N=12), Autor (N=9), Stoljeće (N=9). Element Jedinstveni identifikator ima jednaki broj prepoznavanja (N=7) kao presudno važan i vrlo važan. Kao vrlo važni elementi prepoznati su Mjesto (N=11), Ključne riječi (N=8), Geografsko ime prostora (N=8) i Uža kulturna odrednica (N=7). Kao presudno važni elementi u grupi povijest istraživanja utvrđeni su metapodatkovni elementi Kronološki period i razdoblje (N=13) i Istraživač (N=10). Elementi Geografska lokacija (N=10) i Ime istraživanja (N=7) prepoznati su kao vrlo važni. U grupi projekt, element Ime istraživanja prepoznat je kao umjereno važan (N=8), a ovaj element je od jednog korisnika prepoznat kao nevažan. Element Lokacija projekta ima jednak broj prepoznavanja (N=8) vrlo važan kao i umjereno važan. Elementi grupe kontekst Stratigrafska jedinica (N=13) i Referenca mjesta otkrića (N=11) prepoznati su kao presudno važni.

Kategorija digitalni zapis sadržaja sastoji se od pojavnog oblika i digitalne jedinice. Niti jedan element nije prepoznat kao presudno važan kod grupe pojavni oblik. Elementi Format (N=8), Datum pojavnosti (N=8) i Jezik (N=7) prepoznati su kao vrlo važni. Element Jezik je od dvoje ispitanika označen kao nevažan. Umjereno važnim elementima prepoznati su Inačica (N=8) i Organizacija (N=8). Element Inačica je prepoznat od jednog ispitanika kao nevažan.

U okviru grupe digitalna jedinica presudno važnim prepoznat je element Prava pristupa (N=8). Element Lokacija ima jednaki broj (N=8) prepoznavanja kao presudno važan i vrlo važan. Kao vrlo važni elementi prepoznati su Ime jedinice (N=7) i Pravne informacije (N=7).

Pojedini elementi i procjena važnosti prikazani su grafikonom na Slici 14.

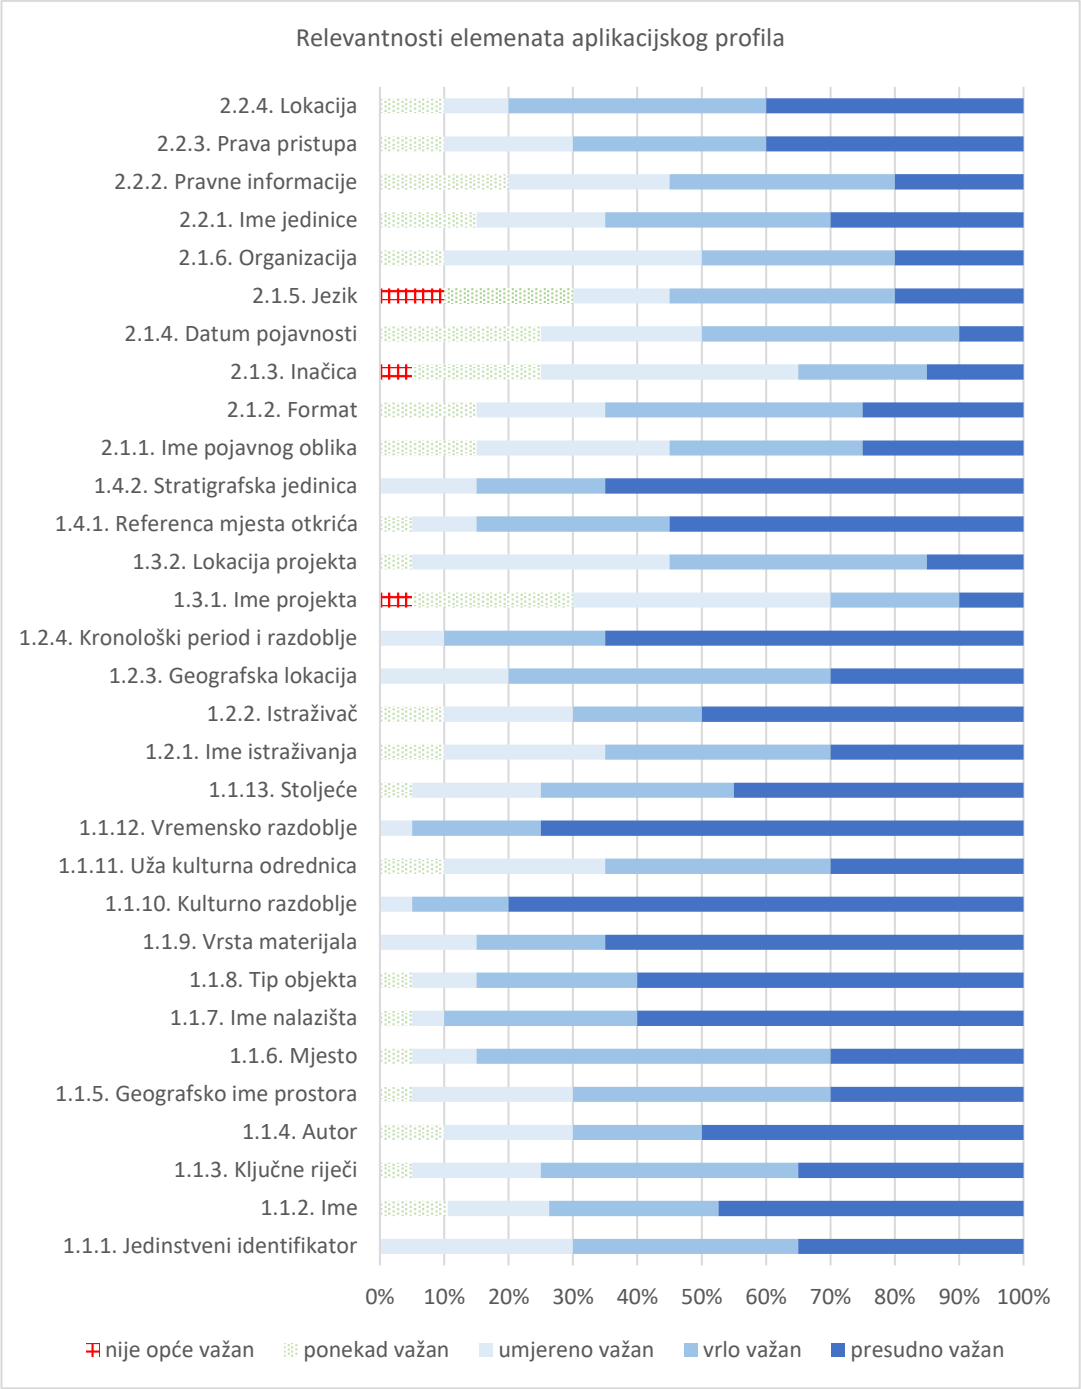

Slika 14.: Rezultati procjene relevantnosti elemenata aplikacijskog profila

U okvirima kategorije istraživački sadržaj kvantifikator s najvećom frekvencijom je presudno važan (N=192), a zatim vrlo važan (N=126), a kod kategorije digitalni zapis sadržaja utvrđeno je da je kvantifikatori s najvećom frekvencijom vrlo važan (N=126), a kvantifikatori presudno važan i umjereno važan imaju jednaki broj frekvencija (N=49).

5.6.3.5. Analiza elementa aplikacijskog profila u stvarnom okruženju

Cilj ovog dijela istraživanja je utvrđivanje važnosti metapodatkovnih elemenata aplikacijskog profila u okvirima stvarnih situacija i provođenja generičkih zadataka (pronalazak - F, identifikacija - I, odabir - S i ponovna uporaba - RU). Rezultati su dani za svaku situaciju putem Priloga 32. (prva situacija), 33. (druga situacija), 34. (treća situacija), 35. (četvrta situacija) i 36. (peta situacija). Za svaku tablicu u prilogu prikazani su elementi aplikacijskog profila, broj utvrđenih frekvencija za svaki generički zadatak razvrstani po grupama A i B, najčešća vrijednost (Mod) za svaki element te kojem generičkom zadatku(icma) pripada najčešća vrijednost. Za izračune χ^2 je korištena web aplikacija objavljena na stranici *Social Science Statistics*[177]. Tablice 34., 35., 36. i 37. sadrže: ukupni rezultat utvrđen kod ispitanika, očekivani zbroj naveden u ( ) i statistiku χ^2 navedenu u [ ].

Prva situacija je povezana uz pretraživanje i kriterijske elemente povijesti istraživanja, a u mjernom instrumentu su bili navedeni podatci za digitalni objekt. Ispitanicima preddiplomskog studija prema najvećoj frekvenciji najvažniji elementi su: ime istraživanja, istraživač, ime istraživanja, geografska lokacija, kronološki period i razdoblje. Ove elemente ispitanici povezuju uz generički zadatak pronalazak. Uz ponovnu uporabu povezuju elemente: ime pojavnog oblika, format, inačica, ime jedinice i prava pristupa. Ispitanicima diplomskog studija prema najvećoj frekvenciji najvažniji elementi su: ime istraživanja, istraživač, ime i ključne riječi. Elemente ime istraživanja istraživač, ime i ključne riječi povezujemo uz generički zadatak pronalazak. Za ponovnu uporabu nije kod ispitanika ove grupe utvrđen niti jedan element. U svrhu utvrđivanja značajnih razlika za ovu situaciju primijenjen je χ^2 test. Rezultati su dani u Tablici 34.

Tablica 34.: Test značajnih razlika za prvu situaciju

Grupa	Generički zadatci				Ukupno
	F	I	S	RU	
1	*2*	*3*	*4*	*5*	*6*
Grupa A	67 (58,66) [1,13]	74 (67,78) [0,57]	32 (48,16) [5,42]	29 (27,20) [0,12]	202
Grupa B	65 (73,14) [0,91]	78 (84,22) [0,46]	76 (59,84) [4,36]	32 (33,80) [0,10]	251
Ukupno	132	152	108	61	453

[177] https://www.socscistatistics.com/tests/chisquare2/default2.aspx

Izračunate su vrijednosti za χ^2=13,0616 i p=0,004505, uz definiranu standardnu značajnost p<0,5, rezultati pokazuju da postoji značajna statistička razlika između analiziranih grupa.

Druga je situacija povezana uz pretraživanje i kriterijske elemente projekta, u mjernom instrumentu ispitanici su imali navedene podatke za digitalni objekt. Ispitanicima preddiplomskog studija prema najvećoj frekvenciji najvažniji elementi su: ime istraživanja, istraživač, kronološki period i razdoblje, ključne riječi i autor. Elemente ime istraživanja, istraživač, kronološki period - razdoblje i autor ispitanici povezuju uz generički zadatak pronalazak. Uz generički zadatak ponovna uporaba ispitanici preddiplomskog studija povezuju elemente stratigrafska jedinica i referenca mjesta otkrića. Ispitanicima diplomskog studija najvažniji elementi prema najvišim frekvencijama su: stoljeće i ime projekta. Ispitanici element stoljeće povezuju uz generički zadatak identifikaciju, a ime projekta povezuju uz generički zadatak odabir. Kod ispitanika diplomskog studija utvrđen je veći broj elemenata (ime pojavnog oblika, format, inačica, datum pojavnosti, jezik, organizacija, ime jedinice i prava pristupa) koji su povezani uz generički zadatak ponovna uporaba. Analiza značajnih razlika za ove grupe temelji se na χ^2 test, a rezultati su dani u Tablici 35.

Tablica 35.: Test značajnih razlika za drugu situaciju

Grupa	Generički zadatci				Ukupno
	F	I	S	RU	
1	*2*	*3*	*4*	*5*	*6*
Grupa A	49 (44,80) [0,39]	64 (59,20) [0,39]	41 (42,80) [0,08]	14 (21,20) [2,45]	168
Grupa B	63 (67,20) [0,26]	84 (88,80) [0,26]	66 (64,20) [0,05]	39 (31,80) [1,63]	252
Ukupno	112	148	107	53	420

Izračunate su vrijednosti su za χ^2=5,5065 i p=0,138248, uz definiranu standardnu značajnost p<0,5, rezultati pokazuju da ne postoji značajna statistička razlika između analiziranih grupa.

Treća situacija je povezana uz pretraživanje i kriterijske elemente osnovne strukture, u mjernom instrumentu ispitanici su imali navedene podatke za digitalni objekt. Ispitanici preddiplomske razine najvažnijim elementima prema najvećim frekvencijama označavaju ime nalazišta, geografsko ime prostora, ključne riječi, ime i jedinstveni identifikator. Elemente ime nalazišta, geografsko ime prostora, ključne riječi, ime i jedinstveni identifikator povezuju uz generički zadatak identifikaciju. Uz generički

zadatak ponovna uporaba povezuju elemente referenca mjesta otkrića i stratigrafska jedinica. Kod ispitanika diplomske razine prema kao najvažniji elementi prema najvišim frekvencijama prepoznati su sljedeći elementi: ime, ključne riječi, istraživač i stoljeće. Elemente istraživač i ključne riječi povezuju uz generički zadatak pronalazak, element ključna riječ je povezana uz generički zadatak identifikaciju. Generičkom zadatku identifikacija pripadaju elementi stoljeće i ime. Uz generički zadatak ponovna uporaba povezuju elemente jedinstveni identifikator, format, inačica, datum pojavnosti i jezik. Analiza značajnih razlika za ove grupe temelji se na χ^2 test, a rezultati su dani u Tablici 36.

Tablica 36.: Test značajnih razlika za treću situaciju

Grupa	Generički zadatci				Ukupno
	F	I	S	RU	
1	*2*	*3*	*4*	*5*	*6*
Grupa A	42 (42,57) [0,00]	80 (61,38) [5,65]	31 (41,18) [2,52]	9 (17,87) [4,40]	162
Grupa B	65 (65,43) [0,00]	78 (96,62) [3,59]	75 (64,82) [1,60]	37 (28,13) [2,80]	255
Ukupno	107	158	106	46	417

Izračunate su vrijednosti za χ^2=20,5584 i p=0,0013, uz definiranu standardnu značajnost p<0,5, rezultati pokazuju da postoji značajna statistička razlika između analiziranih grupa.

Četvrta situacija je povezana uz pretraživanje i kriterijske elemente osnovne strukture, konteksta, pojavnog oblika i digitalne jedinice. Ispitanici nisu imali navedene podatke za digitalni objekt. Ispitanicima preddiplomske razine najvažniji elementi prema najvećim frekvencijama su: ime istraživanja, istraživač i ime projekta. Ove elemente ispitanici povezuju uz generički zadatak pronalazak. Uz generički zadatak ponovna uporaba povezuju elemente: geografska lokacija, kulturno razdoblje, uža kulturna odrednica, stoljeće i organizacija. Ispitanici diplomske razine prema najvećim frekvencijama kao najvažnije elemente prepoznaju: ključne riječi, ime, jedinstveni identifikator i istraživač. Ove elemente povezuju uz generički zadatak identifikacija (jedinstveni identifikator i imena) i pronalazak (ključne riječi, istraživač). Svega dva elementa (ime pojavnog oblika i ime jedinice) su povezana uz generički zadatak ponovna uporaba. Analiza značajnih razlika za ove grupe temelji se na χ^2 test, a rezultati su dani u Tablici 37.

Tablica 37.: Test značajnih razlika za četvrtu situaciju

Grupa	Generički zadatci				Ukupno
	F	I	S	RU	
1	*2*	*3*	*4*	*5*	*6*
Grupa A	52 (52,54) [0,01]	73 (64,31) [1,17]	39 (47,08) [1,39]	26 (26,06) [0,00]	190
Grupa B	73 (72,46) [0,00]	80 (88,69) [0,85]	73 (64,92) [1,01]	36 (35,94) [0,00]	262
Ukupno	125	153	112	62	452

Izračunate su vrijednosti za χ^2=4,4259 i p=0,218999, uz definiranu standardnu značajnost p<0,5, rezultati pokazuju da ne postoji značajna statistička razlika između analiziranih grupa.

Peta situacija je povezana uz pretraživanje i kriterijske elemente osnovne strukture, pojavnog oblika i digitalne jedinice. Ispitanicima preddiplomske razine elementi s najvišom frekvencijom su: istraživač, ime istraživanja i jedinstveni identifikator. Elemente povezuju uz generičke zadatke pronalazak (istraživač te ime istraživanja) i identifikaciju (jedinstveni identifikator). Uz generički zadatak ponovna uporaba povezuju elemente organizacija i pravne informacije. Ispitanicima diplomske razine elementi sa najvećom frekvencijom su: stoljeće, vrsta materijala, ključne riječi i kronološki period. Najznačajnije elemente povezuju uz generičke zadatke pronalazak (ključne riječi, stoljeće te kronološki period i razdoblje), identifikaciju (stoljeće) i odabir (stoljeće). Uz generički zadatak ponovna uporaba povezuju ime pojavnog oblika i ime jedinice. Analiza značajnih razlika za ove grupe temelji se na χ^2 test, a rezultati su dani u Tablici 38.

Tablica 38.: Test značajnih razlika za petu situaciju

Grupa	Generički zadatci				Ukupno
	F	I	S	RU	
1	*2*	*3*	*4*	*5*	*6*
Grupa A	68 (55,36) [2,89]	67 (69,82) [0,11]	44 (49,99) [0,72]	16 (19,83) [0,74]	195
Grupa B	66 (78,64) [2,03]	102 (99,18) [0,08]	77 (71,01) [0,51]	32 (28,17) [0,52]	277
Ukupno	134	169	121	48	472

Izračunate su vrijednosti za χ^2=7,5952 i p=0,055163, uz definiranu standardnu značajnost p<0,5, rezultati pokazuju da ne postoji značajna statistička razlika između analiziranih grupa.

5.6.4. Zaključno razmatranje

Jedan od postavljenih ciljeva ovog rada odnosi se na utvrđivanje korisnosti i prikladnosti razvijenog aplikacijskog profila za širi krug korisnika. Ovaj dio istraživanja realiziran je utvrđivanjem demografskih podataka i digitalnih kompetencija šireg kruga korisnika, identificiranjem elemenata za koje korisnici smatraju da su im korisni za pretraživanje digitalnih objekata i korištenje u kontekstu otvorenih istraživačkih podataka te prosudbu korisnosti definiranih elemenata aplikacijskog profila u okviru stvarnih situacija.

Za širi krug korisnika odabran je prigodan uzorak kojeg čine studenti/ce preddiplomskog i diplomskog studija arheologije na Sveučilištu u Zadru. Uzorak, odnosno populacija studenata/ica izabrana je jer ima digitalne kompetencije potrebne razine za korištenje otvorenih istraživačkih podataka te postoji pretpostavka o njihovom budućem aktivnom korištenju otvorenih istraživačkih podataka u okviru znanstvenog i stručnog rada. Prigodan uzorak podijeljen je u dvije grupe. Prva se grupa odnosi na studente/ice preddiplomskog studija (Grupa A), a druga grupa se odnosi na student/ice diplomskog studija (Grupa B).

U radu se za utvrđivanje digitalnih kompetencija koristio metodološki okvir Digitalnih kompetencija (DigComp). Napravljeno je povezivanje temeljnih funkcionalnih zahtjeva (kreiranje digitalnog objekta, otkrivanje i pronalaženje objekta te dijeljenje i ponovna uporaba podataka) za aplikacijski profil i DigComp digitalnih kompetencija te su u kontekstu ovog rada i otvorenih istraživačkih podataka utvrđene sljedeće važne digitalne kompetencije: 1.1. Pregledati, pretražiti i filtrirati podatke, informacije i digitalni sadržaj, 1.2. Vrjednovati podatke, informacije i digitalni sadržaj, 1.3. Upravljati podatcima, informacijama i digitalnim sadržajem, 2.2. Dijeliti podatke, informacije i sadržaj putem digitalne tehnologije, 2.4. Surađivati putem digitalne tehnologije, 3.1. Razviti digitalni sadržaj, 3.2. Integrirati i ponovno razviti digitalni sadržaj, 3.3. Uvažavati te primijeniti autorska prava i dozvole te 5.1. Prepoznati potrebe i pronalaziti tehnološka rješenja.

Tijekom svibnja 2019. godine provedeno je istraživanje putem mjernog instrumenta. U istraživanju je sudjelovalo 20 ispitanika. Prema vrsti studija, 8 ispitanika je iz skupine preddiplomskog studija, a 12 ispitanika je iz skupine diplomskog studija. U istraživanju je sudjelovalo ukupno 8 žena i 12 muškaraca.

Najveći broj ispitanika u istraživanju pripada dobnom rasponu od 22 do 23 godine (N=7), a modalna vrijednost ispitanika preddiplomskog studija je M_{opd}=20,5 godina i diplomskog studija M_{ods}=23 godine. Iz podataka o korištenju digitalne tehnologije vidljivo je kako ispitanici najčešće koriste digitalne uređaje duži vremenski period (9 i više godina), a na dnevnoj razini modalna vrijednost za jednu i drugu skupinu ispitanika iznosi M_o=4 sata.

Ispitanici preddiplomskog i diplomskog studija trebali bi imati digitalne kompetencije 5. i 6. razine.

Kod ispitanika preddiplomskog studija utvrđene su najviše razine za digitalne kompetencije 5.1, 2.4., 1.1., 1.2, i 3.3. Vrijednosti ovih razina kreću se od max. M=4,1250 do min. M=3,8750. Za ispitanike diplomskog studija utvrđeno je da najviše razine imaju digitalne kompetencije 1.1., 3.3., 1.2. i 5.1. Vrijednosti ovih razina kreću se od max. M=4,4167 do min. M=4,0000. Najniže razine digitalnih kompetencija kod jedne i druge grupe utvrđene su za kompetencije povezene uz kreiranje i integriranje digitalnog sadržaja.

Istraživanjem digitalnih kompetencija koje su u radu povezane uz temeljne zahtjeve za aplikacijski profil, utvrđeno je da ispitanici preddiplomskog i diplomskog studija imaju različite vrste digitalnih kompetencija. Najviša razina kompetencija je utvrđena kod kompetencija ispitanika diplomskog studija i ona je povezana uz otkrivanje i pronalaženje sadržaja (M_{ds}=4,2084, M_{pd}=3,8750,). Ispitanici preddiplomskog studija imaju nešto višu razinu digitalnih kompetencija za kreiranje digitalnog objekta (M_{pd}=3,7500, M_{ds}=3,450) i ponovnu uporabu podataka (M_{pd}=3,7500, M_{ds}=3,667).

Istraživanjem elemenata za koje ispitanici smatraju da su im korisni u digitalnom okruženju za pretraživanje arheoloških entiteta, kao i njihovu ponovnu uporabu, utvrđeno je 20 elemenata. Od ovih 20 elemenata možemo izdvojiti elemente koji imaju veći broj pojavnosti, a to su: lokalitet (N=15), materijal (N=13), istraživač (N=10), vremensko razdoblje (N=10), ime (N=9), tip (N=7), dimenzije (N=6), kontekst (N=4), izgled (N=4) i opis (N=4). Elemente koje su naveli ispitanici najčešće povezuju uz pretraživanje, a ostala obrazloženja su povezana uz funkcionalnu, morfološku, tehnološku i stilističku dimenziju.

Ispitanici su napravili procjenu metapodatkovnih elemenata aplikacijskog profila. U nastavku se navodi pregled presudno važnih elementa aplikacijskog profila po pojedinoj grupi kod osnovne strukture te po grupama pojavni oblik i digitalna jedinica. U

okviru grupe povijest istraživanja kao presudno važni prepoznati su elementi: kronološki period i razdoblje te istraživač. Metapodatkovni elementi grupe projekt nisu od ispitanika prepoznati kao presudno važni elementi. Na razini grupe osnovna struktura presudno važnim elementima prepoznati su sljedeći elementi: kulturno razdoblje, vremensko razdoblje, vrsta materijala, tip objekta, ime nalazišta, autor, stoljeće. Elementi grupe kontekst (stratigrafska jedinica, referenca mjesta otkrića) prepoznati su kao presudno važni. Na razini grupe pojavni oblik niti jedan element nije prepoznat kao presudno važan, a kod grupe digitalna jedinica presudno važnim je označen element prava pristupa i lokacija.

Istraživanje korisnosti definiranih elemenata aplikacijskog profila povezano je uz stvarne situacije i provođenje generičkih zadataka pronalazak, identifikacija, odabir i ponovna uporaba.

U okviru prve situacije ispitanici preddiplomskog i diplomskog studija povezuju elemente aplikacijskog profila s najvećom frekvencijom uz generički zadatak pronalazak. Ispitanicima preddiplomskog studija najvažniji elementi povezani su uz povijest istraživanja (npr. ime istraživanja, istraživač, geografska lokacija i kronološki period), a ispitanicima diplomskog studija najvažniji elementi su povezani uz povijest istraživanja (npr. povijest istraživanja, istraživač) i osnovnu strukturu (npr. ime i ključne riječi). Uz ponovnu uporabu ispitanici preddiplomskog studija povezuju elemente iz grupa pojavni oblik (npr. ime pojavnog oblika, format, inačica) i digitalna jedinica (npr. ime jedinice i prava pristupa). Ispitanici diplomskog studija nisu povezali niti jedan element uz ponovnu uporabu. Utvrđeno je da postoji statistički značajna razlika između ovih dviju grupa u pretraživanju.

Kod druge situacije ispitanici preddiplomskog i diplomskog studija povezuju elemente aplikacijskog profila s najvećom frekvencijom uz generički zadatak pronalazak te generički zadatak odabir. Ispitanicima preddiplomskog studija kod ove su situacije najvažniji elementi povezani uz povijest istraživanja (npr. ime istraživanja, istraživač) i osnovnu strukturu (npr. autor). Kod ispitanika diplomskog studija utvrđeno je da su najvažniji elementi povezani uz osnovnu strukturu (npr. stoljeće) i projekt (npr. ime projekta). Za ponovnu uporabu ispitanicima preddiplomskog studija važni su elementi stratigrafska jedinica i referenca mjesta otkrića, a kod ispitanika diplomskog studija utvrđen je veći broj elemenata iz grupa pojavni oblik (npr. ime pojavnog oblika, format, inačica) i digitalna jedinica (npr. ime jedinice i prava pristupa). Analizom značajnih

razlika nije utvrđeno da postoji statistički značajna razlika pretraživanja između analiziranih grupa.

Rezultati treće situacije pokazuju da ispitanici preddiplomskog studija povezuju elemente s najvećom frekvencijom uz generički zadatak identifikacija, a ispitanici diplomskog studija uz generičke zadatke pronalazak i identifikacija. Ispitanicima preddiplomskog i diplomskog studija kod ove su situacije najvažniji elementi povezani uz osnovnu strukturu (npr. ime nalazišta, ključne riječi, ime, jedinstveni identifikator). Za ispitanike preddiplomskog studija bitni elementi za ponovnu uporabu povezani su uz kontekst (referenca mjesta otkrića i stratigrafska jedinica), a za ispitanike diplomskog studija su povezani uz osnovnu strukturu (npr. jedinstveni identifikator) i grupu pojavni oblik (npr. format, inačica). Analiza značajnih razlika pokazuje da za ovu situaciju postoji statistički značajna razlika u pretraživanju između analiziranih grupa.

Elemente aplikacijskog profila s najvećom frekvencijom ispitanici preddiplomskog studija u četvrtoj situaciji povezuju uz generički zadatak pronalazak, a ispitanici diplomskog studija uz generički zadatak pronalazak i identifikacija. Ispitanici preddiplomskog studija najvažnije elemente povezuju uz povijest istraživanja (npr. ime istraživanja, istraživač) i projekt (npr. ime projekta), a ispitanici diplomskog studija uz povijest istraživanja (npr. geografska lokacija) i osnovnu strukturu (ime, ključne riječi, jedinstveni identifikator). Uz ponovnu uporabu od strane ispitanika preddiplomskog studija povezani su elementi povijesti istraživanja (npr. geografska lokacija), osnovne strukture (npr. kulturno razdoblje, uža kulturna odrednica, stoljeće) i grupe pojavni oblik (npr. organizacija). Bitni elementi za ponovnu uporabu za ispitanike diplomske razine povezani su uz grupe pojavni oblik (npr. ime pojavnog oblika) i digitalna jedinica (npr. ime jedinice). Analiza značajnih razlika za ovu situaciju pokazuje kako nema statistički značajnih razlika između analiziranih grupa.

Ispitanici preddiplomskog i diplomskog studija u okviru pete situacije povezuju elemente s najvećom frekvencijom uz generički zadatak pronalazak i identifikacija, a ispitanici diplomske razine i uz generički zadatak odabir. Ispitanici preddiplomske razine najvažnije elemente povezuju uz povijest istraživanja (npr. istraživač) i osnovnu strukturu (npr. jedinstveni identifikator), a ispitanici diplomskog studija uz povijest istraživanja (npr. kronološki period i razdoblje) i osnovnu strukturu (npr. stoljeće, vrsta materijala). U okviru ove situacije ponovna uporaba od strane ispitanika preddiplomskog i diplomskog studija povezana je uz grupe pojavni oblik (npr. organizacija, ime pojavnog

oblika) i digitalna jedinica (npr. pravne informacije, ime jedinice). Analiza značajnih razlika za ovu situaciju pokazuje da nema statistički značajne razlike između analiziranih grupa.

Ovim poglavljem odgovoreno je na postavljeno RQ5.

6. ZAKLJUČAK

U ovome su radu istraženi metapodatkovni elementi kojima se opisuju arheološki istraživački podatci u kontekstu otvorenosti, otvorenih istraživačkih podataka i digitalnog okruženja. Ciljevi ovog rada odnose se na identifikaciju i vrednovanje metapodatkovnih elemenata iz postojećih shema u području arheologije, preispitivanje metapodatkovnih elemenata kod stručnjaka u području, izradu konkretnog aplikacijskog profila i utvrđivanje njegove korisnosti te prikladnosti kod šireg kruga korisnika. Postavljeno je pet istraživačkih pitanja čiji odgovori proizlaze iz ovog istraživanja.

U teoretskom dijelu istražen je i definiran širi kontekst rada koji se odnosi na osnovne pojmove, znanost i otvorenost te digitalno okruženje i metapodatke u području arheologije.

Sinteza istraživačkih radova o arheološkim podatcima pokazuje kako oni nedvojbeno pripadaju skupini istraživačkih podataka koji se mogu u okviru digitalnog okruženja prikazati u obliku pogodnom za zapisivanje, dugotrajno čuvanje, dostupnost i dijeljenje.

Iako arheologija ima dugu praksu dijeljenja istraživačkih podataka, digitalne tehnologije donose nove izazove u tom procesu. Pored osnovnih preduvjeta pretraživosti, dostupnosti i upotrebljivosti, kao uvjeti za dijeljenje podataka utvrđeni su i postojanje trajnog i jedinstvenog identifikatora te šireg skupa metapodataka.

Važnost metapodataka u području arheologije utvrđena je u pristupu podatcima, pronalaženju podataka, grupiranju podataka, spoznaji i odlučivanju jesu li podatci korisni za ponovnu uporabu, a njihovo evidentiranje je potrebno provesti na razini projekta, sadržaja i datoteke.

U kontekstu otvorenosti i otvorenih istraživačkih podataka za ovaj rad bitan je aplikacijski profil kao metapodatkovna struktura. Važnost aplikacijskog profila utvrđena je u primjeni za određeno područje, ispunjenju funkcionalnih zahtjeva, postojanju entiteta i njihove povezanosti te elementima.

Izvori za elemente i entitete utvrđeni su u metapodatkovnim shemama DC, tDAR, ADS, MOD i CARARE te u znanstvenim istraživanjima i standardima (npr. CDSASM, ICDSAO, citiranje).

U kontekstu znanstveno-istraživačkog rada svrha pretraživanja podataka je utvrđena u pronalaženju činjenica za rješenje pojedinih istraživačkih pitanja, prikupljanju

podataka u svrhu pisanja rada ili donošenju odluka te ostajanju „up-to-date“. Pretraživanje podataka u okvirima ovog rada za području arheologije povezano je uz elemente korisnik, sučelje i web prostor. Sintezom je utvrđeno da su istraživačima u području arheologije podjednako važni klasični i digitalni izvori, a u kontekstu otvorenih istraživačkih podataka važni su im podatci o arheološkim entitetima i njihovi slikovni prikazi, fotografije, zabilješke, geografski podatci, vremenski podatci, stratigrafski podatci kao i kronološki podatci. Činitelji koji su bitni za pretraživanje podataka utvrđeni su u digitalnoj pismenosti, korištenju društvenih mreža, vjerodostojnosti organizacije kao i socio-demografskim karakteristikama.

Stabilna i opće prihvaćena referenca digitalnog objekta povezana je uz trajni identifikator. Postojeća istraživanja ukazuju na upotrebu različitih trajnih identifikatora. Analizirani su pojedini trajni identifikatori (npr. URN, Handle sustav, DOI, ePIC i ARK). Sintezom elemenata za usporedbu trajnih identifikatora utvrđeni su osnovni elementi, a prošireni su elementima povezanima uz dodatne funkcionalnosti.

U istraživačkom dijelu rada dani su odgovori na postavljena istraživačka pitanja te su realizirani postavljeni ciljevi.

Prvo istraživačko pitanje povezano je uz identifikaciju relevantnih elemenata iz postojećih metapodatkovnih shema i znanstvenih istraživanja u kontekstu otvorenih istraživačkih podataka. Relevantni elementi su utvrđeni identifikacijom entiteta i pripadajućih elemenata. Za osnovnu strukturu digitalnog objekta utvrđeni su sljedeći relevantni entiteti: povijest istraživanja, projekt, osnovna struktura i kontekst. Utvrđeno je 99 relevantnih elemenata za osnovnu strukturu digitalnog objekta. Sadržajne stavke digitalnog objekta uključuju sljedeći sadržaj i entitete: osnovni sadržaj (dokumenti i tekstovi, publikacije, tablice, baze podataka, vektorska grafika, rasterska grafika, digitalni video i digitalni zvuk), sadržaj povezan uz prikupljanje arheoloških podataka te terenski rad (prostorno istraživanje, istraživanje bespilotnim letjelicama, geofizička istraživanja, istraživanja podmorja i kronološka istraživanja) i sadržaj koji se odnos na podatkovne analize i vizualizaciju (CAD i 3D modeli). Nakon provedene analize u obzir je uzeto 16 entiteta sa 283 elemenata.

Drugo istraživačko pitanje povezano je uz utvrđivanje važnih elemenata za opisivanje i pretraživanje arheoloških entiteta / digitalnih objekta za stručnjake iz Hrvatske u kontekstu otvorenih istraživačkih podataka. Istraživanje je provedeno na

temelju rezultata iz RQ1, putem Delphi metode i tri iteracije, a sudjelovali su stručnjaci iz područja arheologije. Kroz I. iteraciju utvrđeni su važni elementi za znanstveni i stručni rad stručnjaka, a II. i III. iteracija bila je usmjerena na postizanje konsenzusa o važnim elementima za pretraživanje i ponovnu uporabu. Konsenzus je ostvaren kod 30 elemenata, s time da je najveći broj ostvaren kod osnovne strukture i pripadajućih entiteta (19 elemenata), a kod sadržajnih stavki konsenzus je u najvećem broju ostvaren uz element ime / naslov. Elemente oko kojih je ostvaren konsenzus možemo povezati uz znanstveno-istraživački sadržaj, dok sadržaj koji se odnosi na tehnološki dio stručnjaci ne prepoznaju i ne označavaju kao bitan za njihov znanstveno-istraživački rad.

Aplikacijski profil je definiran temeljem funkcionalnih zahtjeva, modeliranjem domene te utvrđivanjem entiteta, njihove povezanosti i pripadajućih elemenata. Napravljene su dvije konceptualizacije. Prva se odnosi na kreiranje digitalnog objekta, a druga se konceptualizacija odnosi na razinu digitalnog objekta i znanstveno-istraživačkih aktivnosti. Ovaj konceptualni model daje dvije kategorije s pripadajućim entitetima. Prva kategorija je istraživački sadržaj, a pripadaju joj entiteti istraživački rad i izraz, dok je druga kategorija digitalno zapisivanje sadržaja te joj pripadaju entiteti pojavni oblik i digitalna jedinica. Elementi za kategoriju istraživački sadržaj povezani su uz rezultate istraživanja iz RQ2, a elementi za entitete pojavni oblik i izraz definirani su temeljem dodatnog istraživanja znanstvenih članaka. Aplikacijski profil sadrži 31 element. Označen je i opisan putem XML Scheme, a primjer je dan putem XML dokumenta.

Definirani aplikacijski profil sadrži metapodatke kojima su ispunjeni zadatci postavljeni za metapodatke u kontekstu znanstvenih istraživanja i podataka, identificirani u okviru cjeline 4.2.

Treće istraživačko pitanje povezano je uz način osiguravanja prepoznatljivosti i jednoznačnosti zapisa arheološkog entiteta. U okviru aplikacijskog profila definiran je element jedinstveni identifikator i to u okviru grupe Osnovna struktura. Opcionalni identifikator je predviđen ukoliko postoje različite manifestacije pojavnog oblika. Temeljem definiranih elemenata usporedbe provedena je analiza trajnih identifikatora. Trajni identifikator DOI ispunjava najveći broj definiranih elemenata usporedbe. Korištenje DOI-a bilo bi u skladu u odnosu s postojećim istraživanjima u području.

Četvrto istraživačko pitanje usmjereno je na utvrđivanje u kojoj mjeri postojeće baze podataka iz područja arheologije odgovaraju razvijenom aplikacijskom profilu.

Analiza je provedena na temelju dviju baza podataka iz istraživačkih projekata. Baze podataka istraživačkih projekata imaju općenito manji broj atributa u odnosu na broj elemenata aplikacijskog profila. Prva analizirana baza ima 12 atributa, od kojih pet možemo povezati uz aplikacijski profil, a druga analizirana baza ima 20 atributa, od koji 10 možemo povezati uz aplikacijski profil. Rezultati ukazuju na to da su u okviru postojećih baza podataka sadržani pojedini elementi, međutim postojanje samih elemenata ne garantira da se na temelju njih može napraviti cjelovito odlučivanje o uporabljivosti za nova istraživanja.

Peto istraživačko pitanje vezano je uz korisničku percepciju razvijenog aplikacijskog profila s obzirom na prepoznavanje ili neprepoznavanje korisnosti pojedinog metapodatkovnog elementa u okviru stvarnog okruženja. Za širu korisničku skupinu odabrani su studenti/ce preddiplomskog i diplomskog studija. Istraživanje je provedeno na prigodnom uzorku.

Dobiveni rezultati iz istraživanja pokazuju da ispitanici koriste digitalnu tehnologiju duži niz godina. Njihove digitalne kompetencije su na nižoj razini u odnosu na razinu definiranu za njihov stupanj obrazovanja. Digitalne kompetencije potrebne za rad s digitalnim objektima i definiranom funkcionalnošću za aplikacijski profil pripadaju 3. i 4. razini, pri čemu ispitanici preddiplomskog studija imaju nešto višu razinu digitalnih kompetencija za kreiranje digitalnog objekta te dijeljenje i ponovnu uporabu podataka, a ispitanici diplomskog studija imaju nešto višu razinu digitalnih kompetencija za otkrivanje i pronalaženje objekata.

Utvrđeno je 20 elemenata za koje ispitanici smatraju da su im korisni za pretraživanje i ponovnu uporabu arheološkog entiteta u digitalnom okruženju. Nije utvrđen niti jedan element kojim bi mogli napraviti nadopunu aplikacijskog profila.

Rezultati procjene elemenata aplikacijskog profila pokazuje da ispitanici kao presudno važne i vrlo važne prepoznaju elemente sadržane u okviru grupe istraživački sadržaj, a u okviru grupe digitalno zapisivanje sadržaja, elemente prepoznaju najčešće kao vrlo važne.

Istraživanje stvarnog okruženja povezano je uz situacijsku relevantnost i generičke zadatke pretraživanja (pronalazak, identifikaciju, odabir i ponovnu uporabu). Ispitanici preddiplomskog i diplomskog studija povezuju elemente aplikacijskog profila uz generičke zadatke pronalazak i identifikacija. Uz generički zadatak ponovna uporaba

najčešće se povezuju elementi grupe pojavni oblik i digitalna jedinica, u manjem broju se povezuju elementi grupa osnovna struktura, kontekst i povijest istraživanja.

6.1. Znanstveni doprinos

Na razini Hrvatske proveden je mali broj istraživanja povezan uz otvorene istraživačke podatke u području znanosti i istraživanja, a za područje arheologije nije utvrđen niti jedan rad. Također nisu pronađeni radovi koji se odnose na pretraživanje otvorenih istraživačkih podataka od strane širih korisničkih skupina.

Doprinos ovog istraživanja na razini Hrvatske ogleda se u sintetiziranju znanstvenih misli i činjenica povezanih uz arheološke podatke, stanju s otvorenim istraživačkim podatcima u području arheologije, u identifikaciji i analizi pojedinih metapodatkovnih shema te analizi i sintetiziranju spoznaja o pretraživanju podataka u području arheologije. Kroz identifikaciju, opis metapodatkovnih elemenata i izradu aplikacijskog profila doprinos se očituje u metapodatkovnim elementima koji su bitni u području arheologije za opis arheoloških entiteta odnosno digitalnog objekta te u njihovoj realizaciji kao otvorenih istraživačkih podataka. Utvrđeni elementi kao i definirani aplikacijski profil mogu se koristiti u izgradnji istraživačkih podatkovnih repozitorija i na taj način unaprijediti znanstveno-istraživačku infrastrukturu. Utvrđeni elementi imaju doprinos i na široj razini, jer pokazuju bitne elemente za razmjenu istraživačkih podataka korisničke skupine arheologa istraživača iz Hrvatske. Istraživanjem o percepciji aplikacijskog profila kod šire korisničke skupine dan je doprinos kroz identificiranje i određivanje potrebnih digitalnih kompetencija za rad s digitalnim objektom u kontekstu otvorenih istraživačkih podataka te u utvrđenoj razini digitalnih kompetencija i načinu korištenja metapodatkovnih elemenata od strane korisničke skupine.

6.2. Smjernice za daljnja istraživanja

Smjernice za daljnja istraživanja koje proizlaze iz ovog istraživačkog rada odnose se na: metapodatkovne elemente; suradničku interpretaciju podataka; recenzijski postupak, metriku i evaluaciju.

Daljnje istraživanje metapodatkovnih elemenata možemo podijeliti u dva smjera. Prvi se odnosi na proširenje istraživanja metapodatkovnih elemenata u području arheologije za opis događaja kao i za potrebe dijeljenja podataka na široj međunarodnoj razini te dostupnosti širim korisničkim skupinama. Drugi se smjer odnosi na istraživanje sadržajnih stavki i pripadajućih elemenata na istraživačkoj razini u svrhu njihovog boljeg opisa i značenja pojedinog arheološkog entiteta odnosno digitalnog objekta.

Tijekom vremena, realizacijom istraživačkih podatkovnih repozitorija kreirat će se veliki broj digitalnih objekata (odnosno arheoloških entiteta) koji neće uvijek u potpunosti biti opisani bilo na istraživačkoj ili tehničkoj razini. Potrebno je istražiti na koji način i pod kojim je uvjetima moguća suradnička interpretacija (npr. istraživačka ili tehnička razina) i nadopuna otvorenih istraživačkih podatka u području arheologije. Postavlja se pitanje može li suradnička interpretacija biti put za pridobivanje ljudskih resursa koji nedostaju.

Dijeljenje podataka ovisi o raspoloživim istraživačkim podatcima, njihovoj kvaliteti i vjerodostojnosti istraživačkog repozitorija, a za prethodno navedeno bitan je recenzijski postupak. Potrebno je istražiti što je i od čega se sastoji recenzijski postupak za otvorene istraživačke podatke u području arheologije.

Istraživanja u području metrike i evaluacije odnose se na to koja je metrika (npr. indikatori uporabe, utjecaja) najprikladnija za kontekst otvorenih istraživačkih podataka, na određivanje postupaka evaluacije u svrhu unaprjeđenja sustava otvorenih istraživačkih podataka i pripadajućih repozitorija te unaprjeđenja dijeljenja podataka.

7. LITERATURA I KORIŠTENI IZVORI

ADS (2015) *Guidelines for Depositors*, *Guidelines for Depositors*. Objavljeno na: http://archaeologydataservice.ac.uk/advice/FilelevelMetadata.xhtml (pristupljeno: 12. siječnja 2017).

ADS (2017) *Guides to Good Practice*, *Guide to Good Practice*. Objavljeno na: http://guides.archaeologydataservice.ac.uk/g2gp/Main (pristupljeno: 9. lipnja 2017).

Aloia, N. *et al.* (2017) 'Enabling European Archaeological Research: The ARIADNE E-Infrastructure', *Internet Archaeology*, 43. https://doi.org/10.11141/ia.43.11.

Altman, M. i Crosas, M. (2013) 'The Evolution of Data Citation: From Principles to Implementation', *IASSIST Quarterly*, 37, str. 62–70.

Ameyaw, E. E. *et al.* (2016) 'Application of Delphi Method in Construction Engineering and Management Research: A Quantitative Perspective', *Journal of Civil Engineering and Management*, 22(8), str. 991–1000. https:// doi.org/10.3846/13923730.2014.945953.

Amin, A. *et al.* (2008) 'Understanding Cultural Heritage Experts' Information Seeking Needs', u *Proceeding of the 8th ACM/IEEE-CS joint conference on Digital libraries*. New Work, NY: ACM, str. 39–47. https//: doi.org/10.1145/1378889.1378897.

Anić, V. (2004) *Veliki rječnik hrvatskog jezika*. Zagreb: Novi Liber.

Anichini, F. i Gattiglica, G. (2015) 'MAPPA Open Data Metadata. The importance of archaeological background', u Giligny, F. et al. (ur.) *Proceedings of the 42nd Annual Conference on Computer Applications and Quantitative Methods in Archaeology*. Oxford: Archaeopress, str. 361–364.

Atkins, D. i etc. al. (2003) *Revolutionizing Science and Engineering Through Cyberinfrastructure: Report of the National Science Foundation's Blue-Ribbon Advisory Panel on Cyberinfrastructure*. Arlington: National Science Foundation.

Avison, D. E. i Fitzgerald, G. (1998) *Information Systems Development: Methodologies, Techniques, and Tools*. 2nd edn. McGraw-Hill Higher Education.

Banning, E. B. (2002) *The Archaeologist's Laboratory: The Analysis of Archaeological Data*. New York: Kluwer Academic Publishers.

Barclay, A. *et al.* (2016) *A Standard for Pottery Studies in Archaeology*. Medieval Pottery Research Group, Prehistoric Ceramics Research Group, Study Group for Roman Pottery.

Bawden, D. i Robinson, L. (2012) *Introduction to Information Science*. London: Facet Publishing.

Bellini, E. *et al.* (2008) 'Persistent Identifiers distributed system for Cultural Heritage digital objects', *iPRES 2008: The Fifth International Conference on Preservation of Digital Objects*, str. 242–249. https://hdl.handle.net/11353/10.294166.

Biel, J.-I. i Gatica-Perez, D. (2013) 'The YouTube Lens: Crowdsourced Personality Impressions and Audiovisual Analysis of Vlogs', *IEEE Transactions on Multimedia*, 15(1), str. 41–55. https://doi.org/10.1109/TMM.2012.2225032.

Bingwu, C. (2015) 'Archaeological Data and Related Information-Dissemination of Knowledge', u Stone Peter; Hui Zao (ur.) *Sharing Archaeology Academe, Practice and*

the Public. New York: Routledge, str. 57–65.

Blackmar, M. J. (2002) *The Importance & Care of Archeological Records*. Archeology Division of the Nebraska State Historical Society.

Borgman, C. L. (2012) 'The conundrum of sharing research data', *Journal of the American Society for Information Science and Technology*, 63(6), str. 1059–1078. https:// doi.org/10.1002/asi.22634.

Bosančić, B. (2011) *Označavanje teksta starih knjiga na hrvatskom jeziku pomoću TEI standarda*. Sveučilište u Zadru. Objavljeno na: https://www.bib.irb.hr/561774?&rad=561774.

Briney, K. (2015) *Data Management for Researchers: Organize, Maintain and Share your Data for Research Success*. Exeter: Pelagic Publishing.

Buckland, M. K. (1991) 'Information as thing', *Journal of the American Society for Information Science*, 42(5), str. 351–360. https://doi.org/10.1002/(SICI)1097-4571(199106)42:5<351::AID-ASI5>3.0.CO;2-3.

Burton, A. i Treloar, A. (2009) 'Designing for Discovery and Re-Use: the "ANDS Data Sharing Verbs" Approach to Service Decomposition', *The International Journal of Digital Curation*, 4(3), str. 44–56. https://doi.org/10.2218/ijdc.v4i3.124.

Burušić, J. (1999) 'Kakve kategorije rabimo u upitnicima i skalama procjena?', *Društvena istraživanja: časopis za opća društvena pitanja*, 8(1), str. 137–152. Objavljeno na: https://hrcak.srce.hr/31479.

Butler, D. (2016) 'Dutch lead European push to flip journals to open access', *Nature*, 529(7584), str. 13. https://doi.org/10.1038/529013a.

Canham, S. i Ohmann, C. (2016) 'A metadata schema for data objects in clinical research', *Trials*. Trials, 17(1), str. 557. https://doi.org/10.1186/s13063-016-1686-5.

Canny, N. (2015) 'Opening Access to Archaeology', *Archäologische Informationen*, str. 21–29. https://doi.org/10.11588/ai.2015.1.26109.

Caplan, P. (2003) *Metadata Fundamentals for All Librarians*. Chicago: American Library Association.

CARARE (2015) *Training Materials*. Objavljeno na: https://pro.carare.eu/doku.php?id=training-materials.

Carlile, P. R. i Christensen, C. M. (2005) *The Cycles of Theory Building in Management Research*. Objavljeno na: http://www.hbs.edu/faculty/publication files/05-057.pdf.

Carlyle, A. (2006) 'Understanding FRBR As a Conceptual Model', *Library Resources & Technical Services*, 50(4), str. 264–273. https://doi.org/10.5860/lrts.50n4.264.

Carman, J. (2002) *Archeology & Heritage: An Introduction*. London: Continuum.

Carretero, S., Vourikari, R. i Punie, Y. (2017) *DigComp 2.1 The Digital Competence Framework for Citizens with eight proficiency levels and examples of use*. EUR 28558. https://doi.org/10.2760/38842.

Carroll, M. W. (2015) 'Sharing Research Data and Intellectual Property Law: A Primer', *PLOS Biology*, 13(8), str. 1–11. https://doi.org/10.1371/journal.pbio.1002235.

Chaudhri, T. *et al.* (2010) 'Towards a toolkit for implementing application profiles', *Ariadne*, (62). Objavljeno na: http://www.ariadne.ac.uk/issue62/chaudhri-et-al.

Checkland, P. i Holwell, S. (2011) ‘Data, capta, information and knowledge’, in Hinton, M. (ur.) *Introducing Information Management the business approach*. New York: Routledge, str. 47–55.

Chen, Y., Lin, S. C. i Chen, S. (2005) ‘An application practice of the IFLA FRBR model a metadata case study for the National Palace Museum in Taipei’, *Proceedings of the American Society for Information Science and Technology*, 39(1), str. 181–193. https://doi.org/10.1002/meet.1450390120.

Chippindale, C. (2000) ‘Capta and Data: On the True Nature of Archaeological Information’, *American Antiquity*. Society for American Archaeology, 65(4), str. 605–612. https://doi.org/10.2307/2694418.

CIDOC (1992) *International Core Data Standard for Archaeological Objects*. Objavljeno na: https://www.obs-traffic.museum/sites/default/files/ressources/files/CIDOC_Coredata_1992.pdf.

CIFA (2014) *Standard and guidance for the archaeological investigation and recording of standing buildings or structures*. Chartered Institute for Archeologists.

Clare, C. P. i Loucopoulos, P. (1987) *Business Information Systems*. Alfred Waller Ltd.

Corti, L. i et. al. (2014) *Managing and Sharing Research Data: A Guide to Good Practice*. London: Sage Publications Ltd.

Coyle, K. i Backer, T. (2009) *Guidelines for Dublin Core Application Profiles*. Objavljeno na: http://www.dublincore.org/specifications/dublin-core/profile-guidelines/2009-05-18/.

Dappert, A. *et al.* (2017) ‘Connecting the Persistent Identifier Ecosystem : Building the Technical and Human Infrastructure for Open Research’, *Data Science Journal*, (16), str. 28. https://doi.org/10.5334/dsj-2017-028.

Darvill, T. (2007) ‘Research Frameworks for World Heritage Sites and the Conceptualization of Archaeological Knowledge’, *World Archaeology*, 39(3), str. 436–457. https://doi.org/10.1080/00438240701464970.

Data Citation Synthesis Group (2014) ‘Joint Declaration of Data Citation Principles’, u Martone M. (ur.). San Diego: Force 11. https://doi.org/10.25490/a97f-egyk.

Davenhall, C. (2011) *Scientific metadata*, *DCC Digital Curation Reference Manual*. HATII, University of Glasgow, University of Edinburgh, UKOLN, University of Bath.

Davies, T., Perini, F. i Alonso, J. (2013) *Researching the emerging impacts of open data ODDC conceptual framework*. Working Paper #1. Objavljeno na: https://idl-bnc-idrc.dspacedirect.org/bitstream/handle/10625/56313/IDL-56313.pdf.

Delfanti, A. i Pitrelli, N. (2015) ‘Open Science: Revolution or Continuity?’, u Albagali, S., Maciel, M. L., i Abdo, A. H. (ur.) *Open Science, Open Issues*. Rio de Janeiro: IBICT; Unirio, str. 59–86. Objavljeno na: https://ssrn.com/abstract=2619958.

van Deursen, N., Buchanan, W. J. i Duff, A. (2013) ‘Monitoring information security risks within health care’, *Computers & Security*, 37, str. 31–45. https:// doi.org/10.1016/j.cose.2013.04.005.

Dietrich, D. (2010) ‘Metadata Management in a Data Staging Repository’, *Journal of Library Metadata*, 10(2–3), str. 79–98. https://doi.org/10.1080/19386389.2010.506376.

Ding, W., Lin, X. i Zarro, M. (2017) *Information Architecture: The Design and Integration of Information Spaces: Second Edition*, *Synthesis Lectures on Information Concepts, Retrieval, and Services*. Morgan & Claypool Publishers. https://doi.org/10.2200/S00755ED2V01Y201701ICR056.

Djindjian, F. (2000) 'Artefact Analysis', u Stančić, Z. i Veljanovski, T. (ur.) *Computing Archaeology for Understanding the Past. CAA 2000. Computer Applications and Quantitative Methods in Archaeology. Proceedings of the 28th Conference, Ljubljana, April 200 (BAR International Series 931)*. Ljubljana: Archaeopress, Oxford, str. 41–52.

El-Sherbini, M. (2013) *RDA: Strategies for Implementation*. Chicago: ALA Editions.

ESF (2008) *Shared Responsibilities in Sharing Research Data: Policies and Partnerships. Report of an ESF-DFG workshop, 21 September 2007*. Objavljeno na: www.esf.org.

Europska komisija (2012) 'Preporuke komisije od 17. 7. 2012. o pristupu i očuvanju znanstvenih informacija (2012/471/EU)', *Službeni list Europske unije*, str. 39–43.

Europska komisija (2013) *Report of the European Commission Public Consultation on Open Research Data*. Objavljeno na: https://ec.europa.eu/digital-agenda/sites/digital-agenda/files/Report_2013-07-OpenResearchData-Consultation-FINAL1.pdf.

Europska komisija (2015a) *Horizon 2020 AGA - Annotated Model Grant Agreement Version 2.1*. DG Research and Innovation. Objavljeno na: http://ec.europa.eu/research/participants/data/ref/h2020/grants_manual/amga/h2020-amga_en.pdf.

Europska komisija (2015b) *Validation of the results of the public consultation on Science 2.0: Science in Transition*. https://doi.org/10.13140/RG.2.1.4549.0726.

Europska komisija (2018) 'Preporuka komisije (EU) 2018/790 od 25. travnja 2018. o pristupu znanstvenim informacijama i njihovom čuvanju', *Službeni list Europske unije*, str. 12–18.

Farnel, S. i Shiri, A. (2014) 'Metadata for Research Data : Current Practices and Trends', *Proceedings of the International Conference on Dublin Core and Metadata Applications 2014*, str. 74–82.

Fecher, B. i Friesike, S. (2013) *Open Science: One Term, Five Schools of Thought (May 30, 2013). RatSWD_WP_218*. https://doi.org/10.2139/ssrn.2272036.

Fecher, B., Friesike, S. i Hebing, M. (2015) 'What drives academic data sharing?', *PLoS ONE*, 10(2), str. e0118053. https://doi.org/10.1371/journal.pone.0118053.

Fegraus, E. H. *et al.* (2005) 'Maximizing the Value of Ecological Data with Structured Metadata: An Introduction to Ecological Metadata Language (EML) and Principles for Metadata Creation', *Bulletin of the Ecological Society of America*, 86(3), str. 158–168. https://doi.org/10.1890/0012-9623(2005)86[158:MTVOED]2.0.CO;2.

Fernie, K., Gavrilis, D. i Angelis, S. (2013) *The CARARE metadata schema, v.2.0*. https://doi.org/10.5281/zenodo.495365.

Ferrari, A. (2013) *DIGCOMP: A Framework for Developing and Understanding Digital Competence in Europe*. Luxembourg: Join Research Centre - Institute for Prospective Technologies Studies. https://doi.org/10.2788/52966.

Fetherston, A. (2013) *Museum of London Archaeological Archive: Standards 2 Archive*

Components: Standards and Specification 2.7 Digital Data. London: Museum of London.

Floridi, L. (2005) 'Is Semantic Information Meaningful Data', *Philosophy and Phenomenological Research*, LXX(2), str. 351–370. https://hdl.handle.net/2299/1825.

Futrelle, J. (2000) 'Developing metadata standards for scientific data reuse in NCSA's distributed grid architecture', *IGARSS 2000. IEEE 2000 International Geoscience and Remote Sensing Symposium. Taking the Pulse of the Planet: The Role of Remote Sensing in Managing the Environment. Proceedings (Cat. No.00CH37120)*, 3(217), str. 1217–1219. https://doi.org/10.1109/IGARSS.2000.858072.

Gattiglia, G. (2014) 'Think big about data: Archaeology and the Big Data challenge', *Archäologische Informationen*, 38, str. 113–124. https://doi.org/10.11588/ai.2015.1.26155.

Gattiglia, G. (2018) 'Databases in Archaeology', *The Encyclopedia of Archaeological Sciences*, str. 1–4. https://doi.org/10.1002/9781119188230.saseas0147.

Gilliland, A. J. (2011) 'Reflections on the Value of Metadata Archaeology for Recordkeeping in a Global, Digital World.', *Journal of the Society of Archivists*, 32(1), str. 103–118. https://doi.org/10.1080/00379816.2011.563934.

Gilliland, A. J. (2016) 'Setting the Stage', u Baca, M. (ur.) *Introduction to Metadata - Third Edition*. 3ed edn. Los Angeles: Getty Research Institute, str. 1–20.

Gkrous, G. S. i Nikolaidou, M. (2011) 'Building Digital Collections for Archeological Sites: metadata Requirements and CIDOC CRM Extension', u Giannakopulos A. G. i Sakas P. D. (ur.) *Proceedings of the International Conference on Integrated Information (INFO 2011)*. Institute for the Dissemination of Arts and Science, str. 164–168.

Glanznig, M. (2012) 'User Experience Research: Modelling and Describing the Subjective', *Interdisciplinary Description of Complex Systems*, 10(3), str. 235–247. https://doi.org/10.7906/indecs.10.3.3.

Goluchowicz, K. i Blind, K. (2011) 'Identification of future fields of standardisation: An explorative application of the Delphi methodology', *Technological Forecasting and Social Change*, 78(9), str. 1526–1541. https://doi.org/10.1016/j.techfore.2011.04.014.

Greenberg, J. (2003) 'Metadata and the World Wide Web', u Drake, M. A. (ur.) *Encyclopedia of library and information science*. 2nd edn. New York: Taylor & Francis, str. 1876–1888.

Greenberg, J. (2005) 'Understanding Metadata and Metadata Schemes', *Cataloging & Classification Quarterly*, 40(3–4), str. 17–36. https://doi.org/10.1300/J104v40n03_02.

Greenberg, J. *et al.* (2009) 'A Metadata Best Practice for a Scientific Data Repository', *Journal of Library Metadata*, 9, str. 194–212. https://doi.org/10.1080/19386380903405090.

Gregory, K., Groth, P. i Cousijn, H. (2017) *Searching Data: A Review of Observational Data Retrieval Practices - ver. 1*. Cornel University. https://arxiv.org/abs/1707.06937.

Gusar, K. i Vujević, D. (2016) *Utvrda u Zemuniku Donjem u srednjem i novom vijeku - Rezultati arheoloških istraživanja 2014. godine*. Zadar: Sveučilište u Zadru.

Haddad, N. i Akasheh, T. (2005) 'Documentation of Archaeological Sites and

Monuments: Ancient Theatres in Jerash', u Dequal, S. (ur.) *Proceedings of CIPA XXth International Symposium, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. Torino (Italy): CIPA Organising Committee, str. 350–355.

Hakala, J. (2000) 'Dublinski osnovni skup elemenata metapodataka', *Vjesnik bibliotekara Hrvatske*, (43), str. 49–68.

Hansen, H. J. i Fernie, K. (2010) 'Connecting ARcheology and ARchitecture in Europeana (CARARE)', u Ioannides, M. et al. (ur.) *Digital Heritage: Third International Conference, EuroMed 2010, Lemessos, Cyprus, November 8-13, 2010. Proceedings*. Berlin, Heidelberg: Springer, str. 450–462. https://doi.org/10.1007/978-3-642-16873-4_36.

Harold, E. R. (2004) *XML 1.1. Bible*. 3ed edn. Indianapolis: Wiley Publishing, Inc.

Hassenzahl, M. i Tractinsky, N. (2006) 'User experience - A research agenda', *Behaviour and Information Technology*, 25(2), str. 91–97. https://doi.org/10.1080/01449290500330331.

Heery, R. i Patel, M. (2000) 'Application profiles: mixing and matching metadata schemas', *Ariadne*, (25), str. 1–10.

Heimstädt, M., Saunderson, F. i Heath, T. (2014) *Conceptualizing Open Data ecosystems: A timeline analysis of Open Data development in the UK, Diskussionsbeiträge*. Berlin: Freie Universität Berlin, FachbereichWirtschaftswissenschaft. https://hdl.handle.net/10419/96627.

Hein, N., Kroenke, A. i Rodrigues Junior, M. M. (2015) 'Professor Assessment Using Multi-Criteria Decision Analysis', *Procedia Computer Science*, (55), str. 539–548. https://doi.org/10.1016/j.procs.2015.07.034.

Hevner, A. i Chatterjee, S. (2010) *Design Research in Information Systems Theory and Practice*. 1st edn. Boston: Springer. https://doi.org/10.1007/978-1-4419-5653-8.

Hilse, H. i Kothe, J. (2006) *Implementing Persistent Identifiers*. Consortium of European Research Libraries, European Commission on Preservation and Access. https://nbn-resolving.de/urn:nbn:de:gbv:7-isbn-90-6984-508-3-8

Holey, E. A. *et al.* (2007) 'An exploration of the use of simple statistics to measure consensus and stability in Delphi studies', *BMC Medical Research Methodology*, 7(52). https://doi.org/10.1186/1471-2288-7-52.

Hollander, H. (2014) 'The e-Depot for Dutch Archaeology', u Borner, W. i Uhlirz, S. (ur.) *Proceedings of the International Conference on Cultural Heritage and New Technologies (CHNT 18)*. Vienna: Stadt Archäologie Wien.

Howard, A. *et al.* (2018) 'Adult experts' perceptions of telemental health for youth: A Delphi study', *JAMIA Open*, 1(1), str. 67–74. https://doi.org/10.1093/jamiaopen/ooy002.

Hox, J. J. i Boeije, H. R. (2005) 'Data collection, primary versus secondary', u Kimberly, J. L. (ur.) *Encyclopedia of social measurement*. vol. 1. Elsevier, str. 593–599.

Huggett, J. (2015) 'A Manifesto for an Introspective Digital Archaeology', *Open Archaeology*, 1(1), str. 86–95. https://doi.org/10.1515/opar-2015-0002.

IALHI (2013) *Persistent Identification and PIDs*, *Social History Portal*. Objavljeno na:

https://socialhistoryportal.org/bestpractices/pids (pristupljeno: 10. prosinca 2018).

ICOM (2017) *International Core Data Standard for Archaeological Sites and Monuments*, *Documenting the Cultural Heritage*. Objavljeno na: http://archives.icom.museum/objectid/heritage/int.html (pristupljeno: 12. siječnja 2017).

Iden, J., Tessem, B. i Päivärinta, T. (2011) 'Problems in the interplay of development and IT operations in system development projects: A Delphi study of Norwegian IT experts', *Information and Software Technology*, 53(4), str. 394–406. https://doi.org/10.1016/j.infsof.2010.12.002.

Introna, L. D. (1993) 'Information: A hermeneutic perspective', u Whitley, E. A. (ur.) *Proceedings of the First European Conference on Information Systems, {ECIS} 1993, Henley-on-Thames, United Kingdom March 29-30, 1993*. Birmingham: Operational Research Society, str. 171–179.

IRSWG (2015) *White Paper: Recommendations for Standardized International Rights Statements*. International Rights Statements Working Group.

ISO/IEC/IEEE (2010) *Systems and software engineering - Vocabulary ISO/IEC/IEEE 24765:2010(E)*. Geneva: ISO/IEC, IEEE.

ISO (2006) *Information and documentation - Records management processes - Metadata for records - Part 1: Principles (ISO 23081-1:2006(E)*. Geneva: International Standard Organisation.

Ixchel, F. *et al.* (2013) 'The Challenges of Digging Data: A Study of Context in Archaeological Data Reuse', u *JCDL 2013 Proceedings of the 13th ACM/IEEE-CS Joint Conference on Digital Libraries*. New Work: ACM, str. 295–304. https://doi.org/10.1145/2467696.2467712.

Jaana, M. *et al.* (2011) 'Key IT management issues in hospitals: Results of a Delphi study in Canada', *International Journal of Medical Informatics*, 80(12), str. 828–840. https://doi.org/10.1016/j.ijmedinf.2011.07.004.

Jeffrey, S. (2012) 'A new Digital Dark Age? Collaborative web tools, social media and long-term preservation', *World Archaeology*, 44(4), str. 553–570. https://doi.org/10.1080/00438243.2012.737579.

Johnston, L. R. (2017) 'Introduction to Data Curation', u Johnston, L. R. (ur.) *Curating Research Data - Practical Strategies for Your Digital Repository*. Chicago: Association of College and Research Libraries, str. 1–30.

Kadli, J. i Kumbar, B. (2013) 'Library Resources, Services and Information Seeking Behaviour in Changing ICT Environment : A Literature Review', *Library Philosophy and Practice (e-journal)*, Paper 951. Objavljeno na: http://digitalcommons.unl.edu/libphilprac/951.

Kansa, E. C. (2005) 'A community approach to data integration: Authorship and building meaningful links across diverse archaeological data sets', *Geosphere*, 1(2), str. 97. https://doi.org/10.1130/GES00013.1.

Kansa, E. C. (2007) 'An Open Context for Small-scale Field Science', u *Proceedings of the IATUL Conferences*. Objavljeno na: https://docs.lib.purdue.edu/iatul/2007/papers/12/.

Kansa, E. C. *et al.* (2010) 'Googling the Grey: Open Data, Web Services, and

Semantics', *Archaeologies*, 6(2), str. 301–326. https://doi.org/10.1007/s11759-010-9146-4.

Kansa, E. C. (2011) 'New Directions For The Digital Past', u Kansa, Eric C, Kansa, S. W., i Watrall, E. (ur.) *Archaeology 2.0: New Approaches to Communication and Collaboration*. Cotsen Institut of Archeaology Press, str. 1–26.

Kansa, E. C. (2012) 'Openness and archaeology's information ecosystem', *World Archaeology*, 44(4), str. 498–520. https://doi.org/10.1080/00438243.2012.737575.

Kansa, E. C. i Kansa, S. W. (2011) 'Toward a do-it-yourself cyberinfrastructure: Open data, incentives, and reducing costs and complexities of data sharing', u Kansa, E. C., Kansa, S. W., i Watrall, E. (ur.) *Archaeology 2.0: New Approaches to Communication and Collaboration*. Cotsen Institut of Archeaology Press, str. 57–92.

Kansa, S. W. (2015) 'Using Linked Open Data to Improve Data Reuse in Zooarchaeology', *Ethnobiology Letters*, 6(2), str. 224–231. https://doi.org/10.14237/ebl.6.2.2015.467.

Kansa, S. W., Kansa, E. C. i Schultz, M. J. (2007) 'An Open Context for Near Eastern Archaeology', *Near Eastern Archeology*, 70(4), str. 187–193.

Khazraee, E. i Khoo, M. (2011) 'Practice-Based Ontologies: A New Approach to Address the Challenges of Ontology and Knowledge Representation in History and Archaeology', u Garcia-Bariocanal, E. et al. (ur.) *Metadata and Semantic Research*. Berlin, Heidelberg: Springer-Verlag, str. 375–385.

Kim, S. (2018) 'Functional Requirements for Research Data Repositories', *International Journal of Knowledge Content Development & Technology*, 8(1), str. 25–36.

Kimberlin, C. L. i Winterstein, A. G. (2008) 'Validity and reliability of measurement instruments used in research', *American Journal of Health-System Pharmacy*, 65(23), str. 2276–2284. https://doi.org/10.2146/ajhp070364.

Kintigh, K. (2006) 'The Promise and Challenge of Archaeological Data Integration', *American Antiquity*, 71(3), str. 567–578.

Kirasić, D. (2005) 'XML tehnologija i primjena u sustavima procesne informatike', u Kljajić, J. i Baranović, N. (ur.) *Proceedings of the 28th International Convention MIPRO 2005*. Opatija: Croatian Society for Information and Communication Technology, Electronics and Microelectronics, str. 79–99.

Klump, J. i Huber, R. (2017) '20 Years of Persistent Identifiers – Which Systems are Here to Stay?', *Data Science Journal*, 16. https://doi.org/10.5334/dsj-2017-009.

Krippendorff, K. (2004) 'Reliability in Content Analysis: Some Common Misconceptios and Recommendations', *Human Communication Research*, 30(3), str. 411–433.

Kubler, S. *et al.* (2018) 'Comparison of metadata quality in open data portals using the Analytic Hierarchy Process', *Government Information Quarterly*, 35(1), str. 13–29. https://doi.org/10.1016/j.giq.2017.11.003.

Kulasekaran, S. *et al.* (2014) 'Metadata Integration for an Archaeology Collection Architecture', u Moen, W. i Rushing, A. (ur.) *Proc. Int'l Conf. on Dublin Core and Metadata Applications 2014*. Dublin Core Metadata Initiative, str. 53–63.

Lake, M. (2012) ‘Open archaeology’, *World Archaeology*, 44(4), str. 471–478. https://doi.org/10.1080/00438243.2012.748521.

Landeta, J. (2006) ‘Current validity of the Delphi method in social sciences’, *Technological Forecasting and Social Change*, 73(5), str. 467–482. https://doi.org/10.1016/j.techfore.2005.09.002.

Landeta, J. i Barrutia, J. (2011) ‘People consultation to construct the future: A Delphi application’, *International Journal of Forecasting*, 27(1), str. 134–151. https://doi.org/10.1016/j.ijforecast.2010.04.001.

Landis, J. R. i Koch, G. G. (1977) ‘The Measurement of Observer Agreement for Categorical Data’, *Biometrics*, 33(1), str. 159–174.

Lee, D. J. i Stvilia, B. (2014) ‘Developing a Data Identifier Taxonomy’, *Cataloging and Classification Quarterly*, 52(3), str. 303–336. https://doi.org/10.1080/01639374.2014.880166.

Li, Q. (2013) ‘A novel Likert scale based on fuzzy sets theory’, *Expert Systems with Applications*, 40(5), str. 1609–1618. https://doi.org/10.1016/j.eswa.2012.09.015.

Lindberg, D. C. (2008) *The Beginnings of Western Science: The European Scientific tradition in Philosophical, Religious, and Institutional Context, Prehistory to A.D. 1450*. 2nd edn. Chicago: The University of Chicago Press.

Lopez, G., Mazzuci, T. i Sarkani, S. (2014) ‘The Role of System-Thinking Development and Experiential Learning on Enterprise transformation’, *Journal of Information & Knowledge Management*, 13(3), str. 145002101–145002119.

Lucas, G. (2012) *Understanding the Arhaeological Record*. New York: Cambridge University Press.

Luzi, D. *et al.* (2012) ‘Enhancing diffusion of scientific contents: Open data in repositories’, *Grey Journal*, 8(2), str. 71–82.

Madison, O. *et al.* (2009) *Functional Requirements for Bibliographic Records Final Report*. 2 nd. International Federation of Library Accociations and Institutions. Objavljeno na: http://www.ifla.org/VII/s13/frbr/.

Malta, M. C. i Baptista, A. A. (2013) ‘A Method for the Development of Dublin Core Application Profiles (Me4DCAP V0.2): Detailed Description’, u *Proceedings of the DCMI International Conference on Dublin Core and Metadata Applications 2013*. Dublin Core Metadata Initiative, str. 90–102.

Malta, M. C. i Baptista, A. A. (2014) ‘A panoramic view on metadata application profiles of the last decade’, *International Journal of Metadata, Semantics and Ontologies*, 9(1), str. 58–73. https://doi.org/10.1504/IJMSO.2014.059124.

Malta, M. C. i Baptista, A. A. (2017) ‘The Development process of a Metadata Application Profile for the Social and Solidarity Economy’, u Malta, M. C. i Baptista, A. A. (ur.) *Developing Metadata Application Profiles*. Hershey: IGI Global, str. 98–117. https:// doi.org/10.4018/978-1-5225-2221-8.ch005.

Marcial, H. L. i Hemminger, M. B. (2010) ‘Scientific Data Repositories on the Web: An Initial Survey’, *Journal of the American Society for Information Science and Technology*, 61(10), str. 2029–2048. https:// doi.org/10.1002/asi.21339.

Martin, C. i Powell, P. (1992) *Information Systems: A Management Perspective*.

Mcgraw Hill Book Co Ltd.

Martin, V. (2014) *Demystifying eResearch A primer for Librarians*. Santa Barbara: Libraries Unlimited.

Marwick, B. i Birch, S. E. P. (2018) 'A Standard for the Scholarly Citation of Archaeological Data as an Incentive to Data Sharing', *Advances in Archaeological Practice*, 6(2), str. 125–143. https://doi.org/10.1017/aap.2018.3.

May, K. *et al.* (2012) 'Semantic Technologies Enhancing Links and Linked Data for Archaeological Resources', u Zhou, M. et al. (ur.) *Proceedings of the 39th International Conference*. Amsterdam: Pallas Publications, str. 261–272.

May, K., Binding, C. i Tudhope, D. (2015) 'Barriers and opportunities for Linked Open Data use in archaeology and cultural heritage', *Archaologische Informationen*, 38, str. 1–12.

Mayernik, M. S. i Maull, K. E. (2017) 'Assessing the uptake of persistent identifiers by research infrastructure users', *PLoS ONE*, 12(4), str. 1–15. https://doi.org/10.1371/journal.pone.0175418.

McManamon, F. P. (2014) 'Digital Archaeological Data: Ensuring Access, Use, and Preservation', u Smith, C. (ur.) *Encyclopedia of Global Archaeology*. Springer, str. 2124–2128. https://doi.org/10.1007/978-1-4419-0465-2_1219.

Milas, G. (2005) *Istraživačke metode u psihologiji i drugim društvenim znanostima*. Jastrebarsko: Naklada Slap.

Miller, P. (1999) 'The importance of metadata to archaeology: one view from within the Archaeology Data Service', u Dingwall, L. S. et al. (ur.) *Archaeology in the age of the Internet. CAA 97. Computer Applications and Quantitative Methods in Archaeology: Proceedings of the 25th Anniversary Conference, University of Birmingham, April 1997*. Oxford: Archaeopress, str. 133–136.

Miller, T. (2012) *Specify for Archaeology: A Proposed Data Model for Archaeological Collection Database Management*. University of Kansas, UMI, Ann Arbor. https://hdl.handle.net/1808/10845.

Ministarstvo kulture (2010) 'Pravilnik o arheološkim istraživanjima', *Narodne novine*. Narodne novine, (NN 102/2010).

Mitcham, J., Niven, K. i Richards, J. (2010) 'Archiving Archaeology : Introducing the Guides To Good Practice', u Rauber, A. et al. (ur.) *Proceedings of the 7th International Conference on Preservation of Digital Objects*. Vienna: Austria Compuer Society, str. 183–188.

Monteil, A. i Boulétreau, V. (2015) 'Archaeological contents: from open access to open data', u *CAA 2015. KEEP THE REVOLUTION GOING. 43rd Annual Conference on Computer Application and Quantitative Methods In Archaeology. Comite International CAA - Computer Applications and Quantitative Methods in Archaeology*. Sienne, Italy: Universite de Sienne, Italie. https://halshs.archives-ouvertes.fr/halshs-01308043v2.

Mooers, C. N. (1951) 'Zatocoding applied to mechanical organization of knowledge', *American documentation*, 2, str. 20–32.

Mount C. (2004) 'Explicit data and tacit knowledge, exploring the dimensions of archaeological knowledge', u Roche, R. et al. (ur.) *From Megaliths to Metal: Essays in*

Honour of Geogrge Eogan. Oxbow: Exeter.

Muckle, R. J. (2006) *Introducing Archaeology*. Ontario: Broadview Press.

Nelson, M. L. *et al.* (2001) 'A Survey of Complex Object Technologies for Digital Libraries', *NASA Technical Memorandum*, (211426), str. 1–72.

Nicholas, D. *et al.* (2012) 'Digital repositories ten years on: What do scientific researchers think of them and how do they use them?', *Learned Publishing*, 25(3), str. 195–206. https://doi.org/10.1087/20120306.

Nilsson, M. *et al.* (2008) *Harmonization methodology for metadata models*. https://hal.archives-ouvertes.fr/hal-00591548.

Nilsson, M., Baker, T. i Johnston, P. (2008) *The Singapore Framework for Dublin Core Application Profiles*. Objavljeno na: http://dublincore.org/documents/2008/01/14/singapore-framework/ (pristupljeno: 16. studenog 2018).

Ochiai, K., Nagamori, M. i Sugimoto, S. (2014) 'A Metadata Schema Design Model and Support System Based on an Agile Development Model', u Kindling, M. i Greifeneder, E. (ur.) *iConference 2014 Proceedings*. iSchools, str. 921–927. https://doi.org/10.9776/14314.

OECD (2002) *Frascati Manual - Proposed Standard Practice for Surveys on Research and Experimental Development*. Paris: OECD Publication Service.

OECD (2007) *OECD Principles and Guidelines for Access to Research Data from Public Funding*. Paris: OECD Publication Service.

OECD (2015) 'Making Open Science a Reality', u *OECD Science, Technology and Industry Policy Papers, No. 25*. Paris: OECD Publishing. https://doi.org/10.1787/5jrs2f963zs1-en.

Okoli, C. i Pawlowski, S. D. (2004) 'The Delphi method as a research tool: an example, design considerations and applications', *Information & Management*, 42(1), str. 15–29. https://doi.org/10.1016/j.im.2003.11.002.

Open Knowledge (2015) *The Open Definition 2.1*. Objavljeno na: http://opendefinition.org/od/2.1/en/ (Pristupljeno: 10. svibnja 2016).

Pampel, H. i Dallmeier-Tiessen, S. (2014) 'Open Research Data : From Vision to Practice', u Bartling, S. and Friesike, S. (ur.) *Opening Science : The Evolving Guide on How the Internet is Changing Research, Collaboration and Scholarly Publishing*. Springer International Publishing, str. 213–224. http://doi.org/10.1007/978-3-319-00026-8.

Papatheodorou, C. *et al.* (2011) 'A New Architecture and Approach to Asset Representation for Europeana Aggregation: The CARARE Way', u Garcia-Barriocanal, E. et al. (ur.) *Metadata and Semantic Research. MTSR 2011. Communications in Computer and Information Science*. Springer, Berlin, Heidelberg, str. 412–423. https://doi.org/10.1007/978-3-642-24731-6_41.

Park, J.-R. (2009) 'Metadata Quality in Digital Repositories: A Survey of the Current State of the Art', *Cataloging & Classification Quarterly*, 47(3–4), str. 213–228. https://doi.org/10.1080/01639370902737240.

Paskin, N. (2005) 'Digital Object Identifiers for scientific data', *Data Science Journal*,

4, str. 12–20. https://doi.org/10.2481/dsj.4.12.

Peiling, W. (2011) 'Information behavior and seeking', u Ruthven, I. . i Kelly, D. (ur.) *Interactive Information Seeking, Behaviour and Retrieval*. London: Facet Publishing, str. 15–42.

Perrin, K. *et al.* (2014) *A Standard and Guide To Best Practice for Archaeological Archiving in Europe*. Namur, Belgium: Europae Archeaologia Consilium (EAC).

Petrak, J. (2013) 'Otvoreni pristup – put k znanju kao javnom dobru', u *13. okrugli stol o slobodnom pristupu informacija: nakladnici i knjižnice*. https://medlib.mef.hr/id/eprint/2224.

Petrak, J. (2016) *Znanost i znanstveno istraživanje*, *Prezentacija*. Objavljeno na: www.ieee.hr/_download/repository/fer-2.ppt (pristupljeno: 8. travnja 2018).

Peyrard, S., Tramoni, J.-P. i Kunze, J. (2014) 'The ARK Identifier Scheme : Lessons Learnt at the BnF and Question s Yet Unanswered', u Moen, W. i Rushing, A. (ur.) *Proceeding International Conference on Dublin Core and Metadata Applications 2014*. Dublin Core Metadata Initiative, str. 83–94.

St. Pierre, M. i LaPlante, B. (1999) 'Issues in Crosswalking Content Metadata Standards', *Information Standards Quarterly*, 11(1), str. 2–5.

Pinfield, S. (2009) 'Journals and repositories: An evolving relationship?', *Learned Publishing*, 22(3), str. 165–175. https://doi.org/10.1087/2009302.

Prater, S. i Woods, A. (2017) *Fedora Digital Object Model*, *Fedora 3.8 Documentation*. Objavljeno na: https://wiki.duraspace.org/display/FEDORA38/Fedora+Digital+Object+Model (pristupljeno: 22. svibnja 2017).

Qin, J., Ball, A. i Greenberg, J. (2012) 'Functional and Architectural Requirements for Metadata: Supporting Discovery and Management of Scientific Data', u Shou Boon Foo, S. i Overbeek, H. (ur.) *DCMI'12 Proceedings of the 2012 International Conference on Dublin Core and Metadata Applications*. Dublin Core Metadata Initiative, str. 62–71.

Rahem, M. A. i Darrah, M. (2018) 'Using a Computational Approach for Generalizing a Consensus Measure to Likert Scales of Any Size ?', *International Journal of Mathematics and Mathematical Sciences*, 2018, str. 1–7.

Ramos, D., Arezes, P. i Alfonso, P. (2016) 'Application of the Delphi Method for the inclusion of externalities in occupational safety and health analysis', *DYNA*, 83(196), str. 14–20. https://doi.org/10.15446/dyna.v83n196.56603.

Republika Hrvatska (2014) *Nove boje znanja - Strategija obrazovanja, zananosti i tehnologije*. Ministarstvo znanosti, obrazovanja i sporta.

Research Data Alliance (2017) *Digital Objects*, *Term Definition Tool*. Objavljeno na: http://smw-rda.esc.rzg.mpg.de/index.php/Digital_Object (Pristupljeno: 10. siječnja 2017).

Resnik, D. B. (2006) 'Openness versus Secrecy in Scientific Research', *Episteme*, 2(03), str. 135–147. https://doi.org/10.3366/epi.2005.2.3.135.

Richards, J. D. (2015) 'Ahead of the curve : adventures in e-publishing in Internet Archaeology', *Archäologische Informationen*, 38, str. 63–71. https://

doi.org/10.11588/ai.2015.1.26113.

Richards, J. D. i Ryan, N. S. (1985) *Data Processsing in Archaeology*. Cambridge: Cambridge University Press.

Richardson, L.-J. (2014) 'Understanding Archaeological Authority in a Digital Context', *Internet Archaeology*, 38. https://doi.org/10.11141/ia.38.1.

Riva, P., Le Boeuf, P. i Žumer, M. (2016) *FRBR - Library Reference Model*. Den Haag: International Federation of Library Associations and Institutions.

De Roo, B., De Mayer, J. i Bourgeios, J. (2015) 'Information flows as bases for archaeology-specific geodata infrastructures : an exploratory study in Flanders', *Journal of the Association for Information Science and Technology*, 67, str. 1928–1942. https://doi.org/10.1002/asi.23511.

Rüegg, J. *et al.* (2014) 'Completing the data life cycle: using information management in macrosystems ecology research', *Frontiers in Ecology and the Environment*, 12(1), str. 24–30. https://doi.org/10.1890/120375.

Ryan, N. (2001) 'Documenting and validating virtual archaeology', *Archeologia e Calcolatori*, 12, str. 245–273.

Saracevic, T. (2007a) 'Relevance: A Review of the Literature and a Framework for Thinking on the Notion in Information Science. Part II: Nature and Manifestation of Relevance', *Journal of the American Society for Information Science and Technology*, 58(13), str. 1915–1933. https://doi.org/10.1002/asi.20682.

Saracevic, T. (2007b) 'Relevantnost i kako se istraživala', *Vjesnik bibliotekara Hrvatske*, 50(1/2), str. 1–26.

Schaer, P. (2012) 'Better Than Their Reputation? On the Reliability of Relevance Assessments with Students', in Catarci, T. et al. (ur.) *Information Access Evaluation. Multilinguality, Multimodality, and Visual Analytics. CLEF 2012. Lecture Notes in Computer Science*. Berlin, Heidelberg: Springer.

Schlader, R. (2002) 'Archaeological databases: what are they and what do they mean?', u Burenhult, G. i Arvidsson, J. (ur.) *CAA2001. Archaeological Informatics: Pushing The Envelope. Computer Applications and Quantitative Methods in Archaeology. Proceedings of the 29th Conference, Gotland, April 2001*. Oxford: Archaeopress, str. 517–520.

Schloen, D. J. (2001) 'Archaeological Data Models and Web Publication Using XML', *Computer and the Humanities*, 35, str. 123–152. https://doi.org/10.1023/A:1002471112790.

Selhofer, H. i Geser, G. (2014) *D2.1.: First Report on Users' Needs*. ARIADNE Project. Objavljeno na: http://www.ariadne-infrastructure.eu/Resources/D2.1-First-report-on-users-needs.

Selhofer, H. i Geser, G. (2015) *D2.2.: Second Report on Users' Needs*. ARIADNE Project. Objavljeno na: http://legacy.ariadne-infrastructure.eu/resources-2/deliverables/d2-2-second-report-on-users-needs/.

Shaw, R., Corns, A. i Mcauley, J. (2009) 'Archiving Archaeological Spatial Data : Standards and Metadata', *Digital Media*, str. 1–15.

Shen, R. *et al.* (2005) 'Requirements Gathering and Modeling of Domain-Specific

Digital Libraries with the 5S Framework: An Archaeological Case Study with ETANA', u Rauber, A. i et al. (ur.) *Research and Advanced Technology for Digital Libraries*. Berlin, Heidelberg: Springer-Verlag, str. 1–12. https:// doi.org/10.1007/11551362_1.

Silvello, G. (2018) 'Theory and Practice of Data Citation', *Journal of the Society for Information Science and Technology*, 69(1), str. 6–20. https:// doi.org/10.1088/0305-4624/9/3/409.

Skinner, J. (2014) 'Metadata in Archival and Cultural Heritage Settings: A Review of the Literature', *Journal of Library Metadata*, 14(1), str. 52–68. https:// doi.org/10.1080/19386389.2014.891892.

Skov, M. i Ingwersen, P. (2008) 'Exploring information seeking behaviour in a digital museum context', u Borlund, P. et al. (ur.) *ACM International Conference Proceeding Series; Vol. 348*. New York: ACM, str. 110–115. https:// doi.org/10.1145/1414694.1414719.

Smiraglia, R. (2005a) 'Content Metadata - An Analysis of Etruscan Artifacts in a Museum of Archeology', *Cataloging & Classification Quarterly*, 40(3–4), str. 135–151. https://doi.org/10.1300/J104v40n03_07.

Smiraglia, R. (2005b) *Metadata: A Cataloger's Primer 1 st Edition*. New York: Routledge.

Smith, J. R. (2000) *Database Design, Archaeological Classification and Geographic Information Systems: a Case Study From Southeast Queensland*. University of Queensland, Brisbane, Australia.

Snyder, J. (2010) 'Wikipedia as an Academic Reference: Faculty and student Viewpoints', *AMICS 2010 Proceedings*, 17. https://aisel.aisnet.org/amcis2010/17.

Sollins, K. i Masinter, L. (1994) *Functional Requirements for Uniform Resource Names, RFC 1737*. Internet Engineering Task Force. https://doi.org/10.17487/RFC1737.

Spencer, H. (2016) *Thoughts on the sharing of data and research materials and the role of journal policies*. Objavljeno na: http://web.stanford.edu/~vcs/Nov21/hilary_spencer_rdcscsJan2010.pdf (Pristupljeno: 15. listopada 2017).

Sundgren, B. (1973) *An Infological Approach to data Bases*. University of Stockholm.

Sutton, Q. M. (2016) *Archaeology The Science of the Human Past*. 4 th. New York: Routledge.

Swan, A. i Brown, S. (2008) *The skills, roles and career structure of data scientist and curators: an assessment of current practice and future needs: report to the JISC*. Truro: Key Perspectives Ltd.

Tarazona Rua, M. *et al.* (2015) *Access to and Preservation of Scientific Information in Europe*. Luxembourg: Publications Office of the European Union. https:// doi.org/10.2777/975917.

Tastle, J. M. i Tastle, W. J. (2006) 'Extending the Consensus Measure: Analyzing Ordinal Data With Respect to Extrema', *Information Systems Education Journal*, 4(72), str. 3–7.

Tastle, W. J. i Wierman, M. J. (2007) 'Consensus and dissention: A measure of ordinal

dispersion', *International Journal of Approximate Reasoning*, 45(3), str. 531–545. https://doi.org/10.1016/j.ijar.2006.06.024.

tDAR (2013) *Getting Familiar with tDAR*. The Digital Archaeological Record. Objavljeno na: https://docs.tdar.org/display/TDAR/Getting+Familiar+with+tDAR (pristupljeno: 10. listopada 2017).

Thangaratinam, S. i Redman, C. W. (2005) 'The Delphi technique', *The Obstetrician & Gynaecologist*, 7(2), str. 120–125. https://doi.org/10.1576/toag.7.2.120.27071.

The Royal Society (2012) *Science as an open enterprise*. London: The Royal Society.

UNESCO (2003) *Science in the Information Society*. Paris: UNESCO.

Vodopijec, A. i Kranjec, I. (2018) 'Otvoreni istraživački podatci', u Hebrang Grgić, I. (ur.) *Otvorenost u znanosti i visokom obrazovanju*. Školska knjiga, str. 93–112.

Vrana, R. (2011) 'Digital repositories and the future of preservation and use of scientific knowledge', *Informatologia*, 44(1), str. 55–62.

Vuorikari, R. *et al.* (2016) *DigComp 2.0: The Digital Competence Framework for Citizen, Update Phase 1: The Conceptual Reference Model*. Luxembourg: Publication Office of the European Union. https://doi.org/10.2791/11517.

Walker, H. W. (2014) 'Reviews - Gavin Lucas. Understanding the Archaeological Record (Cambridge: Cambridge University Press, 2012, 306pp., 26 gigs., pbk, ISBN 978-0-521-27969-7)', *European Journal of Archaeology*, 17(1), str. 139–144. https://doi.org/10.1179/1461957113Z.00000000061.

Wallace, D. A. (1993) 'Metadata and the Archival Management of Electronic Records : A Review', *Archivaria*, 36, str. 87–110.

Wang, P., Hawk, W. B. i Tenopir, C. (2000) 'Users' interaction with World Wide Web resources : an exploratory study using a holistic approach', *Information Processing and Management*, 36(2), str. 229–251. https://doi.org/10.1016/S0306-4573(99)00059-X.

Watrall, E. (2016) 'Archaeology, the Digital Humanities, and the 'Big Tent.', u Gold, M. K. i Klein, L. F. (ur.) *Debates in the Digital Humanities 2016*. London: University of Minnesota Press, str. 345–358.

Watson, M. (2015) 'When will "open science" become simply "science"?', *Genome biology*, 16(1), str. 101. https://doi.org/10.1186/s13059-015-0669-2.

Webb, S. i McGoohan, C. (2015) *The Digital Repository of Ireland: Requirements Specification*. National University of Ireland Maynooth. http://doi.org/10.3318/DRI.2015.6.

van Wezenbeek, W. J. S. M. *et al.* (2017) *National plan open science*. Dutch Ministy of Education, Culture and Science. https://doi.org/10.4233/uuid:9e9fa82e-06c1-4d0d-9e20-5620259a6c65.

Wilkinson, M. D. *et al.* (2016) 'The FAIR Guiding Principles for scientific data management and stewardship', *Scientific Data*, 3, str. 160018. https://doi.org/10.1038/sdata.2016.18.

Willis, G., Greenberg, J. i White, H. (2012) 'Analysis and Synthesis of Metadata Goals for Scientific Data', *Journal of the American Society for Information Science and Technology*, 63(8), str. 1505–1520. https://doi.org/10.1002/asi.22683.

Wilson, A. (2010) ‘How Much Is Enough: Metadata for Preserving Digital Data’, *Journal of Library Metadata*, 10(2–3), str. 205–217. https://doi.org/10.1080/19386389.2010.506395.

Wise, A. i Miller, P. (1997) *Why Metadata Matters in Archaeology*, *Internet Archeology*. Objavljeno na: http://intarch.ac.uk/journal/issue2/wise/ (pristupljeno: 10. siječnja 2016).

Wittenburg, P. *et al.* (2017) ‘Persistent identifiers: Consolidated assertions. Status of November, 2017.’, *Zenodo*. https://doi.org/10.5281/ZENODO.1116189.

Wood, J. *et al.* (2010) *Riding the wave: How Europe can gain from the rising tide of scientific data.* High Level Expert Group on Scientific Data.

Worrell, J. L., Gangi, P. M. Di i Bush, A. A. (2013) ‘Exploring the use of the Delphi method in accounting information systems research’, *International Journal of Accounting Information Systems*, 14(3), str. 193–208. https://doi.org/10.1016/j.accinf.2012.03.003.

Wright, H. *et al.* (2016) *Archeology and Intellectual Property Rights - CARARE - Project deliverable*. Data Archiving and Networked Services (DANS). https://hdl.handle.net/20.500.11755/b420f7b0-c2e1-4517-86f4-a1e7c08983c0.

Xie, I. (2009) ‘Information Searching and Search Models’, u Bates, J. M. i Maack, M. N. (ur.) *Encyclopedia of Library and Information Sciences, Third Edition*. 3ed edn. Boca Raton: Taylor & Francis, str. 2592–2604.

Yasser, C. M. (2011) ‘An Analysis of Problems in Metadata Records’, *Journal of Library Metadata*, 11(2), str. 51–62. https://doi.org/10.1080/19386389.2011.570654.

Zins, C. (2007) ‘Conceptual approaches for defining data, information, and knowledge’, *Journal of the American Society for Information Science and Technology*, 58(4), str. 479–493. https://doi.org/10.1002/asi.20508.

Zuiderwijk, A. *et al.* (2014) ‘Design principles for improving the process of publishing open data’, *Transforming Government: People, Process and Policy*, 8(2), str. 185–204. https://doi.org/10.1108/TG-07-2013-0024.

Žumer, M., Zeng, M. L. i Salaba, A. (2010) ‘FRBR : A Generalized Approach to Dublin Core Application Profiles’, u Hillmann, D. I. i Lauruhn, M. (ur.) *DC-2010--Pittsburgh Proceedings*. Pittsburgh: Dublin Core Metadata Initiative, str. 21–30.

SAŽETAK

Otvoreni istraživački podatci i otvorena znanost u području arheologije značajni su činitelji znanstveno-istraživačke infrastrukture te se mogu uporabiti za poduzimanje različitih znanstvenih istraživanja u svrhu ostvarenja novih spoznaja i dobrobiti. Za objavu, pretraživanje i pristup otvorenim istraživačkim podatcima važne su metapodatkovne sheme. U Hrvatskoj, otvoreni istraživački podatci u području arheologije i pripadajuće metapodatkovne sheme neistraženo su područje. Cilj ovog rada bio je istražiti i utvrditi važne metapodatkovne elemente u području arheologije u kontekstu otvorene znanosti, razviti konkretni aplikacijski profil te utvrditi njegovu korisnost za širi krug korisnika.

U okviru teoretskog dijela istraženi su i definirani osnovni pojmovi. Nadalje analizirani su i sintetizirani tijek i dosezi u razvoju otvorenosti, životni ciklusa podataka, dijeljenje i ponovna uporaba podataka. Za područje arheologije opisani su digitalno okruženje i njegovi činitelji. Utvrđene su značajne metapodatkovne sheme i pripadajući entiteti. Formulirani su bitni činitelji pretraživanja, prepoznatljivosti i jednoznačnosti u digitalnom okruženju.

Pregledom znanstvenih istraživanja utvrđeni su bitni metapodatkovni elementi. Njih su vrjednovali stručnjaci iz arheologije i to korištenjem Delphi metode te primjenom metrike za ostvarenje konsenzusa. Aplikacijski profil je izrađen na temelju definiranih funkcionalnih zahtjeva, modeliranjem domene, utvrđivanjem entiteta, njihove povezanosti i pripadajućih metapodatkovnih elemenata. Trajni identifikator za aplikacijski profil utvrđen je temeljem definiranih elemenata usporedbe i analizom njihovog ispunjavanja. Provjera aplikacijskog profila i istraživačkih baza podataka provedena je usporedbom elemenata i atributa. Korisnička percepcija aplikacijskog profila istražena je na dvije korisničke skupine (studenti/ce preddiplomskog i diplomskog studija). Za ovaj dio istraživanja bitne su digitalne kompetencije korisničke skupine koje su definirane povezivanjem funkcionalnih zahtjeva aplikacijskog profila i digitalnih kompetencija metodološkog okvira DigComp. Nadalje, korisnička percepcija aplikacijskog profila je istražena pomoću identifikacije važnih elemenata za pretraživanje i ponovnu uporabu, prosudbom važnosti postojećih elemenata aplikacijskog profila i

odabirom metapodatkovnih elemenata u okviru stvarnih situacija za poduzimanje generičkih zadataka.

Provedenim istraživanjem za područje arheologije u kontekstu otvorenosti i otvorenih istraživačkih podataka utvrđeno je 16 bitnih entiteta, s 283 elementa. Za potrebe opisivanja, pretraživanja i ponovne uporabe digitalnih objekta od strane stručnjaka u području postignut je konsenzus kod 30 elemenata. Aplikacijski profil dizajniran je s 31 elementom te opisan XML Schemom i dokumentom. Prepoznatljivost i jednoznačnost arheološkog entiteta putem aplikacijskog profila ostvarena je temeljem jedinstvenog identifikatora. Provedena analiza ukazuje da je najprikladniji trajni identifikator DOI. Postojeće istraživačke baza podataka sadrže pojedine elemente aplikacijskog profila, međutim putem njih nije moguće napraviti cjelovito odlučivanje o uporabljivosti za nova istraživanja. Digitalne kompetencije korisničkih skupina koje su sudjelovale u istraživanju su niže u odnosu na razinu definiranu za njihov stupanj obrazovanja. Utvrđena je razlika u vrsti digitalnih kompetencija koje posjeduju, a elemente aplikacijskog profila povezuju uz generičke zadatke pronalazak i identifikacija.

Ključne riječi: otvoreni istraživački podatci; arheologija; metapodatci; aplikacijski profil; digitalne kompetencije; korisničke skupine.

Summary

In the field of archaeology, Open Research Data and Open Science are significant factors in the scientific-research infrastructure and can be used for conducting various scientific studies for the purpose of gaining new knowledge and benefits. Metadata schemas are important for publishing, searching and accessing open research data. In Croatia, open research data in the field of archaeology and related metadata schemas is an unexplored area. The goal of this thesis was to investigate and identify important metadata elements in the field of archaeology in the context of open science, to develop a concrete application profile and to determine its usefulness for a wider range of users.

Within the theoretical part, basic concepts are explored and defined. Furthermore, the process and the range of the development of openness, data life cycles, data sharing and reuse have been analyzed and synthesized. The digital environment in the field of archaeology is presented, and its factors are described. Significant metadata schemas and

associated entities have been identified. The important factors of search, recognition and uniqueness in digital environment are formulated.

The review of scientific research led to determining the important metadata elements. With the help of experts in archaeology, their importance was evaluated using the Delphi method and the metrics for consensus. The application profile is created, and it is based on the defined functional requirements, domain modeling as well as on the identification of entities, their relationship and the related metadata elements. The persistent identifier for the application profile was determined considering the elements of comparison and the analysis of their fulfilment. The testing of the application profile and the research databases was conducted by using the comparison of elements and attributes. The users' perception of the application profile was explored in two groups of users (undergraduate and graduate students). In this part of the research, digital competencies of the users were important, and they were defined by linking the functional requirements of the application profile with the digital competencies of the methodological framework DigComp. Furthermore, the users' perception of the application profile was explored through the identification of important elements for search and reuse, the assessment of importance of the existing elements of the application profile and the choice of metadata elements within real situations for doing generic tasks.

The research, which was conducted for the field of archaeology in the context of openness and open research data, determined 16 important entities with 283 elements. For the purpose of describing, searching, and reusing digital objects by experts in the aforementioned field, the consensus was reached with 30 elements. The application profile was designed with 31 elements and described by the XML schema and document. The visibility and unigueness of archaeological entity through the application profile is based on a unique identifier. The analysis shows that the permanent identifier DOI is most suitable. The existing databases contain some elements of the application profile; however, they are insufficient for completely reaching a decision concerning their use in new research. Digital competencies of user groups that participated in the research are lower than the level defined for their grade of education. There is a difference in the type of digital competencies they possess, and the elements of the application profile are connected with generic tasks of finding and identification.

Key words: open research data; archaeology; metadata; application profile; digital competencies; user groups.

PRILOZI

Prilog 1. Metapodatkovni elementi entiteta Povijesti istraživanja

Metapodatkovni element	**Područje**	**Kratki opis**	**Uključen u prvu iteraciju istraživanja**	**Prva iteracija**		**Druga iteracija**	**Treća iteracija**	
				Ispunjenje kriterija *(N)*	**Prepoznavanje stručnjaka** *(%)*	**Centralna vrijednost**	**Cns(X)**	**sCns(X)**
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Ime istraživanja	Osnovno	Ime istraživanja	Da	8	*73%*	5	0,816182	**0,944756**
Svrha istraživanja		Kratki opis svrhe i glavnih rezultata istraživanja	Da	8	*73%*	3	0,591798	0,558431
Metode		Planirane metode istraživanja	Da	7	*64%*	3	0,690422	0,586038
Vrsta dokumentacije		Vrsta dokumentacije koje nastaje istraživanjem npr. crteži, fotografije, izvještaji, video,..	Da	8	*73%*	3	0,714357	0,609950
Planirana lokacija istraživanja		Županija, Općina, Mjesto, Adresa	Da	9	*82%*	4,5	0,846949	**0,947460**
Kronološki period i razdoblje		Pripadnost kronološkom razdoblju i periodu	Da	8	*73%*	4,5	0,846949	**0,947460**
Istraživač		Glavni istraživač, voditelj istraživanja	Da	7	*64%*	4	0,693837	**0,834268**
Godina		Godina ili vremenski interval istraživanja	Da	7	*64%*	3,5	0,561705	0,685411
Izvor		Važni prethodni izvori (resursi) na temelju koji nastaje ovaj projekt	Da	6	*55%*	3	0,679241	0,450999

Prilog 2. Metapodatkovni elementi entiteta Projekt

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka *(%)*	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Identifikator projekta	Osnovno	Jedinstveni identifikator projekta / skupa podataka	Da	8	73%	4	0,447807	0,651460
Ime projekta		Ime projekta / skupa podataka u repozitoriju	Da	8	73%	4	0,821320	**0,839677**
Vrsta projekta		Označava vrstu arheološkog istraživanja (npr. pregledno, arhitekturna dokumentacija, istraživanje kolekcija, etnografsko istraživanje)	Da	7	64%	3	0,576350	0,553077
Opis projekta		Kratki sažetak glavnih ciljeva istraživačkog projekta za koji su podatci prikupljeni i kratki opis koji podatci su sadržani	Da	7	64%	3	0,668266	0,611609
Jezik		Indikacija jezika kojim je kreiran skup podataka	Da	3	27%	-	-	-
Vrsta resursa		Oznaka skupa podataka s obzirom na: primarni skup podataka, procesirani skup podataka, interpretacija podataka ili konačni izvještaj	Da	5	45%	-	-	-
Oblik		Format u kojima su sve podatci za ovaj projekt pohranjeni	Da	4	36%	-	-	-
Lokacija projekta	Prostorno	Lokacija istraživanja (država, županija, mjesto, adresa) ili lokacija temelju nacionalnog referalnog sustava (koordinate)	Da	9	82%	4,5	0,808937	**0,912434**
Datum	Vremensko	Označuje se kada je projekt trajao, kada je kreiran skup podataka i kada su podatci procesirani (dodatno uređeni)	Da	8	73%	3	0,561303	0,599856

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka *(%)*	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Organizacija	Organizacijsko	Organizacija koja je nositelj projekta / koja je stvaratelj ovog skupa podataka	Da	7	64%	3	0,571919	0,643986
Izdavač		Detalji o organizaciji koja je publicirala skup podataka	Da	5	45%	-	-	-
Voditelj / Stvaratelj	Autorsko	Detalji o nositelju projekta / stvaratelju ovog skupa podataka (npr. ime, prezime, adresa)	Da	7	64%	4	0,706915	0,775330
Suradnik		Detalji o suradniku na projektu / suradniku za stvaranje skupa podataka (npr. ime, prezime, adresa)	Da	6	55%	3	0,682707	0,564830
Uloga suradnika		Uloga suradnika na projektu ili u stvaranju skupa podataka (npr. istraživač, 3d animator, crtač, arhivist)	Da	5	45%	-	-	-
Pripadnost suradnika organizaciji		Organizacija kojoj pripada suradnik	Da	5	45%	-	-	-
Vlasnička prava	Vlasnička prava	Označava osobu ili organizaciju koja ima autorska prava na kreirani skup podataka	Da	7	64%	3	0,585510	0,418038
Povezanost	Referenca	Ako je skup podataka ovog projekta kojim dijelom vezan uz publicirane ili nepublicirane izvore ovaj element označava referencu na izvorni materijal	Da	8	73%	3	0,669362	0,495128
Primarna mrežna referenca		Jedinstvena adresa resursa u digitalnom okruženju	Da	5	45%	-	-	-
Datum raspoloživosti	Dijeljenje podataka	Označava vremenski termin od kada je skup podatak dostupan drugim korisnicima na slobodno korištenje	Da	5	45%	-	-	-
Licence		Vrsta licence za pristup skupu podataka	Da	5	45%	-	-	-

Prilog 3. Metapodatkovni elementi entiteta Osnovne strukture

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka *(%)*	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Identifikator	Osnovni podatci	Jedinstveni identifikator kojim se arheološki entitet jedinstveno identificira u digitalnom repozitoriju	Da	10	91%	3	0,515437	0,614720
Ime		Deskriptivno ime arheološkog entiteta po kojem se prepoznaje (identificira)	Da	11	100%	4	0,821597	**0,877408**
Osnovni tip		Osnovna pripadnost arheološkog entiteta npr. spomenik, izrađevina, ekofakt	Da	11	100%	4	0,758168	0,795547
Datum kreiranja		Datum osnovnog zapisa i datum zadnjeg dodavanja ili izmjene digitalnog objekta	Da	8	73%	2	0,530377	0,387727
Datum ažuriranja		Datum zadnjeg dodavanja sadržaja o objektu ili izmjene pojedinog podatka	Da	8	73%	2	0,769195	0,199509
Opis (sažetak)		Kratki opis arheološkog entiteta	Da	10	91%	4	0,686451	0,771635
Ključne riječi		Ključne riječi kojima opisujemo arheološki entitet	Da	11	100%	4	0,788923	**0,857190**
Ime arhivskog identifikatora		Ime sustava koji se uporabio za dodjelu identifikacijskog broja npr. Smithsonian trinomial arheološkom entitetu	Da	5	45%	-	-	-
Vrijednost arhivskog identifikatora		Vrijednost identifikatora	Da	5	45%	-	-	-
Stvarno stanje objekta		Stvarno stanje arheološkog entiteta u prirodnom okruženju npr. cjelovit, oštećen,	Da	8	73%	3	0,535870	0,641281

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka *(%)*	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Vrsta istraživanja		Vrsta istraživanja koje je provedeno za arheološki entitet (npr. arheološki pregled, bio-arheološko istraživanje,)	Da	10	91%	4	0,732007	0,757817
Podrijetlo		Slobodni tekst o promjenama vlasništva i promjenama značajnim za autentičnost, integritet i interpretaciju arheološkog entiteta	Da	7	64%	2	0,578953	0,340947
Status		Odnosi se na status digitalno objekta u repozitoriju kroz životni ciklus npr. u pripremi, aktivan, aktivan i dostupan javnosti, obrisan	Da	6	55%	1	0,821597	0,117065
Lokacija, Geografsko ime prostora	Prostorno	Geografski termini koji pomažu kod pronalaženja, identificiranja, arheološkog entiteta npr. Špilja Vindija; Donja Voća	Da	10	91%	5	1,000000	**1,000000**
Lokacija, Mjesto		Geografska lokacija država, županija, mjesto, adresa	Da	10	91%	5	1,000000	**1,000000**
Katastarska referenca		Katastarska čestica lokacije nalaska arheološkog entiteta	Da	9	82%	3,5	0,566426	0,705629
Lokacija, Geografske koordinate (širina, visina, dužina)		Koordinate nalazišta (širina, visina, dužina) arheološkog entiteta	Da	10	91%	3	0,522109	0,661499
Ime nalazišta	Nalazište	Ime nalazišta arheološkog entiteta	Da	10	91%	5	0,936033	**0,982487**
Vrsta nalazišta		Vrsta nalazišta (npr. arhitektonski kompleks, poljoprivreda, industrijske strukture, lov, rudnici, grobnice)	Da	10	91%	3,5	0,693837	0,758807
Dodatne ključne riječi nalazišta		Ključne riječi nalazišta arheološkog entiteta koje pridruži autor, a nisu navedene kroz vrstu nalazišta	Da	7	64%	3	0,551319	0,578648

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka *(%)*	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Tip objekta	Tehnološko, funkcionalno i stilističko	Termin po kojemu će se arheološki entitet indeksirati, interpretirati temeljem funkcionalnog ili deskriptivnog kriterija	Da	10	91%	5	0,785548	**0,927243**
Kategorija objekta		Funkcionalna ili deskriptivna kategorija kojoj arheološki entitet pripada	Da	8	73%	2,5	0,522109	0,435551
Stanje objekta		U kakvom stanju je arheološki entitet u stvarnosti (npr. neoštećen,..)	Da	7	64%	3,5	0,623167	0,626473
Vrsta materijala		Glavni materijal iz kojeg je napravljen arheološki entitet (npr. keramika, kamen, staklo)	Da	10	91%	4	0,676187	**0,830574**
Dodatne vrste materijala		Dodatni materijal iz kojeg je napravljen arheološki entitet	Da	8	73%	4	0,547348	0,766226
Ukrasi		Opis ukrasa koji postoji na arheološkom entitetu	Da	7	64%	4	0,706915	0,775330
Dimenzije - opseg		Opseg arheološkog entiteta (npr. mm)	Da	6	55%	3,5	0,520290	0,681716
Dimenzije (vrsta i vrijednost)		Vrsta mjere (npr. dužina, širina) te njezina vrijednost (npr. mm, cm)	Da	9	82%	3,5	0,520290	0,681716
Kulturno razdoblje	Kulturno područje	Kulturno razdoblje kojem pripada arheološki entitet (npr. željezno doba, rana antika, kasni srednji vijek)	Da	11	100%	5	0,936033	**0,982487**
Uža kulturna odrednica		Dodatni kulturni pojam (npr. vučedolska kultura, Langobardi, ..)	Da	9	82%	5	0,846949	**0,947460**
Vremensko razdoblje	Vremensko razdoblje	Vremensko razdoblje (npr. paleolitik, mezolitik, neolitik, brončano doba, ..)	Da	10	91%	5	0,553222	**0,874065**
Stoljeće		Stoljeće kojemu arheološki entitet pripada	Da	10	91%	5	0,553222	**0,874065**

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka *(%)*	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Nekalibrirani datum		Konvencionalni datum	Da	9	82%	3	0,620871	0,538213
Kalibrirani datum		Kalendarski datum	Da	9	82%	3	0,620871	0,538213
Metoda određivanja datuma		Znanstvena metoda temeljem koje je određen datum	Da	9	82%	3	0,776466	0,548307
Osoba		Ime i prezime osobe koja je povezana s arheološkim entitetom	Da	8	73%	3	0,644695	0,653034
Uloga osobe	Istraživač / autor	Uloga koju ima osoba kod povezanog arheološkog entiteta (npr. istraživač, kontakt osoba, preparator, analitičar, vlasnik)	Da	6	55%	3	0,534827	0,531814
Institucija osobe		Institucija u kojoj radi osoba	Da	7	64%	3	0,576350	0,555726
Uloga institucije		Uloga institucije kod pronalaska arheološkog entiteta	Da	5	45%	-	-	-
Institucija odgovorna za objekt		Institucija organizacija u čijem je vlasništvu arheološki entitet	Da	8	73%	3	0,625044	0,512642
Vrsta oznake ili zaštite	Označavanje i zaštita	Pripadnost objekta kategoriji, npr. lokalni značaj, značaj za državu, svjetski značaj	Da	6	55%	2	0,788923	0,228776
Datum označavanja ili zaštite		Datum označavanja ili zaštite	Da	5	45%	-	-	-
Referentni broj označavanja i zaštite		Jedinstveni broj zaštite ili označavanja	Da	5	45%	-	-	-
Organizacija zaštite		Organizacija koja provodi označavanje ili zaštitu	Da	4	36%	-	-	-

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka *(%)*	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Osoba ovlaštena za promjene digitalnog objekta		Ime i prezime osobe koja može napraviti promjene digitalnog objekta arheološkog entiteta	Da	7	64%	2	0,866481	0,287308
Dozvole	Ažuriranje sadržaja objekta	Dozvole koje imaju osobe zadužene za ažuriranje	Da	4	36%	-	-	-
Kreiranje i identifikacija		Putem ovog elementa označava se autentičnost digitalnog objekta, identifikacijski broj te naznačuje verzija digitalnog objekta.	Da	6	55%	1,5	0,715205	0,164889
Procjena	Administrativno područje	Informira korisnika je li digitalni objekt ima daljnju vrijednost ili je označen za brisanje iz repozitorija	Da	3	27%	-	-	-
Uporaba i kontrola		Informira korisnika o povezanosti digitalnog objekta s drugim digitalnim objektima, te pokazuje njegovu pojavu u pretraživanjima	Da	8	73%	2,5	0,668266	0,349996
Raspoloživost		Informira korisnika o daljnjoj dostupnosti digitalnog objekta	Da	5	45%	-	-	-
Zaštita intelektualnog vlasništva		Način na koji se štiti digitalni objekt i poveznica na tekst o zaštiti	Da	6	55%	1,5	0,785548	0,111711
Bilješke	Pravni uvjeti korištenja	Bilješke uz arheološki entitet koje nisu navedene kroz prethodne elemente ili su bitne	Da	5	45%	-	-	-
Pružatelj usluge	Ostalo	Institucija koja je ovlaštena za arhivu i diseminaciju sadržaja	Da	5	45%	-	-	-
Ime reference		Ime reference	Da	9	82%	2,5	0,680744	0,403174

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka *(%)*	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Vrsta reference	Reference	Vrsta reference (npr. članak, arhiv,) i URL poveznica na referencu ako postoji	Da	8	73%	4	0,555566	0,642995
Reprezentacija		Povezanost s drugim digitalnim objektima	Da	9	82%	3	0,620871	0,538213
Prethodni objekt	Relacije	Povezanost s prethodnim arheološkim entitetom koji je bio na ovoj lokaciji (npr. crkva koja je izgrađena na lokaciji postojeće crkve)	Da	9	82%	3	0,561303	0,508947
Aktivnosti		Povezanost s aktivnostima (npr. obnova, provedena zaštita) vezane uz arheološki entitet ili digitalni objekt	Da	8	73%	3	0,681193	0,497778
Ima dijelove		Uključuje ostale digitalne objekte / arheološke entitete, odnosno ima sastavne dijelove	Da	8	73%	2,5	0,651804	0,449954
Je dio objekta		Pripada drugim digitalnim objektima / arheološkim entitetima, odnosno dio je nekog entiteta	Da	8	73%	3	0,623167	0,494083
URL		Jedinstvena adresa digitalnog objekta u digitalnom okruženju	Da	5	45%	-	-	-
Mjesto registracije	Informacije o plovilu	Mjesto u kojem je arheološki entitet registriran	Da	6/PR	55%/PR	-	-	-
Država		Država	Da	7/PR	64%/PR	-	-	-
Metoda konstrukcije		Glavna metoda kojom je arheološki entitet izgrađen	Da	6/PR	55%/PR	-	-	-
Tip pogona		Osnovni tip pogona arheološkog entiteta	Da	5/PR	45%/PR	-	-	-
Posljednja plovidba		Informacije o posljednjoj plovidbi arheološkog entiteta	Da	4/PR	36%/PR	-	-	-

Prilog 4. Metapodatkovni elementi entiteta Kontekst

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Način otkrića	Konteksta	Na koji način je arheološki entitet pronađen (npr. slučajni nalaz, sustavno istraživanje, zaštita istraživanja)	Da	10	91%	4	0,652388	0,766281
Referenca mjesta otkrića		Detaljna referenca gdje je arheološki entitet pronađen (koordinate)	Da	11	100%	5	0,757193	**0,938367**
Stratigrafska jedinica		Opis sloja u kojemu je pronađen arheološki entitet, i njegova povezanost s ostali slojevima	Da	11	100%	5	0,838385	**0,891588**
Značajno pridruživanje		Značajno pridruživanje arheološkog entiteta (npr. pronađen u ognjištu, u grobnici,..)	Da	11	100%	3,5	0,788923	0,743998

Prilog 5. Metapodatkovni elementi entiteta Dokumenti i tekstovi

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Naslov	Specifično	Naslov po kojemu se prepoznaje	Da	11	100%	4	0,652388	0,766281
Tip		Narav ili vrsta sadržaja izvora	Da	11	100%	3	0,682707	0,564830
Tema		Predmet sadržaja izvora (ključne riječi)	Da	11	100%	4	0,704990	0,786499
Opis		Opisu sadržaja izvora	Da	10	91%	3	0,611336	0,491434
Stvaratelj		Osoba (tijelo) koja je odgovorna za sadržaj	Da	9	82%	4,5	0,652388	0,766281
Suradnik		Osoba (tijelo) koje je odgovorno za doprinos sadržaju izvora	Da	7	64%	3	0,535870	0,459463
Nakladnik		Osoba (tijelo) koje je odgovorno za objavljivanje izvora	Da	6	55%	3	0,697097	0,474911
Opseg		Prostorni ili vremenski obuhvat sadržaja izvora	Da	7	64%	3	0,716793	0,406869
Datum		Datum vezan uz životni ciklus izvora	Da	5	45%	-	-	-
Identifikator		Identifikator formalnog identifikacijskog sustava	Da	5	45%	-	-	-
Jezik		Jezik sadržaja najvećeg dijela izvora	Da	7	64%	2	0,821320	0,258042
Odnos		Odnos opisanog izvora prema srodnom izvoru	Da	5	45%	-	-	-
Vlasnička prava		Vlasnička prava nad izvorom	Da	4	36%	-	-	-
Izvor		Uputa na izvor iz kojega je sadašnji izvor nastao	Da	6	55%	2	0,637363	0,320730

Prilog 6. Metapodatkovni elementi entiteta Publikacije

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Naslov	Specifično	Naslov publikacije po kojemu se prepoznaje	Da	11	100%	5	0,553222	**0,874065**
Vrsta publikacije		Vrsta publikacije (npr. knjiga, časopis)	Da	9	82%	3	0,644695	0,471216
DOI		Digitalni identifikator objekta npr. publikacije	Da	6	55%	2	0,522454	0,334548
ISSN		Jedinstveni standardi kod za tiskane ili elektroničke publikacije	Da	5	45%	-	-	-
ISBN		Međunarodni standardni knjižni broj	Da	5	45%	-	-	-
Jezik		Jezik publikacije	Da	6	55%	2	0,757579	0,252688
Edicija		Verzija publikacije	Da	9	82%	2	0,612446	0,238285
Ime serije		Pripadnost publikacije grupi	Da	9	82%	2	0,612446	0,238285
Broj serije		Kronološki redoslijed knjige u grupi	Da	9	82%	2	0,612446	0,238285
Volumen		Identifikacija publikacije u kolekciji	Da	10	91%	4	0,455071	0,672668
Broj izdanja		Identifikacija publikacije u volumenu	Da	9	82%	3	0,600407	0,532859
Početna i završna stranica		Početna i završna stranica publikacije	Da	7	64%	2	0,539891	0,388772
Institucija		Institucija koja je publicirala publikaciju	Da	8	73%	3	0,561632	0,483375
Odjel		Odjel koji je publicirao publikaciju	Da	6	55%	2,5	0,626925	0,421733
Konferencija		Konferencija s koje su radovi za publikaciju	Da	10	91%	3	0,642694	0,515346
Lokacija konferencije		U kojem mjestu je održana konferencija	Da	10	91%	3	0,590960	0,441950
Lokacija		Lokacija izdanja publikacije	Da	8	73%	3	0,644695	0,471216

Prilog 7. Metapodatkovni elementi entiteta Tablice

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Ime radne knjige	Specifično	Ime radne knjige tablica	Da	9	82%	-	-	-
Svrha i sadržaj radne knjige		Svrha i sadržaj radne knjige	Da	8	73%	-	-	-
Svrha i sadržaj radnog lista		Svrha i sadržaj pojedinog radnog lista	Da	8	73%	-	-	-
Opis polja		Opis polja i tip podataka polja	Da	5	45%	-	-	-
Broj stupaca i redaka za svaki radni list		Ukupni broj stupaca i redaka za svaki radni list	Da	5	45%	-	-	-
Dokumentiranost funkcija		Opis funkcija, formula, skripti	Da	5	45%	-	-	-

Prilog 8. Metapodatkovni elementi entiteta Baze podataka

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Svrha i sadržaj baze	Specifično	Svrha i sadržaj baze	Da	9	82%	4	0,924539	**0,804651**
Svrha i sadržaj svake tablice		Svrha i sadržaj svake tablice u bazi	Da	8	73%	4	0,758156	0,740303
Opis polja		Ime, Opis polja i vrsta podataka za svaku tablicu	Da	7	64%	3	0,673790	0,697164

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
Primarni ključevi za svaku tablicu		Primarni ključ za svaku tablicu	Da	6	55%	3	0,780437	0,550957
Vanjski ključevi za svaku tablicu		Vanjski ključ za svaku tablicu	Da	6	55%	2	0,671230	0,493038
Relacije između tablica		Povezanost između tablica	Da	8	73%	2	0,641141	0,554681

Prilog 9. Metapodatkovni elementi entiteta Vektorska grafika

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Ime	Specifično	Ime slike	Da	10	91%	-	-	-
Svrha / Opis		Svrha ili opis slike	Da	6	55%	-	-	-
Autor		Ime i prezime autora slike	Da	7	64%	-	-	-
Datum		Datum kreiranja slike	Da	6	55%	-	-	-
Ključne riječi		Ključne riječi, npr. period, lokacija	Da	6	55%	-	-	-
Porijeklo / povezanost		Opis od kuda dolazi slika i kako je povezana s drugim slikama	Da	5	45%	-	-	-
Objašnjenje za značenje korištenih konvencija		Objašnjenje primijenjenih konvencija (npr. boje, slojevi)	Da	5	45%	-	-	-

Prilog 10. Metapodatkovni elementi entiteta Rasterska grafika

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Ime	Specifično	Ime slike	Da	10	91%	4,5	0,821597	**0,929947**
Opis		Opis slike	Da	7	64%	4	0,700130	0,737599
Autor		Osoba koja je kreirala sliku	Da	8	73%	3,5	0,651804	0,670602
Datum		Datum kreiranja slike	Da	6	55%	3	0,742720	0,565820
Autorska prava		Autorska prava na sliku	Da	8	73%	3	0,667259	0,562125
Ključne riječi		Ključne riječi slike	Da	4	36%	-	-	-
Lokacija		Lokacija na kojoj je snimljena	Da	7	64%	4	0,611767	0,746064
Rezolucija	Dodatno	Rezolucija slike (ppi)	Da	5	45%	-	-	-
Dimenzije		Dimenzije slike (px)	Da	5	45%	-	-	-
Boje		Vrsta korištene boje (npr. RGB, grayscale)	Da	4	36%	-	-	-
Dubina boje		Npr. 24-bitna ili 8-bitna	Da	3	27%	-	-	-
Uređaj za slikanje		Uređaj kojim je snimljena ili skenirana slika	Da	4	36%	-	-	-

Prilog 11. Metapodatkovni elementi entiteta Digitalni video

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Opis	Specifično	Opis sadržaja videa	Da	10	91%	4	0,644695	0,713687
Dužina zapisa		Dužina zapis (sati, minute, sekunde)	Da	6	55%	2	0,583115	0,367509
Ime i verzija kodeka		Ime i verzija video kodeka	Da	5	45%	-	-	-
Dimenzije videa		Dimenzije videa u px (npr. 1024x768 px)	Da	4	36%	-	-	-
Broj prikaza slika		Broj slika po sekundi (npr. 24 slike/sec)	Da	4	36%	-	-	-
Video bitrate		Broj bitova koji se procesiraju u vremenu (utječe na kvalitetu videa)	Da	3	27%	-	-	-
Audio kodek		Ime i verzija audio kodeka	Da	4	36%	-	-	-
Frekvencija audio uzorka		Frekvencija audio uzorka	Da	2	18%	-	-	-
Audio bitrate		Audio bitrate	Da	3	27%	-	-	-
Broj audio kanala		Koliko kanala se koristi npr. stereo	Da	2	18%	-	-	-
Licenca		Način zaštite videa i dozvoljeni način uporabe videa	Da	7	64%	2,5	0,693837	0,353691
Ime videa	Dodatno	Jedinstveno ime videa (npr. Istraživanje Groba 12 - Nekropola Caska)	Ne	NDP	NDP	4	0,611289	**0,821525**
Autor / Snimatelj		Osoba ili autorski tim koji su napravili snimku	Ne	NDP	NDP	3	0,833630	0,572219
Autorska prava		Osoba ili autorski tim koji su nositelji autorskog prava	Ne	NDP	NDP	2,5	0,715205	0,430781
Vrijeme snimanja		Godina ili puni datum nastanka videa	Ne	NDP	NDP	3,5	0,607968	0,646690

Prilog 12. Metapodatkovni elementi entiteta Digitalni zvuk

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Dubina bita	Specifično	Broj bita za opis zvuka (npr. 16 ili 24 bita)	Da	3	27%	-	-	-
Bit rate		Bit rate	Da	3	27%	-	-	-
Uzorak bita		Npr. u kHZ	Da	3	27%	-	-	-
Kodek		Korišteni kodek	Da	4	36%	-	-	-
Dužina zapisa		Dužina zapisa (npr. sati, minute, sekunde)	Da	5	45%	-	-	-
Autorska prava		Osoba ili autorski tim koji su nositelji autorskog prava	Da	8	73%	2,5	0,628342	0,397820
Transkripti intervjua		Prijepis razgovora	Da	7	64%	2,5	0,632375	0,447304
Ime zvučnog zapisa	Dodatno	Jedinstveno ime zvučnog zapisa (npr. Intervju I. Ivić, Mali Pašman 2016)	Ne	NDP	NDP	4	0,652329	**0,804012**
Autor / Snimatelj		Osoba ili autorski tim koji su napravili zvučni zapis	Ne	NDP	NDP	3	0,686451	0,539258
Licenca		Način zaštite videa i način dozvole uporabe	Ne	NDP	NDP	3	0,664391	0,401515
Vrijeme nastanka		Godina ili puni datum nastanka zvučnog zapisa	Ne	NDP	NDP	3	0,651811	0,556771
Pohrana snimke		Ustanova na kojoj se snimka čuva	Ne	NDP	NDP	3	0,697097	0,474911

Prilog 13. Metapodatkovni elementi entiteta Prostorna istraživanja

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Predmet	Osnovno	Arheološke ključne riječi, izvor iz terminološkog rječnika (npr. Thesaurusi)	Da	11	100%	5	1,000000	**1,000000**
Prostorna pokrivenost		Prostorna / geografska pokrivenost subjekta	Da	11	100%	2,5	0,673790	0,427087
Format podataka		Format podataka	Da	8	73%	3	0,833630	0,574869
Autorska prava		Nositelj autorskog prava	Da	7	64%	2	0,657827	0,324424
Licence		Način zaštite i način dozvole uporabe	Ne	NDP	NDP	2	0,727378	0,276600
Kreator i suradnici		Osobe koje su kreirale sadržaj	Da	10	91%	3	0,714357	0,609950
Vrijeme kreiranja		Prvi datum kreiranja i ostali datumi bitni u životnom ciklusu podataka (promjene)	Da	6	55%	3	0,759974	0,589732
Povezanost		Povezanost na korisni sadržaj na drugim mjestima	Da	11	100%	3	0,641334	0,585047
Tehnički uređaji	Dodatno	Instrumenti korišteni za prikupljanje podataka	Da	6	55%	3	0,758156	0,504177
Rezolucija		Skala preciznosti prikupljanja podataka	Da	6	55%	2,5	0,676187	0,523350
Podatci procesiranja		Podatci koji su prikupljeni tijekom procesiranja (log podatci)	Da	7	64%	3	0,644695	0,471216
Tehnička specifikacija		Tehnička specifikacija slike	Da	3	27%	-	-	-
Legenda		Konvencije korištene za podatke	Da	8	73%	3	0,561303	0,508947
Bibliografija		Ukazuje na ostale relevantne informacije o kolekciji, procesiranju, interpretaciji	Da	8	73%	3	0,626925	0,421733

Prilog 14. Metapodatkovni elementi entiteta Istraživanja bespilotnim letjelicama

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Ime slike	Slikovno	Ime slike	Da	10	91%	*3*	0,758156	0,504177
Geografska visina, širina, i dužina		Geografska visina, širina i dužina	Da	10	91%	*3*	0,697097	0,474911
Prostor	Istraživačko	Prostor istraživanja (npr. WGS84)	Da	10	91%	4,5	0,581455	**0,839038**
Datum		Datum istraživanja	Da	7	64%	4	0,682707	0,792843
Kamera		Proizvođač kamere model i broj	Da	5	45%	-	-	-
Tehničke karakteristike		Vrijednosti zatvarača, žarišta i osvjetljenja u trenutku snimanja	Da	3	27%	-	-	-
GPS		Karakteristike GPS, npr. ime, model, odstupanja	Da	6	55%	2,5	0,628342	0,397820
Tehničke karakteristike leće		Npr. kalibracija, dimenzije	Da	2	18%	-	-	-
Programska podrška		Korišteni programi u konverziji iz .raw u .tiff format / koordinata	Da	4	36%	-	-	-
Izvorni podatci	Procesiranje	Jedinstveni identifikator podataka	Da	9	82%	3	0,749499	0,478606
Programska podrška obrade		Ime i verzija korištenih programa	Da	6	55%	2	0,727378	0,276600
Priroda obrade		Opis metode i li vrste transformacije	Da	6	55%	2	0,773616	0,305866
Generirani podatci		Novi identifikator podataka	Da	6	55%	3	0,614845	0,372249
Opis generiranih podataka		Opis novo generiranih podataka, te napravljenih promjena	Da	5	45%	-	-	-

Prilog 15. Metapodatkovni elementi entiteta Geofizička istraživanja

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Geološki kontekst	Projektno	Koji događaji su imali utjecaj na ovo područje kroz povijest	Da	9	82%	2,5	0,560503	**0,909091**
Geološki sastav		Geološki sastav (materijal) istraženog područja	Da	9	82%	3	0,551319	0,578648
Vrijeme		Izvještaj o vremenu tijekom istraživanja	Da	9	82%	2	0,675508	0,748768
Stanje tla		Stanje tla tijekom istraživanja	Da	7	64%	2	0,553222	**0,874065**
Vrsta istraživanja	Istraživačke tehnike	Određivanje geofizičkih tehnika (npr. istraživanje magnetometrom, seizmička,..)	Da	9	82%	4	0,642103	0,373908
Instrument		Informacije o konfiguraciji geofizičkog uređaja	Da	8	73%	2,5	0,732007	0,524395
Opis odabrane tehnike		Kratki opis odabrane tehnike u svrhu kasnije evaluacije rezultata (npr. istraživačko pitanje, stanje terena)	Da	9	82%	2	0,710886	0,272905
Istraženo područje		Područje koje je istraženo (izraženo u m2)	Da	10	91%	3	0,710886	0,272905
Metode		Metode kojima su prikupljeni podatci	Da	9	82%	3,5	0,373966	0,622194
Traverzna separacija		Razdvajanje između susjednih i prethodnih mjerenja	Da	6	55%	3	0,522109	0,435551
Separacija linija		Odvajanje dobivenih linija nakon spajanja podataka sa senzora instrumenta	Da	7	64%	3	0,796930	0,335132
Interval čitanja		Udaljenost između susjednih očitanja	Da	8	73%	3	0,604378	0,576989
Pozicija uzorkovanja		Točan položaj u kojem su snimljeni podatci (npr. mrežni kvadrati)	Da	10	91%	3	0,534827	0,573294
Veličina podatkovne mreže		Veličina istraženog područja (grida)	Da	9	82%	3	0,727388	0,498823

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Točnost		Točnost evidentiranja prostornih podataka	Da	10	91%	3	0,727388	0,498823
Dodatne napomene		Dodatne napomene	Da	7	64%	2	0,727388	0,498823
Podatkovna mreža	Istraživačka metodologija	Geofizičke koordinate pojedine podatkovne mreže (istraženog prostora)	Da	9	82%	3	0,727388	0,498823
Veličina podatkovne mreže		Za svaku mrežu potrebno je evidentirati veličinu	Da	8	73%	3	0,686451	0,539258
Rezolucija		Razmak između x i y smjera	Da	8	73%	3	0,776466	0,548307
Smjer istraživanja		Smjer u kojem je napravljeno pro snimanje i očitovanje	Da	8	73%	3	0,796930	0,281954
Sekvence linije		Način na koji se hoda kako bi se definirala mreža	Da	8	73%	2	0,682707	0,564830
Vrijednosti		Vrijednost materijala koje su očitanje tijekom istraživanja	Da	7	64%	2	0,667259	0,559476
Naslov izvještaja		Naslov izvještaja koji je kreiran	Da	9	82%	4	0,758156	0,504177
Referenca izvještaja		Jedinstveni broj npr. DOI	Da	9	82%	1,5	0,637826	0,445645
Autor izvještaja		Autor izvještaja	Da	9	82%	3,5	0,757579	0,252688
Lokacija		Lokacija na kojoj je izvještaj moguće dobiti	Da	9	82%	3	0,727378	0,276600

Prilog 16. Metapodatkovni elementi entiteta Istraživanje podmorja

Element istraživanja podmorja nisu identificirani kroz sheme, osim za razinu datoteke (ime, veličina datoteke, program i verzije, opis sadržaja). Kroz istraživanje nije dobivena sugestija za metapodatkovne elemente.

Prilog 17. Metapodatkovni elementi entiteta Lasersko skeniranje

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Ime projekta	Projektno	Ime projekta	Da	7	64%	-	-	-
Ime arheološkog entiteta		Ime arheološkog entiteta koji je skeniran	Da	9	82%	-	-	-
Broj arheološkog entiteta		Jedinstveni identifikacijski broj arheološkog entiteta	Da	8	73%	-	-	-
Opis arheološkog entiteta		Kratki opis arheološkog entiteta koji će biti skeniran	Da	9	82%	-	-	-
Istraživačka lokacija		Lokacija skeniranja s kompletnom adresom i koordinata	Da	9	82%	-	-	-
Datum istraživanja		Datum istraživanja	Da	6	55%	-	-	-
Uvjeti istraživanja		Vremenski uvjeti istraživanja	Da	7	64%	-	-	-
Detalji skenera		Detalji instrumenata sa serijskim brojem i jedinicama skeniranja	Da	6	55%	-	-	-
Ime operatera		Ime i prezime osobe koja je napravila skeniranje	Da	5	45%	-	-	-
Karakteristike		Korištenje dodatnih pomagala kod skeniranja (npr. mehanizam za okretanje)	Da	3	27%	-	-	-
RGB		Korištenje sustava za prikupljanje podataka o bojama (npr. korištenje dodatnog osvjetljenja)	Da	4	36%	-	-	-
Rezolucija		Korištena rezolucija za cijeli arheološki entitet	Da	5	45%	-	-	-
Broj skenova u projektu		Ukupni broj skenova	Da	4	36%	-	-	-

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Opis finalnog skupa podataka		Opis svih skupova podataka koji su arhivirani	Da	5	45%	-	-	-
Dodatne napomene		Dodatne napomene o projektu	Da	5	45%	-	-	-
Ime datoteke skeniranja	Razina skeniranja	Ime skeniranja	Da	4	36%	-	-	-
Transformacijska matrica skeniranja		Ime transformacijske matrice	Da	4	36%	-	-	-
Primijenjena matrica		Je li matrica primijenjena za arhivirane skenove	Da	4	36%	-	-	-
Ime objekta		Ime arheološkog entiteta koji će biti skeniran	Da	7	64%	-	-	-
Datum istraživanja		Datum skeniranja	Da	4	36%	-	-	-
Rezolucija podataka		Podatkovna rezolucija	Da	5	45%	-	-	-
Broj točaka u skeniranju		Broj točaka u datoteci skeniranja	Da	4	36%	-	-	-
Tehnologija skeniranja		Tehnologija skeniranja (npr. faze, triangulacija)	Da	4	36%	-	-	-
Tehnički uvjeti		Definiranje načina prolaza, količine svjetlosti, frekvencije skeniranja, vrste leće	Da	2	18%	-	-	-
Ime skupa podataka	Mreža podataka	Ime skupa podataka	Da	4	36%	-	-	-
Metoda korištena za mrežu točaka		Točan opis metode korištene za skup točaka	Da	4	36%	-	-	-
Global registration error		Ukupni broj RMS pogrešaka kod skeniranja	Da	3	27%	-	-	-
Broj točaka mreže u datoteci		Ukupni broj točaka u finalno registriranoj mreži točaka	Da	4	36%	-	-	-

Prilog 18. Metapodatkovni elementi entiteta Kronološka istraživanja

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Ime projekta	Projektno	Ime projekta	Da	9	82%	5	0,560503	**0,909091**
Identifikator		Identifikator projekta u okvirima laboratorija, ili izvještajni broj	Da	9	82%	2,5	0,483468	0,455769
Vrsta projekta		Vrste projekta, a mogu biti npr. datiranje, tehnologija drva, rekonstrukcija vegetacije, klimatološka studija	Da	10	91%	4	0,536087	0,657859
Laboratorij		Ime laboratorija u kojem se provodi istraživanje	Da	9	82%	3,5	0,535193	0,637641
Kategorija		Kategorija projekta, npr. arheologija, podvodna arheologija, umjetnost, vegetacija	Da	5	45%	-	-	-
Istraživač		Ime i prezime osobe koja provodi istraživanje	Da	7	64%	3	0,534373	0,485035
Period		Vremenska oznaka kada je pokrenut / završen projekt	Da	6	55%	2,5	0,680744	0,403174
Vrsta uzorka	Opći objekt	Vrsta materijala koji se analizira (npr. kost)	Da	10	91%	4	0,582778	**0,801307**
Opis uzorka		Sažeti opis uzorka koji se analizira	Da	9	82%	3	0,604378	0,576989
Geografske koordinate		Geografska dužina, visina, širina; lokacija pronalaska	Da	8	73%	3	0,651811	0,556771
Nekalibrirani datum		Konvencionalni datum	Da	10	91%	4	0,629528	0,783794
Kalibrirani datum		Kalendarski datum	Da	10	91%	4	0,493359	0,713103
Odstupanje		Vremensko odstupanje	Da	10	91%	4	0,520863	0,695589

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Analizirani izotop		Vrsta analize izotopa (npr. ^{13}C, ^{15}N, ^{18}O,.)	Da	10	91%	4	0,493359	0,713103
Vrijednost izotopa		Vrijednost analiziranog izotopa (‰)	Da	10	91%	3,5	0,448783	0,564245
Ime objekta	Objekt	Ime arheološkog entiteta koji je analiziran	Da	9	82%	4	0,465955	0,730616
Vrsta objekta		Funkcionalni opis, npr. brod (i vrsta)	Da	9	82%	4	0,548802	0,678076
Geografske koordinate		Geografska širina, dužina	Da	9	82%	2	0,611767	0,343597
Ime elementa	Element	Ime elementa	Da	9	82%	4	0,482791	0,633947
Takson		Najdetaljnije taksonomsko poznato ime: npr vrsta, rod.	Da	9	82%	3	0,514363	0,570590
Geografske koordinate		Geografska širina, dužina	Da	9	82%	2	0,706915	0,326084
Ime uzorka	Uzorak	Ime uzorka	Da	9	82%	4	0,582779	0,704638
Vrsta uzorka		Metoda koja je korištena za uzimanje uzorka iz elementa te opis uzorka (npr. dio)	Da	9	82%	3	0,556244	0,462168
Datum		Datum kada je uzorka uzet	Da	7	64%	3	0,590960	0,441950
Ime radijusa	Radijus	Ime radijusa	Da	6	55%	2	0,706915	0,326084
Centralna točka		Prisutnost centralne točke	Da	6	55%	2	0,644695	0,399480
Vanjski omotač (sapwood)		Prisustvo vanjskog omotača (npr. nema, odsutan, kompletan,..)	Da	6	55%	2	0,644695	0,399480
Kora		Je li prisutna kora (da/ne)	Da	6	55%	2,5	0,632375	0,423392
Ime serije	Serija	Ime ili oznake serije	Da	7	64%	3	0,626925	0,421733
Metoda		Metoda koja se koristi za mjerenje uzorka	Da	7	64%	3	0,608646	0,395785

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Varijable		Ime varijable i njezina vrijednost koja se mjeri (npr. centralna točka)	Da	6	55%	2	0,727378	0,549966
Vrsta serije		Proizlazi li serija iz ostalih serija i vrsta serije	Da	6	55%	3	0,664391	0,401515

Prilog 19. Metapodatkovni elementi entiteta CAD

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Ime	Projektno	Ime projekta ili naslov projekta	Da	8	73%	-	-	-
Opis		Kratki i sažeti opis projekta	Da	9	82%	-	-	-
Predmet		Opis subjekata o kojima se radi zapis	Da	9	82%	-	-	-
Ključne riječi		Ključne riječi projekta	Da	8	73%	-	-	-
Jezik		Jezik dokumentacije projekta	Da	3	27%	-	-	-
Adresa		Adresa subjekta o kojemu se radi zapis	Da	7	64%	-	-	-
Područje		Administrativno područje (npr. općina, grad, županija)	Da	8	73%	-	-	-
Prostorna pokrivenost		Koordinate subjekta prema nacionalnom standardu	Da	9	82%	-	-	-
Veličina		Veličina prostora koji se istražuje	Da	7	64%	-	-	-

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Izvoditelj		Organizacija / osoba koja je odgovorna za projekt	Da	8	73%	-	-	-
Naručitelj		Organizacija / osoba koja je investitor za projekt	Da	5	45%	-	-	-
Depozitor		Organizacija kod koje su deponirani podatci projekta	Da	7	64%	-	-	-
Identifikator		Jedinstveni identifikacijski broj po kojemu se podatci projekta prepoznaju	Da	8	73%	-	-	-
Trajanje		Vremensko trajanje projekta npr. od dana, do dana	Da	5	45%	-	-	-
Pravna zaštita		Opis pravne zaštite podataka ako postoji	Da	5	45%	-	-	-
Primarna arhiva		Organizacija / osoba koja čuva primarne podatke projekta	Da	7	64%	-	-	-
Izvori / povezane arhive		Reference prema izvornom materijalu	Da	8	73%	-	-	-
Bibliografija		Naslov i autor publikacije o publikaciji vezanoj uz projekt	Da	7	64%	-	-	-
Format		Kratki opis formata podataka koji se koriste u projektu (npr. DWG, DXF,..)	Da	8	73%	-	-	-
Ime konvencije	Konvencije o slojevima	Ime konvencije za slojeve	Da	9	82%	-	-	-
Ime sloja		Ime ili broj pridružen sa sloja	Da	9	82%	-	-	-
Sadržaj sloja		Kratki opis sadržaja sloja	Da	9	82%	-	-	-
Konvencija crtanja		Konvencije o crtanju ili korištenim specijalnim znakovima	Da	6	55%	-	-	-
Ime projekta	Način prikuljanja	Ime projekta ili dokumentacije	Da	7	64%	-	-	-
Broj reference		Jedinstveni identifikator projekta	Da	7	64%	-	-	-

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Vrsta istraživanja		Vrsta istraživanja (npr. istraživanje stanicom, ručno premjeravanje)	Da	8	73%	-	-	-
Svrha		Kratki opis svrhe istraživanja, tehnike, opreme	Da	7	64%	-	-	-
Trajanje		Vremensko razdoblje istraživanja (od datuma, do datuma)	Da	4	36%	-	-	-
Istraživač		Ime i prezime osobe koja je provela istraživanje	Da	7	64%	-	-	-
Ključne riječi istraživanja		Ključne riječi istraživačke tehnike	Da	5	45%	-	-	-
Instrumenti		Specifične informacije o korištenim instrumentima	Da	4	36%	-	-	-
Pokrivenost		Opis pokrivenog područja i korištenih metoda i tehnike	Da	6	55%	-	-	-
Preciznost i točnost		Način osiguravanja točnosti i preciznosti kod prikupljanja podataka	Da	7	64%	-	-	-
Način prijenosa podataka		Način ostvarenja prijenosa podataka između digitalne opreme	Da	4	36%	-	-	-
Lokacijska metoda	Dokumentiranje podataka o GPS	Metoda koja je korištena za lociranje stanica	Da	6	55%	-	-	-
Koordinatna transformacija		Programi korišteni za koordinatnu transformaciju i odstupanja	Da	4	36%	-	-	-
Satelit		Korišteni satelit	Da	3	27%	-	-	-
Korekcija		Primijenjena korekcija	Da	4	36%	-	-	-
Bazna stanica		Ime pružatelja usluge i lokacija osnovne stanice	Da	2	18%	-	-	-

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Post procesiranje		Programska podrška za post-procesiranje i korekciju podataka	Da	3	27%	-	-	-
Ime projekta	Izvori podataka	Ime projekta	Da	7	64%	-	-	-
Broj reference		Broj projekta	Da	7	64%	-	-	-
Ime izvora		Ime izvora podataka	Da	8	73%	-	-	-
Referenca izvora		Referenca (broj) izvora	Da	7	64%	-	-	-
Vrsta izvora		Vrsta izvora (npr. mapa, plan, fotografija)	Da	8	73%	-	-	-
Medij		Opis medija izvora podataka (npr. papir,..)	Da	6	55%	-	-	-
Izdavač		Izdavač izvora podataka	Da	5	45%	-	-	-
Pravna zaštita		Opis postojećih autorskih prava koji sadrži izvor podataka	Da	6	55%	-	-	-
Skale		Skale izvora podatka	Da	6	55%	-	-	-
Točnost		Točnost izvora	Da	7	64%	-	-	-
Mape		Detalji o izvorima (npr. koordinatni sustav)	Da	8	73%	-	-	-
Fotografski detalji		Fotografski detalji (npr. pozicija, fokus,..)	Da	4	36%	-	-	-
Tehnika	Prethodno snimljeni podatci	Generička kategorija korištene tehnike npr. digitalizacija, skeniranje	Da	7	64%	-	-	-
Oprema		Vrsta opreme koja je korištena	Da	3	27%	-	-	-
Programi		Programi i verzija koja je korištena	Da	3	27%	-	-	-
Parametri		Parametri korištenih uređaja (npr. rezolucija)	Da	3	27%	-	-	-

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Post-procesiranje		Opis aktivnosti post-procesiranja (npr. smanjenje pogrešaka)	Da	4	36%	-	-	-
Automatsko procesiranje		Primijenjeno automatsko procesiranje	Da	2	18%	-	-	-
Preciznost i točnost		Aktivnosti poduzete za osiguranje preciznosti i točnosti	Da	4	36%	-	-	-
Autorska prava		Autorska prava materijala	Da	6	55%	-	-	-
Ime projekta	Model	Ime projekta	Da	7	64%	-	-	-
Broj reference		Broje reference projekta	Da	7	64%	-	-	-
Kreator		Osoba ili organizacija odgovorne za model	Da	6	55%	-	-	-
Ime modela		Ime CAD modela	Da	6	55%	-	-	-
CAD programi		Korišten CAD program i verzija	Da	5	45%	-	-	-
Korištene datoteke		Korištene datoteke za model	Da	4	36%	-	-	-
Konvencije sloja		Korištene konvencije imenovanih slojeva	Da	6	55%	-	-	-
Ime projekta	Vanjske baze podataka	Ime projekta	Da	7	64%	-	-	-
Referenca projekta		Broj reference projekta	Da	7	64%	-	-	-
Baza podataka		Vrsta i verzija korištene baze podataka	Da	5	45%	-	-	-
Ime		Ime baze, tablica	Da	7	64%	-	-	-
Polja		Ime polja, i korištenih tipova podatka, napomene, definirani ključevi	Da	5	45%	-	-	-

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
CAD datoteka		Ime CAD datoteka s kojima je baza podataka povezana	Da	8	73%	-	-	-
Polje povezivanja		Povezana polja između baze podatka i CAD modela	Da	7	64%	-	-	-
Format datoteke		Format u kojemu je baza podataka snimljena	Da	8	73%	-	-	-
Datum kreiranja		Datum kada je baza kreirana	Da	3	27%	-	-	-

Prilog 20. Metapodatkovni elementi entiteta 3D Model

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Broj vrhova (točaka)	Pojedine datoteke	Broj točaka u 3D modelu	Da	4	36%	-	-	-
Broj poligona ili Trokuta		Broj poligona ili trokuta u modelu	Da	3	27%	-	-	-
Vrsta geometrije		Vrsta geometrije korištene s modelom	Da	3	27%	-	-	-
Skale		Koja skala postoji, i što je reprezentirano s 1 jedinicom	Da	5	45%	-	-	-
Koordinatni sustav		Koja vrsta koordinatnog sustava se koristi (stvarni, dogovoreni)	Da	7	64%	-	-	-

Metapodatkovni element	Područje	Kratki opis	Uključen u prvu iteraciju istraživanja	Prva iteracija		Druga iteracija	Treća iteracija	
				Ispunjenje kriterija *(N)*	Prepoznavanje stručnjaka (%)	Centralna vrijednost	Cns(X)	sCns(X)
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*
Glavni model		Je stvarni model iz raw podataka ili je stvoren od glavnog modela (npr. pojednostavljenjem)	Da	5	45%	-	-	-
Rezolucija na razini detalja		Rezolucija skenera, te koliko je model detalj	Da	4	36%	-	-	-
Slojevi		Koliko slojeva ima model	Da	3	27%	-	-	-
Boja i tekstura		Koja vrsta boja i tekstura se koristi	Da	3	27%	-	-	-
Materijal		Informacije o materijalu koji se koristi i u kojoj mjeri odgovara fizičkom modelu i njegovim svojstvima	Da	3	27%	-	-	-
Izvor svjetlosti		Broj i vrst izvora svjetlosti za model	Da	1	9%	-	-	-
Sjenčanje		Koja vrsta sjenčanja je korištena	Da	1	9%	-	-	-
Animacija		Vrsta animacije koja je korištena	Da	2	18%	-	-	-
Vanjske datoteke		Popis vanjskih datoteka koje se koriste	Da	1	9%	-	-	-

Prilog 21. Digitalna kompetencija - 1.1. Pregledati, pretražiti i filtrirati podatke, informacije i digitalni sadržaj

Kompetencija	***1.1. Pregledati, pretražiti i filtrirati podatke, informacije i digitalni sadržaj***
Opis:	Izraziti informacijske potrebe, pronaći podatke, informacije i digitalni sadržaj, pristupiti njima, pregledati ih te odrediti načine i postupke pretraživanja

Iskazi - znanja, vještina i odgovornosti

Osnovna	
1	**2**
Uz pomoć i savjete drugih osoba: a.) Mogu identificirati, sa liste baza podataka, baze podataka koje mi mogu pomoći kod izrade seminara b.) Na internetu putem digitalnog uređaja znam pristupiti web stranicama, blogovima i pregledavati ih c.) Sa liste generičkih ključnih riječi, mogu identificirati važne ključne riječi	Uz povremenu pomoć drugih osoba: a.) Identificirati web stranice, blogove i baze podataka navedene u digitalnom izvoru za pristup dodatnom sadržaju o temi za seminar b.) Znam pristupiti web stranicama, blogovima putem digitalnih uređaja, te ih pregledavati c.) Koristeći generičke ključne riječi i oznake iz digitalnih sadržaja, mogu odrediti koje su bitne za moj seminar

Srednja	
3	**4**
Samostalnu u svrhu rješavanja izravnih problema: a.) Objasniti informacijske potrebe vezane uz temu za izradu seminara b.) U digitalnom okruženju temeljem definiranih postupaka pronaći web stranice ili blogove sa podatcima za seminarski rad c.) Objasniti kako pristupiti njima i kako koristiti poveznice između njih d.) Objasniti definiranu i osnovnu pretragu za podacima i web stranicama	Samostalno, s obzirom na potrebe te rješavajući definirane i nesvakodnevne probleme: a.) Ilustrirati informacijske potrebe o podatcima i informacija o potrebnom sadržaju za seminarski rad b.) Podacima i informacijama potrebnim za seminarski rad pristupam putem web tražilica ili baza podataka c.) Opisati kako pristupiti traženim podacima i informacijama u digitalnom okruženju koristeći različite tražilice i baze podataka d) Provoditi različite strategije pretraživanja web stranica i baza podataka

Napredna	
5	**6**
Samostalno te pomažući drugima: a.) Odgovoriti na informacijske potrebe vezane uz teme za izradu seminara b.) U digitalnom okruženju primijeniti odgovarajuće postupke za pronalaženje podataka, informacija ili sadržaja za seminarski rad c.) Pokazati kako pristupiti tim podacima na web stranicama, blogovima ili bazama podataka d.) Predložiti kako najbolje pronaći podatke i informacije na web stranicama, blogovima, repozitorijama ili bazama podataka	Samostalno, s obzirom na potrebe drugih te rješavajući složene probleme: a.) Procijeniti informacijske potrebe o podatcima i informacija o potrebnom sadržaju za seminarski rad b.) Prilagoditi strategije pretraživanja podataka i informacija u svrhu dobivanja odgovarajućih podataka, informacija i sadržaja u digitalnom okruženju. Npr. kombinacijom različitih tražilica, uvjeta, pretraživanjem različitih domena. c.) Objasniti i pokazati kako pristupiti traženim podacima i informacijama u digitalnom okruženju koristeći različite tražilice i baze podataka d) Provoditi i evaluirati različite strategije pretraživanja web stranica i baza podataka

Visoko specijalizirana	
7	**8**
Prepoznavanjem potreba i probleme korisnika: a.) Kreirati rješenja za složene probleme koji su djelomično definirani od strane korisnika u svrhu pregledavanja, pretraživanja i filtriranja podataka, informacija i digitalnog sadržaja (npr. kreirati digitalni repozitorij prema potrema korisnika sa svim funkcijama pretraživanja) b.) Integrirati vlastito znanje za doprinos profesionalnoj praksi i znanju za edukaciju ostalih korisnika u području pregledavanja, pretraživanja i filtriranja digitalnog sadržaja (npr. kreirati digitalni tečaj o pretraživanju podataka)	Prepoznavanje specifičnih potreba i probleme korisnika u složenoj okolini: a.) Kreirati rješenja za rješavanje složenih i kompleksnih problema koji uključuju interakciju različitih činitelja a koji su povezani uz pregledavanje, pretraživanje digitalnog sadržaja, podataka i informacija b.) Prezentirati nove i orginalne ideje, rješenja u području pretraživanja podataka, infromacija i digtalnog sadržaja

Procijenjena razina:	

Prilog 22. Digitalna kompetencija - 1.2. Vrjednovati podatke, informacije i digitalni sadržaj

Kompetencija	***1.2. Vrednovati podatke, informacije i digitalni sadržaj***
Opis:	Analizirati, usporediti i kritički evaluirati kredibilitet izvora podataka, informacija i digitalnog sadržaja kao i samih podataka, informacija i sadržaja.

Iskazi - znanja, vještina i odgovornosti

Osnovna	
1	**2**
Uz stalnu pomoć i savjete drugih: a.) Mogu identificirati, sa lista repozitorija (baza podataka) web stranice, blogove koje sadrže podatke, informacije ili digitalni sadržaj	Uz povremenu pomoć drugih: a.) Mogu identificirati vjerodostojnost pojedinih web stranica i baza koje sadrže potrebne podatke, informacije i digitalni sadržaj

Srednja	
3	**4**
Samostalnu u svrhu rješavanja postojećih jednostavnih problema: a.) Napraviti analizu, usporedbu i evaluaciju vjerodostojnosti pred definiranih web stranica koji služe kao izvora podataka, informacija ili digitalnog sadržaja b.) Napraviti analizu i interpretaciju prikupljenih podataka, informacija i digitalnog sadržaja	Samostalno, s obzirom na potrebe te rješavajući definirane i nesvakodnevne probleme: a.) Napraviti analizu, usporedbu i evaluaciju vjerodostojnosti web stranica koji služe kao izvora podataka, informacija ili digitalnog sadržaja b.) Napraviti analizu i interpretaciju prikupljenih podataka, informacija i digitalnog sadržaja

Napredna	
5	**6**
Samostalno te pomažući drugima: a.) Provesti procjenu vjerodostojnosti i pouzdanosti različitih izvora podataka, informacija i digitalnog sadržaja b.) Provesti evaluaciju različitih podataka, informacija i digitalnog sadržaja	Samostalno, s obzirom na potrebe drugih te rješavajući složene probleme: a.) kritički procijeniti vjerodostojnost i pouzdanost izvora podataka, informacija i digitalnog sadržaja b.) Kritički procijeniti podatke, informacije i digitalni sadržaj

Visoko specijalizirana	
7	**8**
Prepoznavanjem vlastitih potreba i probleme korisnika: a.) Kreirati rješenja za složene probleme koji su djelomično definirani, a povezani su uz evaluaciju vjerodostojnosti i pouzdanosti izvora podataka, informacija i digitalnog sadržaja b.) Integrirati vlastito znanje za doprinos profesionalnoj praksi i znanju za edukaciju ostalih korisnika za potrebe evaluacije i provjere pouzdanosti izvora podataka, informacija i digitalnog sadržaja	Prepoznavanje specifičnih potreba i probleme korisnika u složenoj okolini: a.) Kreirati rješenja za rješavanje složenih i kompleksnih problema koji uključuju interakciju različitih činitelja, a koji su povezani uz evaluaciju i pouzdanost različitih i složenih izvora podataka, informacija i digitalnog sadržaja b.) Prezentirati nove i originalne ideje, rješenja u svrhu provjere evaluacije i pouzdanosti izvora podataka, informacija i digitalnog sadržaja

Procijenjena razina:

Prilog 23. Digitalna kompetencija - 1.3. Upravljati podatcima, informacijama i digitalnim sadržajem

Kompetencija	***1.3 Upravljati podatcima, informacijama i digitalnim sadržajem***
Opis:	Organizirati, snimiti i pristupi podatcima, informacija i digitalnom sadržaju. Organizirati ih i procesirati u strukturiranom okruženju.

Iskazi - znanja, vještina i odgovornosti

Osnovna	
1	**2**
Uz pomoć i savjete drugih osoba: a.) Mogu identificirati gdje (npr. disk, usb, vanjski disk) i kako ih organizirati (npr. mape) prikupljene podatke i digitalni sadržaj za seminarski rad	Uz povremenu pomoć drugih osoba: a.) Mogu identificirati gdje (npr. disk, usb, vanjski disk, dropbox) i kako organizirati (npr. mape, mrežne) prikupljene podatke i digitalni sadržaj za seminarski rad. Redovito pristupam podacima koji su mi potrebni za rad.

Srednja	
3	**4**
Samostalnu u svrhu rješavanja izravnih problema: a.) Odabirem podatke, informacije i sadržaj te ih organiziram, snimam ih, pristupam svakodnevno, rutinski u različitom digitalnom okruženju sa različitih digitalnih uređaja	Samostalno, s obzirom na potrebe te rješavajući definirane i nesvakodnevne probleme: a.) Organiziram podatke, informacije i sadržaj na način da osiguravam jednostavnu pohranu i pristup, uz dugotrajno očuvanje (npr. različiti mrežni sustavi, Dropbox,..) b.) Organiziram podatke, informacije i sadržaj u strukturiranom okruženju (npr. putem tablica)

Napredna	
5	**6**
Samostalno te pomažući drugima: a.) Upravljam podacima, informacijama i digitalnim sadržajem za jednostavno pohranjivanje i pristup podacima, informacijama i digitalnom sadržaju (npr. objava podataka u okviru digitalnih repozitorija) b.) Provodim njihovo organiziranje i procesiranje u strukturiranom okruženju (npr. kroz repozitorije ili baze podataka)	Samostalno, s obzirom na potrebe drugih te rješavajući složene probleme: a.) Pripremam i upravljam podacima, informacijama i digitalnim sadržajem kako bi se osigurala jednostavna pohrana i brzi pristup (npr. implementacija podatkovnih repozitorija) b.) U svrhu ovoga prilagođavam strukturirano okruženje (npr. repozitorije) za njihovo odgovarajuće organiziranje i procesiranje

Visoko specijalizirana	
7	**8**
Prepoznavanjem potreba i probleme korisnika a.) Kreirati rješenja za složene probleme koji su djelomično definirani od strane korisnika u svrhu realizacije sustava za pohranjivanje i pristup podacima, informacijama i digitalnom sadržaju u strukturiranom obliku b.) Integrirati vlastito znanje za doprinos profesionalnoj praksi i znanju za edukaciju ostalih korisnika u području pohranjivanja i pristupa podacima, informacijama i digitalnom sadržaju	Prepoznavanje specifičnih potreba i probleme korisnika u složenoj okolini a.) Kreirati rješenja za rješavanje složenih i kompleksnih problema koji uključuju pohranjivanje i pristup podacima, informacijama i digitalnom sadržaju b.) Prezentirati nove i originalne ideje, rješenja u području pohrane i pristupa podacima, informacijama i digitalnom sadržaju

Procijenjena razina:	

Prilog 24. Digitalna kompetencija - 2.2. Dijeliti podatke, informacije i sadržaj putem digitalne tehnologije

Kompetencija	***2.2. Dijeliti podatke, informacije i sadržaj putem digitalne tehnologije***
Opis:	Dijeliti podatke, informacije i digitalni sadržaj s drugima putem digitalne tehnologije, te u praksi primjenjivati referenciranje izvora sadržaja.

Iskazi - znanja, vještina i odgovornosti

Osnovna	
1	**2**
Uz pomoć i savjete drugih: a.) Mogu identificirati i primijeniti jednostavnu digitalnu tehnologiju za razmjenu podataka, informacija i digitalnog sadržaja (npr. e-mail) b.) Mogu temeljem pomoći i definiranih postupaka primijeniti sustav referenciranja sadržaja	Uz povremenu pomoć drugih: a.) Mogu identificirati i primijeniti različite jednostavne digitalne tehnologije za razmjenu podataka, informacija i digitalnog sadržaja (npr. e-mail; webmail, dijeljene datoteke) b.) Mogu identificirati jednostavne sustave referenciranja (npr. unutar programa za obradu teksta)

Srednja	
3	**4**
Samostalnu u svrhu rješavanja izravnih problema: a.) Rutinski odabrati odgovarajuću digitalnu tehnologiju (npr. Dropbox) za dijeljenje podataka, informacija i digitalnog sadržaja b.) Rutinski primijeniti definirani sustav referenciranja (npr. u okviru programa za obradu teksta)	Samostalno, s obzirom na potrebe te rješavajući definirane i nesvakodnevne probleme: a.) Primijeniti odgovarajuću digitalnu tehnologiju za dijeljenje podataka, informacija i sadržaja koja je prikladna s obzirom na problem i okruženje u kojem radim b.) S obzirom na problem ili zadatak primijeniti različite sustave navođenja atributa i referenciranja (npr. Mendeley)

Napredna	
5	**6**
Samostalno te pomažući drugima: a.) Dijeliti podatke, informacije i digitalni sadrža različitom odgovarajućom digitalnom tehnologijom, te uz prilagodbu za druge korisnike (npr. Zotero, Mendeley, Dropbox) b.) Primijeniti različite sustave referenciranja te pomoći drugima u njihovom korištenju	Samostalno, s obzirom na potrebe drugih te rješavajući složene probleme: a.) Dijeliti podatke, informacije i digitalni sadrža različitom odgovarajućom digitalnom tehnologijom, te uz prilagodbu za različite skupine korisnika b.) Primijeniti različite sustave referenciranja te pomoći drugima u odabiru i korištenju tehnologije s obzirom na zadatke ili problem

Visoko specijalizirana	
7	**8**
Prepoznavanjem potreba i probleme korisnika: a.) Kreirati rješenja za složene probleme koji su djelomično definirani od strane korisnika u svrhu dijeljenja podataka, informacija i digitalnog sadržaja putem digitalne tehnologije b.) Integrirati vlastito znanje za doprinos profesionalnoj praksi i znanju za edukaciju ostalih korisnika u području dijeljenja podataka, informacija i digitalnog sadržaja	Prepoznavanje specifičnih potreba i probleme korisnika u složenoj okolini: a.) Kreirati rješenja za rješavanje složenih i kompleksnih problema koji uključuju interakciju različitih činitelja a koji su povezani uz dijeljenje podataka, informacija i digitalnog sadržaja b.) Prezentirati nove i originalne ideje, rješenja u području dijeljenja podataka, informacija i digitalnog sadržaja

Procijenjena razina:

Prilog 25. Digitalna kompetencija - 2.4. Surađivati putem digitalne tehnologije

Kompetencija	***2.4. Surađivati putem digitalne tehnologije***
Opis:	Koristiti digitalnu tehnologiju u svrhu zajedničke suradnje i kreiranju podataka, informacija i digitalnog sadržaja.

Iskazi - znanja, vještina i odgovornosti

Osnovna	
1	**2**
Uz pomoć i savjete drugih: a.) Mogu identificirati i primijeniti jednostavnu digitalnu tehnologiju za suradnju (npr. SMS, e-mail)	Uz povremenu pomoć drugih: a.) Mogu identificirati i primijeniti različite jednostavne digitalne tehnologije za suradnju (npr. Viber, SMS, e-mail)

Srednja	
3	**4**
Samostalnu u svrhu rješavanja izravnih problema: a.) Odabrati i raditi s digitalnom tehnologijom koja omogućava suradnju te jednostavno kreiranje podataka, informacija i digitalnog sadržaja (npr. Office 365)	Samostalno, s obzirom na potrebe te rješavajući definirane i nesvakodnevne probleme: a.) Odabrati i raditi sa različitom digitalnom tehnologijom koja omogućava suradnju te jednostavno kreiranje podataka, informacija i digitalnog sadržaja (npr. Office 365, Dropbox, Google Docs, Netvibes)

Napredna	
5	**6**
Samostalno te pomažući drugima: a.) Surađivati i kreirati podatke i digitalni sadržaj različitom odgovarajućom digitalnom tehnologijom (npr. Google Docs, Samepage, Trello, Assana)	Samostalno, s obzirom na potrebe drugih te rješavajući složene probleme: a.) Surađivati i kreirati podatke, informacije i digitalni sadrža različitom odgovarajućom digitalnom tehnologijom s obzirom na probleme ili zadatke (npr. komunikacija, rad na projektu), te uz prilagodbu za različite skupine korisnika

Visoko specijalizirana	
7	**8**
Prepoznavanjem potreba i problema korisnika: a.) Kreirati rješenja za složene probleme koji su djelomično definirani od strane korisnika u svrhu unaprijeđena suradnje putem digitalne tehnologije b.) Integrirati vlastito znanje za doprinos profesionalnoj praksi i znanju za edukaciju ostalih korisnika u području suradnje putem digitalne tehnologije	Prepoznavanje specifičnih potreba i probleme korisnika u složenoj okolini: a.) Kreirati rješenja za rješavanje složenih i kompleksnih problema koji uključuju interakciju i suradnju različitih činitelja b.) Prezentirati nove i originalne ideje, rješenja u području suradnje putem digitalne tehnologije

Procijenjena razina:

Prilog 26. Digitalna kompetencija - 3.1. Razviti digitalni sadržaj

Kompetencija	***3.1. Razviti digitalni sadržaj***
Opis:	Kreiranje i editiranje digitalnog sadržaja u različitim formatima, te korištenje digitalne tehnologije za samostalno izražavanje

Iskazi - znanja, vještina i odgovornosti

Osnovna	
1	**2**
Uz pomoć i savjete drugih: a.) Identificirati tutoriale (npr. na web stranicama, YouTubeu) i primijeniti jednostavnu digitalnu tehnologiju za kreiranje digitalnog sadržaja (npr. MS Paint) b.) Identificirati jednostavnu digitalnu tehnologiju (npr. Power Paint) za samostalno izražavanje	Uz povremenu pomoć drugih: a.) Identificirati tutoriale (npr. na web stranicama, YouTubeu) i primijeniti jednostavnu digitalnu tehnologiju za kreiranje i editiranje digitalnog sadržaja (npr. MS Paint, Google Drive, Inforgram) b.) Identificirati jednostavnu digitalnu tehnologiju (npr. Power Paint, web stranica) za samostalno izražavanje

Srednja	
3	**4**
Samostalnu u svrhu rješavanja izravnih problema: a.) Identificirati i primijeniti digitalne alate (npr. Google Drive, Office 365) u svrhu kreiranja i editiranja sadržaja prema unaprijed definiranim postupcima i formatima b.) Izraziti se putem definiranih i opće prihvaćenih digitalnih alata	Samostalno, s obzirom na potrebe te rješavajući definirane i nesvakodnevne probleme: a.) Identificirati i primijeniti digitalne alate (npr. Google Drive, Office 365) u svrhu kreiranja i editiranja sadržaja u različitim formatima (slika, video, zvuk) b.) Izraziti se putem definiranih i opće prihvaćenih digitalnih alata

Napredna	
5	**6**
Samostalno te pomažući drugima: a.) Identificirati i primijeniti različite digitalne alate (npr. Canava, Evernote, Fotojet, Infogram, Piktochart, Slideshare) u svrhu kreiranja i editiranja sadržaja u različitim formatima (slika, video, zvuk) b.) Demonstrirati kako se Izraziti putem različitih prihvaćenih digitalnih alata	Samostalno, s obzirom na potrebe drugih te rješavajući složene probleme: a.) Identificirati i primijeniti različite digitalne alate (npr. Slideshare, Videolean, Storify) u svrhu kreiranja i editiranja sadržaja u različitim formatima (slika, video, zvuk) b.) Odabrati odgovarajuće alate za samostalno izražavanje te demonstrirati drugima različite digitalne alate

Visoko specijalizirana	
7	**8**
Prepoznavanjem potreba i problema korisnika: a.) Kreirati rješenja za složene probleme koji su djelomično definirani od strane korisnika u svrhu kreiranja i editiranja digitalnog sadržaja b.) Integrirati vlastito znanje za doprinos profesionalnoj praksi i znanju u svrhu kreiranja i editiranja digitalnog sadržaja	Prepoznavanje specifičnih potreba i probleme korisnika u složenoj okolini: a.) Kreirati rješenja za rješavanje složenih i kompleksnih problema koji uključuju interakciju različitih činitelja a koji su povezani uz kreiranje i editiranje digitalnog sadržaja b.) Prezentirati nove i originalne ideje, rješenja u području kreiranja digitalnog sadržaja

Procijenjena razina:

Prilog 27. Digitalna kompetencija - 3.2. Integrirati i ponovno razviti digitalni sadržaj

Kompetencija	***3.2. Integrirati i ponovno razviti digitalni sadržaj***
Opis:	Modificirati, doraditi, unaprijediti te integrirati postojeće podatke, informacije ili digitalni sadržaj u svrhu kreiranja novog i relevantnog sadržaja

Iskazi - znanja, vještina i odgovornosti

Osnovna	
1	**2**
Uz pomoć i savjete drugih: a.) Odabrati postupke za mijenjanje, unaprjeđenje i jednostavnu integraciju postojećeg jednostavnog sadržaja (npr. video) u svrhu kreiranja novog sadržaja (npr. prezentacija sa videom)	Uz povremenu pomoć drugih: a.) Odabrati postupke i primijeniti ih za mijenjanje, unaprjeđenje i jednostavnu integraciju postojećeg sadržaja (npr. video, animacija) u svrhu kreiranja novog sadržaja (npr. prezentacija sa videom, video)

Srednja	
3	**4**
Samostalnu u svrhu rješavanja izravnih problema: a.) Primijeniti osnovne digitalne alate (Office 365, Google Docs, Animation Desk) za mijenjanje, unaprjeđenje i jednostavnu integraciju postojećeg sadržaja (npr. video, animacija) u svrhu kreiranja novog i jedinstvenog sadržaja (npr. prezentacija sa videom, video)	Samostalno, s obzirom na potrebe te rješavajući definirane i nesvakodnevne probleme: a.) Primijeniti standardne i različite digitalne alate (Office 365, Google Docs, Animation Desk) za mijenjanje, unaprjeđenje i jednostavnu integraciju postojećeg sadržaja (npr. video, animacija) u svrhu kreiranja novog i jedinstvenog sadržaja (npr. prezentacija sa videom, video)

Napredna	
5	**6**
Samostalno te pomažući drugima: a.) Primijeniti nove i različite digitalne alate (Giphy, SurveyMonkey, Wideo, Venngage) za mijenjanje, unaprjeđenje i jednostavnu integraciju postojećeg sadržaja (npr. video, animacija) u svrhu kreiranja novog i jedinstvenog sadržaja (npr. prezentacija sa videom, video)	Samostalno, s obzirom na potrebe drugih te rješavajući složene probleme: a.) Primijeniti različite digitalne alate (npr. Gamefroot, ThingLink, Ecamm, GotToWebinar, BotMakes) s obzirom na probleme, zadatke i korisnike za mijenjanje, unaprjeđenje i jednostavnu integraciju postojećeg sadržaja u svrhu kreiranja novog i jedinstvenog sadržaja

Visoko specijalizirana	
7	**8**
Prepoznavanjem potreba i problema korisnika: a.) Kreirati rješenja za složene probleme koji su djelomično definirani od strane korisnika u svrhu integriranja i kreiranja novog jedinstvenog sadržaja b.) Integrirati vlastito znanje za doprinos profesionalnoj praksi i znanju	Prepoznavanje specifičnih potreba i probleme korisnika u složenoj okolini: a.) Kreirati rješenja za rješavanje složenih i kompleksnih problema koji uključuju interakciju različitih činitelja b.) Prezentirati nove i originalne ideje, rješenja u području integriranja i kreiranja jedinstvenog digitalnog sadržaja

Procijenjena razina:

Prilog 28. Digitalna kompetencija - 3.3. Uvažavati te primijeniti autorska prava i dozvole

Kompetencija	***3.3. Uvažavati te primijeniti autorska prava i dozvole***
Opis:	Razumjeti autorska prava i licence, uvažavati ih te primijeniti na podatke, informacije i digitalni sadržaj

Iskazi - znanja, vještina i odgovornosti

Osnovna	
1	**2**
Uz pomoć i savjete drugih: a.) Identificirati i uvažavati jednostavna pravila vezana uz autorska prava i dozvole koje se primjenjuju za podatke, informacije i digitalni sadržaj	Uz povremenu pomoć drugih: a.) Identificirati i uvažavati pravila vezana uz autorska prava i dozvole koje se primjenjuju za podatke, informacije i digitalni sadržaj

Srednja	
3	**4**
Samostalnu u svrhu rješavanja izravnih problema: a.) Identificirati prema unaprijed definiranim pravilima (autorska prava, dozvole) on koje se mogu primijeniti za zaštitu podataka, informacija i digitalnog sadržaja, uvažavati tuđa prava i dozvole	Samostalno, s obzirom na potrebe te rješavajući definirane i nesvakodnevne probleme: a.) Primijeniti različita prava i prava u svrhu zaštite podataka, informacija i digitalnog sadržaja

Napredna	
5	**6**
Samostalno te pomažući drugima: a.) Analizirati različita prava i dozvole te ih primijeniti u različitim situacijama (npr. otvoreni podaci, digitalni sadržaj, aplikacije) i okruženju (edukacija, poslovno okruženje) na podatke, informacije i digitalni sadržaj	Samostalno, s obzirom na potrebe drugih te rješavajući složene probleme: a.) Kritički procijeniti upotrebu prava i dozvola, primijeniti odgovarajuća pravila i dozvole na podatke, informacije i digitalni sadržaj, te savjetovati korisnike u primjeni i uvažavanju pravila

Visoko specijalizirana	
7	**8**
Prepoznavanjem potreba i problema korisnika: a.) Kreirati rješenja za složene probleme koji su djelomično definirani od strane korisnika u svrhu primjene autorskih prava i dozvola za podatke, informacije i digitalni sadržaj b.) Integrirati vlastito znanje za doprinos profesionalnoj praksi i znanju	Prepoznavanje specifičnih potreba i probleme korisnika u složenoj okolini: a.) Kreirati rješenja za rješavanje složenih i kompleksnih problema koji uključuju interakciju različitih činitelja b.) Prezentirati nove i originalne ideje te rješenja u području

Procijenjena razina:	

Prilog 29. Digitalna kompetencija - 5.1. Prepoznati potrebe i pronalaziti tehnološka rješenja

Kompetencija	***5.1. Prepoznati potrebe i pronalaziti tehnološka rješenja***
Opis:	Identificirati potrebe, provesti njihovu evaluaciju te odabrati odgovarajuće tehnološko rješenje u svrhu njihovog ispunjenja. Prilagoditi digitalno okruženje prema potrebama.

Iskazi - znanja, vještina i odgovornosti

Osnovna	
1	**2**
Uz pomoć i savjete nastavnika: a.) Prepoznati osnovne potrebe (npr. komunikacija, pohrana podataka) koje je moguće realizirati putem digitalne tehnologije i okruženja b.) Koristiti osnovne funkcionalnosti digitalne tehnologije (aplikacija, uređaja) u svrhu ispunjenja potreba c.) Napraviti osnovno podešavanje digitalne tehnologije u svrhu lakšeg korištenja	Uz povremenu pomoć drugih: a.) Prepoznati šire potrebe (npr. komunikacija, suradnja, izrada prezentacija, rada) koje je moguće realizirati putem digitalne tehnologije i okruženja b.) Prepoznati i koristiti širi krug digitalnih alata i uređaja u svrhu ispunjenja potreba c.) Napraviti osnovno podešavanje digitalne tehnologije u svrhu lakšeg korištenja

Srednja	
3	**4**
Samostalnu u svrhu rješavanja izravnih problema: a.) Prepoznati svakodnevne potrebe (komunikacija) ili rutinske zadatke (zadaće, prezentacije, radovi) b.) Koristiti svakodnevne uređaje (računalo, mobitel) i alate (Viber, Word, Excel, Power Point) u svrhu ispunjenja svakodnevnih potreba c.) Primijeniti osnovne i definirane postupke za prilagodbu digitalnih uređaja i aplikacija	Samostalno, s obzirom na potrebe te rješavajući definirane i nesvakodnevne probleme: a.) Objasniti potrebe u okviru digitalnog okruženja b.) Odabrati odgovarajuće digitalne uređaje i alate za njihovo ispunjenje c.) Rutinski primijeniti osnovne i definirane postupke za prilagodbu digitalnih uređaja i aplikacija

Napredna	
5	**6**
Samostalno te pomažući drugima: a.) Prepoznati i evaluirati potrebe b.) Odabrati odgovarajuće digitalne uređaje i različite alate za njihovo ispunjenje, te koristiti njihove različite funkcionalnosti c.) Rutinski primijeniti napredne i različite postupke za prilagodbu digitalnih uređaja i aplikacija	Samostalno, i s obzirom na potrebe drugih te rješavajući složene probleme: a.) Prepoznati, evaluirati i kritički prosuditi potrebe b.) Odabrati odgovarajuće digitalne uređaje i različite alate za njihovo ispunjenje, koristiti njihove različite funkcionalnosti, proširiti funkcionalnosti te voditi računa o korisnicima i okruženju d) Provoditi i evaluirati različite potrebe i digitalnu tehnologiju, te je prilagoditi s obzirom na potrebe korisnika

Visoko specijalizirana	
7	**8**
Prepoznavanjem potreba i problema korisnika: a.) Kreirati rješenja na temelju digitalne tehnologije kojima se mogu ispuniti potrebe korisnika kod složenih i nepredvidljivih problema b.) Integrirati vlastito znanje za doprinos profesionalnoj praksi i znanju za edukaciju ostalih korisnika u području	Prepoznavanje specifičnih potreba i probleme korisnika u složenoj okolini: a.) Kreirati digitalne aplikacije i uređaje za rješenje složenih i kompleksnih problema različitih korisnika b.) Prezentirati nove i originalne ideje, rješenja u području digitalne tehnologije

Procijenjena razina:

Prilog 30. Digitalni objekt, podatci i metapodatkovni elementi

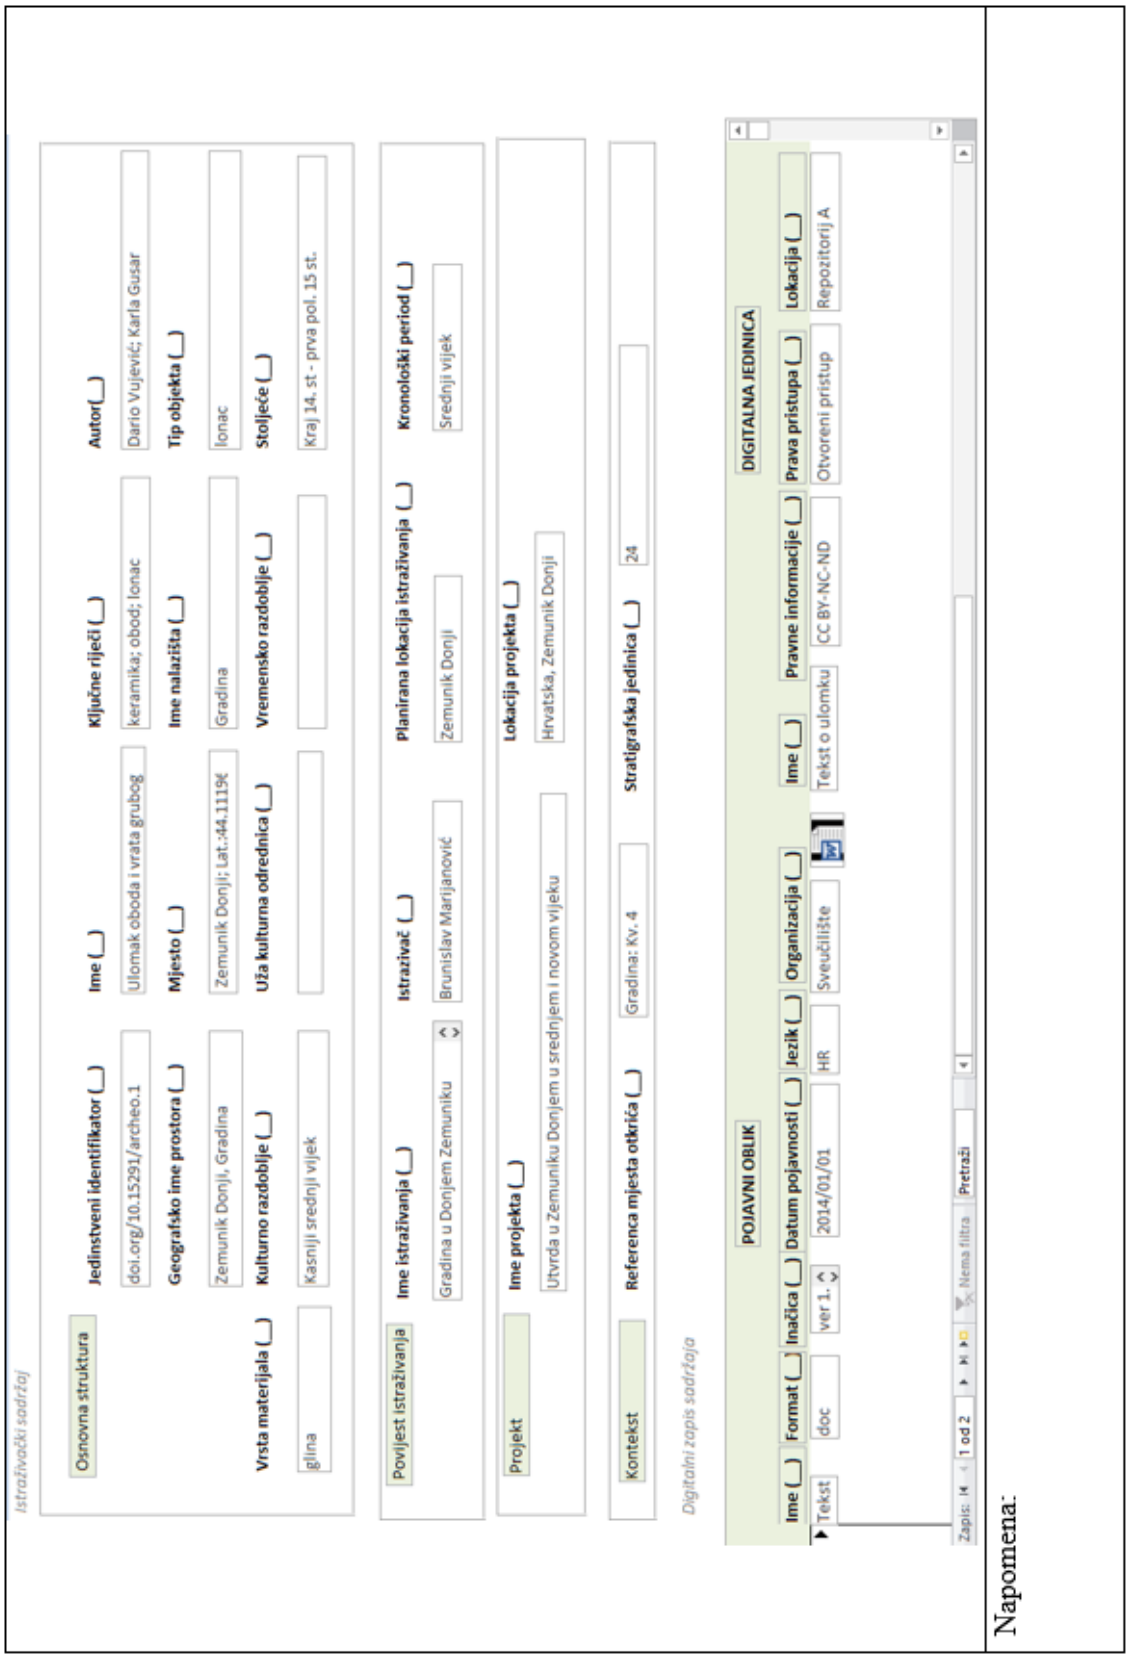

Napomena:

Prilog 31. Rezultati procjene aplikacijskog profila od strane korisnika

Element	Kvantifikatori					Ukupno
	nije opće važan *(N)*	ponekad važan *(N)*	umjereno važan *(N)*	vrlo važan *(N)*	presudno važan *(N)*	
1	*2*	*3*	*4*	*5*	*6*	*7*
1.1.1. Jedinstveni identifikator	0	0	6	7	7	20
1.1.2. Ime	0	2	3	5	9	19
1.1.3. Ključne riječi	0	1	4	8	7	20
1.1.4. Autor	0	2	4	4	10	20
1.1.5. Geografski ime prostora	0	1	5	8	6	20
1.1.6. Mjesto	0	1	2	11	6	20
1.1.7. Ime nalazišta	0	1	1	6	12	20
1.1.8. Tip objekta	0	1	2	5	12	20
1.1.9. Vrsta materijala	0	0	3	4	13	20
1.1.10. Kulturno razdoblje	0	0	1	3	16	20
1.1.11. Uža kulturna odrednica	0	2	5	7	6	20
1.1.12. Vremensko razdoblje	0	0	1	4	15	20
1.1.13. Stoljeće	0	1	4	6	9	20
1.2.1. Ime istraživanja	0	2	5	7	6	20
1.2.2. Istraživač	0	2	4	4	10	20
1.2.3. Geografska lokacija	0	0	4	10	6	20
1.2.4. Kronološki period i razdoblje	0	0	2	5	13	20
1.3.1. Ime projekta	1	5	8	4	2	20
1.3.2. Lokacija projekta	0	1	8	8	3	20
1.4.1. Referenca mjesta otkrića	0	1	2	6	11	20
1.4.2. Stratigrafska jedinica	0	0	3	4	13	20
2.1.1. Ime pojavnog oblika	0	3	6	6	5	20
2.1.2. Format	0	3	4	8	5	20
2.1.3. Inačica	1	4	8	4	3	20
2.1.4. Datum pojavnosti	0	5	5	8	2	20
2.1.5. Jezik	2	4	3	7	4	20
2.1.6. Organizacija	0	2	8	6	4	20
2.2.1. Ime jedinice	0	3	4	7	6	20
2.2.2. Pravne informacije	0	4	5	7	4	20
2.2.3. Prava pristupa	0	2	4	6	8	20
2.2.4. Lokacija	0	2	2	8	8	20

Prilog 32. Rezultati o važnosti elemenata – 1. situacija

Elementi	Generički zadatci													
	Grupa A					Grupa B					Grupa A		Grupa B	
	F (N)	I (N)	S (N)	RU (N)	Σ	F (N)	I (N)	S (N)	RU (N)	Σ	Mod	Tip	Mod	Tip
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*	*10*	*11*	*12*	*13*	*14*	*15*
Jedinstveni identifikator	1	2	2	1	6	2	4	2	3	11	2	I,S	4	I
Ime	4	3	0	0	7	2	7	3	0	12	4	F	7	I
Ključne riječi	5	0	2	0	7	3	6	1	2	12	5	F	6	I
Autor	5	1	1	0	7	4	4	2	0	10	5	F	4	F,I
Geografski ime prostora	3	2	1	0	6	5	3	2	0	10	3	F	5	F
Mjesto	2	4	0	0	6	2	5	0	2	9	4	I	5	I
Ime nalazišta	2	4	1	0	7	4	4	0	1	9	4	I	4	F,I
Tip objekta	1	5	1	0	7	1	7	3	0	11	5	I	7	I
Vrsta materijala	0	4	1	0	5	0	5	1	2	8	4	I	5	I
Kulturno razdoblje	2	3	1	1	7	1	5	3	0	9	3	I	5	I
Uža kulturna odrednica	1	2	2	1	6	0	2	3	1	6	2	I,S	3	S
Vremensko razdoblje	3	1	0	2	6	1	4	1	0	6	3	F	4	I
Stoljeće	1	2	1	2	6	0	8	3	0	11	2	I	8	I
Ime istraživanja	5	2	0	1	8	7	1	2	2	12	5	F	7	F
Istraživač	6	2	0	0	8	10	0	0	2	12	6	F	10	F
Geografska lokacija	5	2	0	1	8	6	3	2	0	11	5	F	6	F
Kronološki period i razdoblje	3	3	2	0	8	3	5	2	0	10	3	F,I	5	I
Ime projekta	2	3	1	1	7	7	1	1	2	11	3	I	7	F
Lokacija projekta	2	4	0	1	7	5	1	3	1	10	4	I	5	F
Referenca mjesta otkrića	2	2	0	1	5	0	1	4	3	8	2	F,I	4	S
Stratigrafska jedinica	1	2	0	1	4	1	2	3	2	8	2	I	3	S
Ime pojavnog oblika	2	2	0	2	6	0	0	3	2	5	2	F,I,RU	3	S
Format	1	1	2	3	7	0	0	5	0	5	3	RU	5	S
Inačica	0	2	2	2	6	0	0	4	0	4	2	I,S,RU	4	S
Datum pojavnosti	1	2	3	1	7	1	0	3	0	4	3	S	3	S
Jezik	0	3	3	1	7	0	0	4	0	4	3	I,S	4	S
Organizacija	1	2	2	1	6	0	0	4	0	4	2	I,S	4	S
Ime jedinice	2	2	0	2	6	0	0	3	2	5	2	F,I,RU	3	S
Pravne informacije	1	3	0	1	5	0	0	3	2	5	3	I	3	S
Prava pristupa	1	2	2	2	7	0	0	3	1	4	2	I,S,RU	3	S
Lokacija	2	2	2	1	7	0	0	3	2	5	2	F,I,S	3	S
UKUPNO	67	74	32	29		65	78	76	32					

Prilog 33. Rezultati o važnosti elemenata – 2. situacija

	Generički zadatci													
	Grupa A					Grupa B					Grupa A		Grupa B	
Elementi	F (N)	I (N)	S (N)	RU (N)	Σ	F (N)	I (N)	S (N)	RU (N)	Σ	Mod	Tip	Mod	Tip
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Jedinstveni identifikator	2	2	2	0	6	0	4	3	3	10	2	F,I,S	4	I
Ime	1	4	1	0	6	1	7	2	0	10	4	I	7	I
Ključne riječi	3	1	0	3	7	3	5	1	0	9	3	F	5	I
Autor	5	2	0	0	7	6	2	0	1	9	5	F	6	F
Geografski ime prostora	2	2	1	0	5	4	3	1	1	9	2	F,I	4	F
Mjesto	1	2	1	1	5	2	1	5	0	8	2	I	5	S
Ime nalazišta	3	2	0	1	6	2	4	4	0	10	3	F	4	I,S
Tip objekta	0	3	1	0	4	1	5	2	1	9	3	I	5	I
Vrsta materijala	0	4	1	0	5	0	5	0	3	8	4	I	5	I
Kulturno razdoblje	0	3	3	0	6	1	4	3	1	9	3	I,S	4	I
Uža kulturna odrednica	0	3	2	0	5	0	5	5	0	10	3	I	5	I,S
Vremensko razdoblje	1	1	3	0	5	1	4	0	0	5	3	S	4	I
Stoljeće	0	2	4	0	6	2	6	3	1	12	4	S	6	I
Ime istraživanja	6	0	1	0	7	8	0	2	0	10	6	F	8	F
Istraživač	6	1	0	0	7	7	2	1	0	10	6	F	7	F
Geografska lokacija	2	3	1	0	6	5	2	2	1	10	3	I	5	F
Kronološki period i razdoblje	3	2	2	0	7	4	4	1	1	10	3	F	4	F,I
Ime projekta	3	2	0	1	6	6	0	2	3	11	3	F	6	F
Lokacija projekta	3	2	0	1	6	3	4	2	1	10	3	F	4	I
Referenca mjesta otkrića	1	2	0	2	5	1	0	6	1	8	2	I,RU	6	S
Stratigrafska jedinica	0	2	0	2	4	1	1	5	1	8	2	I,RU	5	S
Ime pojavnog oblika	1	2	1	0	4	0	2	2	2	6	2	I	2	I,S,RU
Format	1	2	3	0	6	0	2	2	3	7	3	S	3	RU
Inačica	0	3	2	0	5	0	2	2	2	6	3	I	2	I,S,RU
Datum pojavnosti	1	2	2	0	5	0	1	2	2	5	2	I,S	2	S,RU
Jezik	1	2	2	0	5	1	1	2	2	6	2	I,S	2	S,RU
Organizacija	1	2	1	1	5	1	1	2	2	6	2	I	2	S,RU
Ime jedinice	2	1	1	0	4	0	2	1	3	6	2	F	3	RU
Pravne informacije	0	2	1	1	4	0	2	1	2	5	2	I	2	I,RU
Prava pristupa	0	0	5	0	5	1	2	1	1	5	5	S	2	I
Lokacija	0	3	0	1	4	2	1	1	1	5	3	I	2	F
UKUPNO	49	64	41	14		63	84	66	39					

Prilog 34. Rezultati o važnosti elemenata – 3. situacija

Elementi	Generički zadatci													
	Grupa A					Grupa B					Grupa A		Grupa B	
	F (N)	I (N)	S (N)	RU (N)	Σ	F (N)	I (N)	S (N)	RU (N)	Σ	Mod	Tip	Mod	Tip
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*	*10*	*11*	*12*	*13*	*14*	*15*
Jedinstveni identifikator	3	4	0	0	7	2	1	2	5	10	4	I	5	RU
Ime	1	3	2	1	7	2	6	3	1	12	3	I	6	I
Ključne riječi	1	4	1	1	7	5	5	2	0	12	4	I	5	F,I
Autor	4	1	1	0	6	6	1	2	0	9	4	F	6	F
Geografski ime prostora	2	4	0	1	7	1	7	1	0	9	4	I	7	I
Mjesto	1	4	1	0	6	1	4	5	0	10	4	I	5	S
Ime nalazišta	3	4	0	1	8	4	3	2	1	10	4	I	4	F
Tip objekta	0	4	2	0	6	2	7	1	0	10	4	I	7	I
Vrsta materijala	0	5	1	0	6	1	4	2	1	8	5	I	4	I
Kulturno razdoblje	1	3	1	0	5	0	5	2	0	7	3	I	5	I
Uža kulturna odrednica	1	2	1	0	4	0	2	4	1	7	2	I	4	S
Vremensko razdoblje	1	2	2	0	5	1	3	2	1	7	2	I,S	3	I
Stoljeće	1	3	1	0	5	4	5	2	0	11	3	I	5	I
Ime istraživanja	5	0	0	1	6	7	2	0	1	10	5	F	7	F
Istraživač	4	2	0	0	6	6	2	1	2	11	4	F	6	F
Geografska lokacija	3	3	0	0	6	4	2	2	1	9	3	F,I	4	F
Kronološki period i razdoblje	3	1	2	0	6	6	2	0	2	10	3	F	6	F
Ime projekta	2	2	1	0	5	3	4	1	1	9	2	F,I	4	I
Lokacija projekta	1	2	2	0	5	3	2	1	1	7	2	I,S	3	F
Referenca mjesta otkrića	2	0	0	2	4	1	2	5	1	9	2	F,RU	5	S
Stratigrafska jedinica	0	1	0	2	3	3	2	3	0	8	2	RU	3	F,S
Ime pojavnog oblika	0	4	0	0	4	0	0	4	1	5	4	I	4	S
Format	2	1	2	0	5	1	1	2	4	8	2	F,S	4	RU
Inačica	0	4	1	0	5	0	1	2	3	6	4	I	3	RU
Datum pojavnosti	0	2	2	0	4	0	2	2	3	7	2	I,S	3	RU
Jezik	0	1	3	0	4	0	1	2	3	6	3	S	3	RU
Organizacija	0	2	2	0	4	0	2	2	1	5	2	I,S	2	I,S
Ime jedinice	0	4	0	0	4	1	0	3	2	6	4	I	3	S
Pravne informacije	0	4	0	0	4	0	0	4	1	5	4	I	4	S
Prava pristupa	0	1	3	0	4	1	0	5	0	6	3	S	5	S
Lokacija	1	3	0	0	4	0	0	6	0	6	3	I	6	S
	42	80	31	9		65	78	75	37					

Prilog 35. Rezultati o važnosti elemenata – 4. situacija

Elementi	Generički zadatci													
	Grupa A					Grupa B					Grupa A		Grupa B	
	F (N)	I (N)	S (N)	RU (N)	Σ	F (N)	I (N)	S (N)	RU (N)	Σ	Mod	Tip	Mod	Tip
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Jedinstveni identifikator	0	4	0	2	6	2	4	3	2	11	4	I	4	I
Ime	0	4	0	1	5	1	6	4	0	11	4	I	6	I
Ključne riječi	4	2	0	0	6	7	3	2	0	12	4	F	7	F
Autor	4	1	1	0	6	6	2	1	1	10	4	F	6	F
Geografski ime prostora	1	3	3	0	7	4	2	3	1	10	3	I,S	4	F
Mjesto	0	3	3	0	6	2	5	1	2	10	3	I,S	5	I
Ime nalazišta	3	2	1	1	7	4	3	2	1	10	3	F	4	F
Tip objekta	0	3	1	2	6	1	4	2	1	8	3	I	4	I
Vrsta materijala	0	4	2	0	6	0	5	2	1	8	4	I	5	I
Kulturno razdoblje	2	2	1	2	7	2	3	2	1	8	2	F,I,RU	3	I
Uža kulturna odrednica	0	2	1	2	5	1	5	2	1	9	2	I,RU	5	I
Vremensko razdoblje	1	0	3	1	5	2	4	2	0	8	3	S	4	I
Stoljeće	2	1	1	2	6	2	6	0	1	9	2	F,RU	6	I
Ime istraživanja	5	1	1	1	8	7	2	0	1	10	5	F	7	F
Istraživač	8	0	0	0	8	8	1	1	1	11	8	F	8	F
Geografska lokacija	2	2	0	2	6	3	4	1	2	10	2	F,I,RU	4	I
Kronološki period i razdoblje	4	1	1	0	6	6	3	0	1	10	4	F	6	F
Ime projekta	4	2	2	0	8	4	1	3	2	10	4	F	4	F
Lokacija projekta	3	3	1	0	7	3	2	3	1	9	3	F,I	3	F,S
Referenca mjesta otkrića	2	2	1	1	6	2	1	5	2	10	2	F,I	5	S
Stratigrafska jedinica	0	4	1	0	5	1	2	5	1	9	4	I	5	S
Ime pojavnog oblika	1	1	1	0	3	0	0	2	2	4	1	F,I,S	2	S,RU
Format	2	2	3	0	7	0	1	4	2	7	3	S	4	S
Inačica	1	4	0	1	6	0	2	3	1	6	4	I	3	S
Datum pojavnosti	0	5	0	1	6	1	2	3	1	7	5	I	3	S
Jezik	0	2	4	0	6	2	1	3	0	6	4	S	3	S
Organizacija	0	2	2	2	6	0	1	3	0	4	2	I,S,RU	3	S
Ime jedinice	2	2	2	1	7	1	1	3	3	8	2	F,I,S	3	S,RU
Pravne informacije	0	3	0	1	4	0	1	3	1	5	3	I	3	S
Prava pristupa	0	2	3	2	7	0	1	3	2	6	3	S	3	S
Lokacija	1	4	0	1	6	1	2	2	1	6	4	I	2	I,S
	52	73	39	26		73	80	73	36					

Prilog 36. Rezultati o važnosti elemenata – 5. situacija

Elementi	Generički zadatci													
	Grupa A					Grupa B					Grupa A		Grupa B	
	F (N)	I (N)	S (N)	RU (N)	Σ	F (N)	I (N)	S (N)	RU (N)	Σ	Mod	Tip	Mod	Tip
1	*2*	*3*	*4*	*5*	*6*	*7*	*8*	*9*	*10*	*11*	*12*	*13*	*14*	*15*
Jedinstveni identifikator	2	6	0	0	8	2	3	3	2	10	6	I	3	I,S
Ime	2	4	0	0	6	4	4	2	0	10	4	I	4	F,I
Ključne riječi	4	0	2	0	6	7	3	1	0	11	4	F	7	F
Autor	1	2	3	0	6	4	2	2	1	9	3	S	4	F
Geografski ime prostora	2	2	1	1	6	3	4	2	0	9	2	F,I	4	I
Mjesto	2	1	3	0	6	3	5	1	1	10	3	S	5	I
Ime nalazišta	3	2	1	1	7	3	5	2	0	10	3	F	5	I
Tip objekta	1	6	0	0	7	3	4	1	1	9	6	I	4	I
Vrsta materijala	1	2	3	1	7	1	4	4	2	11	3	S	4	I,S
Kulturno razdoblje	1	1	3	1	6	1	5	3	1	10	3	S	5	I
Uža kulturna odrednica	0	3	2	0	5	0	6	4	0	10	3	I	6	I
Vremensko razdoblje	1	1	3	1	6	4	4	1	0	9	3	S	4	F,I
Stoljeće	2	2	2	0	6	3	8	1	0	12	2	F,I,S	8	I
Ime istraživanja	5	2	0	1	8	6	2	0	2	10	5	F	6	F
Istraživač	7	1	0	0	8	7	1	0	2	10	7	F	7	F
Geografska lokacija	3	1	0	1	5	2	3	3	2	10	3	F	3	I,S
Kronološki period i razdoblje	6	0	1	0	7	2	4	3	2	11	6	F	4	I,S
Ime projekta	3	3	1	0	7	4	1	3	1	9	3	F,I	4	F
Lokacija projekta	4	2	1	0	7	0	7	2	0	9	4	F	7	I,S
Referenca mjesta otkrića	3	2	0	0	5	0	4	4	1	9	3	F	4	I,S
Stratigrafska jedinica	1	4	2	0	7	0	3	4	2	9	4	I	4	S
Ime pojavnog oblika	3	1	1	1	6	1	1	3	3	8	3	F	3	S,RU
Format	1	2	4	0	7	2	1	4	1	8	4	S	4	S
Inačica	2	4	0	1	7	1	3	3	0	7	4	I	3	I,S
Datum pojavnosti	1	4	0	1	6	0	2	2	1	5	4	I	2	I,S
Jezika	1	1	4	0	6	1	2	4	0	7	4	S	4	S
Organizacija	1	1	1	1	4	0	3	2	0	5	1	F,I,S,RU	3	I
Ime jedinice	3	1	1	1	6	1	1	3	3	8	3	F	3	S,RU
Pravne informacije	0	2	1	2	5	1	3	2	2	8	2	I,RU	3	I
Prava pristupa	0	2	3	1	6	0	1	5	2	8	3	S	5	S
Lokacija	2	2	1	1	6	0	3	3	0	6	2	F,I	3	I,S
	68	67	44	16		66	102	77	32					

Prilog 37. Popis oznaka i kratica

ADS – engl. Archaeology Data Service

ANDS – engl. Australian National Data Service

ANSI – engl. American National Standard Institute

AP – aplikacijski profil

Arh-Istr - znanstveno istraživački rad u području arheologije

ARCS – engl. Archaeological Resoruce Cataloging Systems

ARIADNE – engl. Advanced Research Infrastructure for Archaeological Dataset Networking in Europe

ARK – engl. Archival Resource Key

AVM – engl. Astronomy Visualization Metadata

BP1 – baza podataka Tranzicija i tradicija u špilji Vlakno: Model prijelaza paleolitika u mezolitik na prostoru Sjeverne Dalmacije

BP2 – baza podataka Utvrda u Zemuniku Donjem u srednjem i novom vijeku

CAD – engl. Computer Aided Design

CARARE – engl. Connecting Archaeology and Architecture in Europeana

CDSASM – engl. The Core Data Standard for Archeological Sites and Monuments

CDATA – engl. Character Data

CERIF – engl. Common European Research Information Format

CIDOC – engl. International Committee for Documentation

CLEI – engl. Common Language Equipment Identifier

Cns – metrika konsenzus

CNRI – engl. Corporation for National Research Initiatives

CROSBI – Hrvatska znanstvena bibliografija

csv – engl. comma-separated values

DABAR – Digitalni akademski arhivi i repozitoriji

DANS – engl. Data Archiving and Networked Services

DARIAH – engl. Digital Research Infrastrucutre for the Arts and Humanities

DDI – engl. Data Document Initiative

DC - engl. Dublin Core

DCMI – engl. Dublin Core Metadata Initiative

DCMI-SF – engl. Dublin Core Metadata Initiative – Singapore Framework

DIF - engl. Directory Interchange Format

DIGCOMP – engl. European Digital Competence Framework for Citizens

DTD – engl. Documet Type Definition

DS – diplomski studij

DOI – engl. Digital Object Identifier

DOK - rad na dokumentiranju i zaštiti arheološke građe

EASY – engl. Electronic Archiving System of DANS

EDNA – engl. E-Depot Dutch Archaeology

EML - engl. Ecological Metadata Language

ERC – engl. Electronic Resource Citation

ePIC – engl. European Persistent Identifier Consortium

ER – engl. Entity Relationship diagram

EU – Europska unija

F - pronalazak

FAIR - engl. Findable, Accessible, Interoperable, Reusable

FRBR – engl. Functional Requirments for Bibliographic Records

GHR – engl. Global Handle Registry

GIS – geoinformacijski sustavi

GPS - globalni položajni sustav

HTML – engl. Hypertext Markup Language

HRČAK – Portal hrvatskih znanstvenih i stručnih časopisa

I - identifikacija

IANUS – Njemački digitalni repozitorij za arheološke pronalaske i istraživanja

IANA – engl. Internet Assigned Numbers Authority

ICDSAO – engl. International Core Data Standard for Archaeological Objects

ICOM – engl. International Council of Museum

IDF – engl. International DOI Foundation

IEC – engl. International Electrotehnical Commission

IEEE – engl. Institute of Electrical and Electronics Engineers

IETF – engl. Internet Engineering Task Force

IFLA – engl. International Federation of Library Associations

IOP – oznaka za strčunjaka u istraživanju

IRGMA – engl. Information Retrieval Group of the Museum Assocation

ISBN – engl. International Standard Book Number

ISO – engl. International Organization for Standardization

ISSN – engl. International Standard Serial Number

Kns - konsenzus

LCCN – engl. Library of Congress Control Number

LIDO – engl. Lightweight Information Describing Objects

LOD – engl. Linked Open Data

LSID – engl. Life Science Identifiers

MAP – engl. Metadata Application Profile

MAPPA – ita. Metodologie applicate all predittività del potenziale archeologico,

MAP-RI – MAP reverzni inženjering

METS – engl. Metadata Encoding and Transmission Standard

MIME – engl. Multipurpose Internet Mail Extensions

MINARK – engl. Management of Information in Arkaeology

MOD – engl. MAPPA Open Data Metadata

MODS – engl. Metadata Object Description Schema

mu – mobilni uređaji

NAAN – engl. Name Assigning Authority Number

NARCIS – engl. National Research and Collaboration Information System

NDP – oznaka za nadopunu

NISO – engl. National Information Standards Organization

NMA – engl. Name Authority Mapping

OA – otvoreni pristup

OAI-ORE - engl. Open Archives Initiative Object Reuse and Exchange

OECD – engl. Organization for Economic Cooperation and Development)

OP – otvoreni podatci (engl. Open data)

OpenURL – standardizirani format za kodiranje opisa resursa sa URL

or – osobna računala

PD – preddiplomski studij

PDF – engl. Portable Document Format

PICHE – engl. Persistent Identifiers for Cultural Heritage Entities

PID – engl. Persistent Identifier

PR – primjedba (izostavljanje elemenata)

PURL – engl. Persistent URL

RDA – engl. Research Data Aliance

RDF - engl. Resource Description Framework

RFC – engl. Request for Comments

RU – pristup i ponovna uporaba

RQ – engl. Research Question

S – odabir

sCns - metrika snage konsenzusa

SDMX - engl. Statistical Data and Metadata Exchange

tDAR – engl. The Digital Archaeological Record

THOR – engl. Tehnical and Human Infrastructure for Open Research

TI – trajni identifikator

TRIDaS – engl. The Tree Ring Data Standard

txt – tekstualna datoteka

UK – Ujedinjeno Kraljevstvo Velike Britanije i Sjeverne Irske

UML – engl. Unified Modelling Language

UNESCO – engl. United Nations Educational, Scientific and Cultural Organization

URI – engl. Uniform Resource Identificator

URL – engl. Uniform Resource Locator

URN – engl. Uniform Resoruce Names

ZI – znanstveno istraživanje

XML – engl. Extensible Markup Language

XSD – engl. XML Schema Definition

W3C – engl. World Wide Web Consortium

3D – tri dimenzije

Prilog 38. Popis slika

Slika 1.: Primjer sustava trajnog identifikatora 88
Slika 2.: Postupak istraživanja primjenom Delphi metode 114
Slika 3.: Konceptualni prikaz arheološkog entiteta u fizičkom svijetu i digitalnom okruženju 116
Slika 4.: Primjer pitanja u mjernom instrumentu za I. iteraciju 118
Slika 5.: Primjer pitanja u mjernom instrumentu za II. iteraciju 126
Slika 6.: Primjer pitanja u mjernom instrumentu za III. iteraciju 129
Slika 7.: Konceptualni model kreiranja digitalnog objekta 139
Slika 8.: Konceptualni model digitalnog objekta pomoću FRBR 140
Slika 9.: Model domene aplikacijskog profila 141
Slika 10.: Entiteti i veze aplikacijskog profila 142
Slika 11.: Primjer povezanosti metapodatkovnih elemenata i kvantifikatora 176
Slika 12.: Usporedba razina digitalnih kompetencija ispitanika 181
Slika 13.: Važni elementi ispitanika 183
Slika 14.: Rezultati procjene relevantnosti elemenata aplikacijskog profila 186

Prilog 39. Popis tablica

Tablica 1.: Opisi i konstrukti podataka iz literature 17
Tablica 2.: Činitelji promjena u znanstvenim istraživanjima 37
Tablica 3.: Zahtjevi za metapodatke kod istraživačkih podatkovnih repozitorija 54
Tablica 4.: Usporedba razvojnih pristupa za aplikacijski profil 62
Tablica 5.: Prikaz entiteta za sadržajne stavke osnovnog sadržaja 71
Tablica 6.: Relevantni metapodatkovni elementi povijesti istraživanja..... 103
Tablica 7.: Relevantni metapodatkovni elementi projekta..... 105
Tablica 8.: Relevantni metapodatkovni elementi osnovne strukture 106
Tablica 9.: Relevantni metapodatkovni elementi konteksta 109
Tablica 10.: Prikaz sadržajnih stavki i entiteta digitalnog objekta..... 110
Tablica 11.: Skala kvantifikatora za I. iteraciju istraživanja 117
Tablica 12.: Stručna skupina za I. iteraciju 119
Tablica 13.: Prikupljeni podatci i interna konzistentnost za I. iteraciju istraživanja 120
Tablica 14.: Identificirani elementi I. iteracije 124
Tablica 15.: Skala kvantifikatora za II. iteraciju 125
Tablica 16.: Stručna skupina za II. iteraciju istraživanja 127
Tablica 17.: Prikupljeni podatci i interna konzistentnost za II. iteraciju istraživanja ... 128
Tablica 18.: Prikupljeni podatci i interna konzistentnost za III. iteraciju istraživanja.. 133
Tablica 19.: Metapodatkovni elementi s ostvarenim konsenzusom..... 133
Tablica 20.: Povezanost funkcionalnih zahtjeva za aplikacijski profil i utvrđenih metapodatkovnih elemenata 138
Tablica 21.: Metapodatkovni elementi aplikacijskog profila..... 144
Tablica 22.: Usporedba funkcionalnih zahtjeva trajnih identifikatora..... 161
Tablica 23.: Atributi istraživačke baze podataka „Tranzicija i tradicija u špilji Vlakno: Model prijelaza paleolitika u mezolitik na prostoru Sjeverne Dalmacije“ 166
Tablica 24.: Atributi druge istraživačke baze podataka „Utvrda u Zemuniku Donjem u srednjem i novom vijeku“ 167
Tablica 25.: Mapiranje atributa baza podataka i elemenata aplikacijskog profila 169
Tablica 26.: Povezanost temeljnih funkcionalnih zahtjeva i digitalnih kompetencija.. 174
Tablica 27.: Pregled pet definiranih situacija korištenih za utvrđivanje korisničke percepcije korisnosti metapodatkovnih elemenata..... 177
Tablica 28.: Distribucija ispitanika po dobi 179
Tablica 29.: Distribucija ispitanika s obzirom na korištenje digitalnih tehnologija 179
Tablica 30.: Digitalne kompetencije ispitanika preddiplomske razine 180
Tablica 31.: Digitalne kompetencije ispitanika diplomske razine 180
Tablica 32.: Funkcionalni zahtjevi i razine digitalnih kompetencija 182
Tablica 33.: Argumentacija ispitanika o imenovanim elementima..... 183
Tablica 34.: Test značajnih razlika za prvu situaciju 187
Tablica 35.: Test značajnih razlika za drugu situaciju 188
Tablica 36.: Test značajnih razlika za treću situaciju 189
Tablica 37.: Test značajnih razlika za četvrtu situaciju 190
Tablica 38.: Test značajnih razlika za petu situaciju..... 190

ŽIVOTOPIS AUTORA

Neven Pintarić rođen je u Varaždinu. Nakon završene srednje elektrotehničke škole upisao je i završio studij na Fakultetu organizacije i informatike Varaždin, Sveučilište u Zagrebu te stekao zvanje diplomirani informatičar (dipl. inf.). Nakon studija na Filozofskom fakultetu u Zadru završio je dodatno pedagoško, psihološko, didaktičko i metodičko obrazovanje za obavljanje poslova nastavnika, položio je državni ispit te stekao zvanje profesora informatike / računalstva. Na Fakultetu elektrotehnike, strojarstva i brodogradnje, Sveučilište u Splitu, završio je program stručnog usavršavanja Cisco akademije mrežnih tehnologija. Trenutno radi na Sveučilištu u Zadru kao voditelj Informatičke službe. Član je društva Association for Computing Machinery (ACM).

Tijekom proteklog razdoblja radio je na nizu informatičkih projekata iz područja poslovne informatike, obrazovanja i znanstveno-istraživačke infrastrukture. Od važnijih projekata na kojima je radio možemo istaknuti TAC-Line projekt (Trans-Adriatic Communications Line) u sklopu programa EU INTERREG III A, uspostava informacijskog sustava visokih učilišta na Sveučilištu u Zadru uspostava poslovne i informacijske infrastrukture Sveučilišta u Zadru te CARNet-ov projekt e-Škole: Uspostava sustava razvoja digitalno zrelih škola (pilot-projekt).

Sudjelovao je na više stručnih i znanstvenih konferencija, s radovima na temu e-obrazovanja, strateškog upravljanja IT i otvorenih istraživačkih podataka.

Author's Biography

Neven Pintarić was born in Varaždin. After finishing the High School of Electromechanical Engineering, he studied at the Faculty of Organization and Informatics in Varaždin, University of Zagreb, upon completion of which he obtained the master's degree. After that he finished additional pedagogical, psychological, didactic, and methodological education at the Faculty of Philosophy in Zadar. He passed the state exam for teaching in elementary and high school. At the Faculty of Electrical Engineering, Mechanical Engineering and Naval Architecture in Split, University of Split, he completed a course on the professional development in network technologies organized by the Cisco Networking Academy. He is currently employed at the University of Zadar

as Head of the Information Service. He is a member of the Association for Computing Machinery (ACM).

During his career, he has collaborated on a series of IT projects in the field of business informatics, education and scientific-research infrastructure, including the following projects: TAC-Line Project (Trans-Adriatic Communications Line) within the programme EU INTERREG III A, establishing the information system of higher education at the University of Zadar, establishing the business and information infrastructure of the University of Zadar and the CARNet project e-Schools: Establishing a System for Developing Digitally Mature Schools (pilot project).

He has participated in several professional and scientific conferences with papers on e-education, strategic management of IT and open research data.