

Plan upravljanja istraživačkim podacima - EvoSat

Mravinac, Brankica

Data management plan / Plan upravljanja istraživačkim podacima

Publication year / Godina izdavanja: **2024**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:241:911371>

Rights / Prava: [In copyright/Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-09-27**



Repository / Repozitorij:

[Fulir DATA - Ruđer Bošković Institute Research Data Repository](#)



DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJ

Plan upravljanja istraživačkim podacima

Opće informacije	
Ime i prezime predlagatelja	Dr. sc. Brankica Mravinac
Matična organizacija	Institut Ruđer Bošković
Naziv projekta	Rasvjetljavanje evolucije satelitnih DNA visokoprotočnim analizama satelitoma srodnih vrsta
Upravitelj podacima	Brankica Mravinac, Brankica.Mravinac@irb.hr , voditeljica projekta
1. Prikupljanje podataka i dokumentacija	
Koje ćete podatke prikupljati, obrađivati, stvarati ili se ponovno njima koristiti? (navedite format, vrstu i opseg podataka)	<p>Projekt se zasniva na analizi satelitoma invertebratnih organizama, a istraživanja se provode na dva neovisna modelna sustava – vrstama kukaca iz roda <i>Tribolium</i> te vrstama školjkaša iz porodice Ostreidae. Tijekom projekta generirat ćemo i obrađivati dva različita tipa sirovih podataka, koji se odnose na oba modelna sustava:</p> <ol style="list-style-type: none"> 1. rezultate sekvenciranja DNA metodama nove generacije (Illumina i PacBio) kao i rezultate sekvenciranja Sanger metodom 2. slike metafaznih kromosoma izučavanih vrsta dobivenih konfokalnom mikroskopijom. <p>Za 1. kategoriju sirovi rezultati sekvenciranja bit će isporučeni u digitalnoj formi od strane centara u kojima će se vršiti usluga sekvenciranja i to u sljedećim formatima: rezultati Sanger sekvenciranja u fasta formatu, rezultati Illumina sekvenciranja u fastq formatu te rezultati PacBio sekvenciranja u BAM formatu. Procjenjujemo da ćemo za 1. kategoriju kumulativno generirati otprilike 8-9 TB podataka (500 MB podataka Sanger sekvenciranja, 20 GB podataka Illumina sekvenciranja te 8 TB podataka dobivenih PacBio sekvenciranjem).</p> <p>Za 2. kategoriju sirovi rezultati konfokalnih slika dobit će se i pohraniti u digitalnom obliku u TIFF formatu. Procjenjujemo da ćemo za pohranu konfokalnih slika trebati 1 TB prostora.</p>
Kako će se podaci prikupljati, obrađivati ili stvarati? (ukratko navedite metodologiju i procese osiguranja kvalitete te načine organiziranja podataka)	<p>Rezultati sekvenciranja bit će organizirani na način da se pohranjuju u datoteke nazvane prema dogovorenim normama kako bi se nedvosmisleno mogao utvrditi naziv organizma kojem podaci pripadaju te vrsta i datum sekvenciranja kojim su podaci generirani. Skup podataka pratiće također i README dokumenti u kojima će se opisati hijerarhija direktorija, odnosno svi relevantni podaci za pojedini eksperiment koji je prethodio generiranju podataka. Daljnja analiza podataka primarno će se provoditi računalnim programima Geneious i RepeatExplorer. Program Geneious omogućava lokalnu pohranu generiranih rezultata (u različitim izlaznim formatima), dok se analize alatom RepeatExplorer odvijaju na serverskom poslužitelju Galaxy (https://repeatexplorer-elixir.cerit-sc.cz/) preko korisničkog računa. S obzirom na limitirani serverski prostor namijenjen pojedinom korisniku (200 GB), podaci dobiveni analizama „izvozit“ će se u lokalne direktorije osobnih računala pojedinih suradnika.</p> <p>Baze konfokalnih slika bit će hijerarhijski organizirane u datoteke poštujući sistematizaciju prema vrsti organizma->tipu analizirane satelitne DNA->datumu eksperimenta. Daljnje obrade slika radit će se u programima Adobe Photoshop, Inkscape i Gimp. Proizvedene obrade slike pohranjavat će se inicijalno lokalno na računalima suradnika na projektu.</p>

		Za sve eksperimente (izolacije DNA, odnosno fluorescencijske analize <i>in situ</i>), koji su prethodili krajnjem generiranju podataka, postojat će datirana zabilježba u laboratorijskim dnevnicima primarnih eksperimentatora s detaljnim opisom protokola prema kojem je eksperiment proveden te uz jasno istaknuta eventualna odstupanja od standardnog protokola, ako je do njih došlo.
	Koju ćete dokumentaciju i metapodatke ustupiti osim podataka? (navedite koje su informacije potrebne korisnicima kako bi mogli čitati i interpretirati podatke u budućnosti te koji će se standardi koristiti pri tumačenju podataka)	Svi podaci bit će popraćeni dokumentacijom u vidu README dokumenta s objašnjenjima i detaljnim navođenjem imena vrste kojoj rezultati pripadaju, broja i razvojnog stadija analiziranih jedinki, metode sekvenciranja i imena platforme na kojoj su inicijalni rezultati/očitanja (eng. <i>reads</i>) generirani. Procesirani podaci dobiveni daljnjim analizama bit će popraćeni README dokumentima s detaljnim objašnjenjima analiza, kao i specifikacijom parametara pod kojima su analize provedene. Prilikom objave radova za koje će biti potrebne kompleksnije, razvijene kodne knjige, iste će biti dostupne u skopu Github online alata koji omogućava i verzioniranje. Sirovi podaci koje budemo pohranjivali u javno dostupnim bazama podataka (primjerice, NCBI, ENA...) bit će pojašnjeni priloženim protokolima/kodnim knjigama dovoljnim za interpretaciju istih. Nadalje, skupovi podataka će u repozitorijima biti opisani metapodacima (detaljan opis svakog uzorka/stadija/tkiva/tipa sekvenciranja) i trajnim identifikatorima te će se na taj način omogućiti pretraživanje u databazama. U slučaju novo posloženih genoma ili opisanih sekvenci, iste će biti pripremljene kao dodatak radu u časopis na način na budu pohranjeni u repozitoriju. Za procesirane konfokalne slike bit će osigurana pojašnjenja priložena u vidu komentara, kojima će se specificirati eventualno poduzete intervencije u procesu analize slika, kao i njihovog procesiranja do publikabilne razine.
2.	Pravna i sigurnosna pitanja	
	Jeste li ograničeni sporazumom o povjerljivosti? Imate li potrebna dopuštenja za prikupljanje, obradu, čuvanje i dijeljenje podataka? Jesu li osobe čiji se podaci pohranjuju informirani o tome i jesu li dali privolu? Kojim ćete se metodama koristiti u svrhu zaštite osjetljivih podataka (GDPR - posebne kategorije osobnih podataka)?	Pri izvedbi ovog projekta neće se kršiti etička načela. Također nismo ograničeni sporazumom o povjerljivosti.
	Kako će se regulirati pristup podacima i njihova sigurnost? Koji su potencijalni rizici koje treba uzeti u obzir? Kako ćete osigurati sigurnost pohrane osjetljivih podataka?	Pristup podacima koji su se koristili kako bi se dobili publikabilni rezultati bit će omogućeni po objavi rada u jednom u repozitorija ili na zahtjev s obzirom na veliku količinu podataka koja onemogućuje jednostavno dijeljenje preko mrežnih infrastruktura. Trajna pohrana velikih setova bit će izvršena na lokalnoj pohrani u najmanje dvije kopije kako bi se osigurala sigurna pohrana podataka i spriječio njihov eventualni gubitak.

	Kako ćete upravljati zaštitom autorskih prava i intelektualnog vlasništva? Tko će biti vlasnik podataka? Koje će se licencije primjenjivati na podatke? Koja će se ograničenja primjenjivati na ponovnu uporabu osobnih podataka?	Sve podatke dobivene u sklopu istraživanja bit će licencirane licencom CC BY 4.0 po preporuci Europske komisije kako bi omogućili ponovno i ispravno korištenje podataka od strane drugih znanstvenika. Vlasnik podataka je Institut Ruđer Bošković, u kojem se realizira projekt i produciraju rezultati. S obzirom da nema osobnih i povjerljivih podataka osim intelektualnih dostignuća, nikakva ograničenja neće biti primjenjiva na podatke.
3.	Pohrana i čuvanje podataka	
	Kako će podaci biti pohranjeni i kako će biti napravljena sigurnosna kopija podataka (<i>backup</i>) tijekom istraživanja? Koji su kapaciteti čuvanja podataka kojim raspolažete? Kojim se procedurama koristite za sigurnosnu kopiju (<i>backup</i>)?	Većina podataka čuvat će se kroz nekoliko razina/pohrana: 1) sirovi i procesirani podaci čuvat će se na lokalnim računalima sudsionika projekta; 2) uz pohranu na lokalnim diskovima, s obzirom na veliku količinu prikupljenih podataka (>8 TB), kupljeni su dodatni vanjski tvrdi diskovi. Četiri diska od 5 TB služe za dodatnu sigurnosnu pohranu radnih podataka u tijeku analiza (dva za modul kukaca, dva za modul školjkaša). K tome, nabavljena su i dva diska velikog kapaciteta (8 TB) koja služe isključivo za pohranu sirovih podataka i finalnih procesiranih podataka – jedan je namijenjen za podatke vezane uz modul kukaca, a drugi uz modul školjkaša – za redovitu sigurnosnu pohranu podataka modula školjkaša odgovorna je Brankica Mravinac, dok je za redovitu sigurnosnu pohranu podataka modula školjkaša odgovorna Eva Šatović Vukšić; 3) po potrebi, podaci od interesa izmjenjuju se između projektnih suradnika, a mogu se i pohranjivati na virtualnom poslužitelju MojOblak kojim raspolaže Institut Ruđer Bošković; 4) finalno, po objavi rezultata podaci će biti deponirani u depozitorijima javnih baza kao što su to NCBI, ENA, i FigShare.
	Koji je vaš plan čuvanja podataka? U kojim će se formatima čuvati?	Sigurnosne kopije podataka čuvat će se u komprimiranoj formi na vanjskim jedinicama za pohranu na neodređeni vremenski period, zajedno s metapodacima i kodnim knjigama kako bi ponovno korištenje podataka bilo moguće u bilo kojoj vremenskoj točci.
4.	Dijeljenje i ponovna uporaba podataka	
	Kako i gdje će se podaci dijeliti? Na kojem repozitoriju planirate dijeliti podatke? Kako će potencijalni korisnici doznati za podatke?	Za ovaj projekt najprikladnije mjesto pohrane i dijeljenja sa znanstvenom zajednicom jesu javni repozitoriji National Center for Biotechnology Information (NCBI), European Nucleotide Archive (ENA) i FigShare, a korisnici će o postojanju tih podataka biti informirani u sklopu objavljenih publikacija. Također, temeljni i sirovi podaci bit će ustupljeni svim znanstvenicima koji traže dopuštenje korištenja, osobno ili na zahtjev preko za to osiguranih protokola za dijeljenje podataka (direktni FTP/SFTP transfer, ili putem programa za prijenos poput WinSCP ili FileZilla).
	Ako postoje podaci koji se ne smiju dijeliti (prijavači vezani zakonskim, etičkim, autorskim pravila, povjerljivošću i sl.), pojasnite razloge ograničenja.	Podaci neophodni za bilo koju publikaciju bit će dostupni u trenutku objavljivanja. Svi neobjavljeni podaci pohranit će se u repozitoriju na 24 mjeseca od završetka projekta.

	Potvrdite da ćete se koristiti digitalnim repozitorijem koji je u skladu s načelima FAIR-a.	Digitalni repozitorij koji će biti korišten prati sva 4 FAIR načela, Findable - dostupan na internetu poveznicama s objavljenih publikacija, Accessible - moguće je pristupiti uz stabilnu internetsku vezu, Interoperable - podaci se preuzimaju u standardnim formatima za pohranu podataka poput .zip, Reusable - svi metapodaci bit će objavljeni zajedno s glavnim dijelom podataka.
	Potvrdite da ćete se koristiti digitalnim repozitorijem koji održava neprofitna organizacija (ako ne, objasnite zašto ne možete dijeliti podatke na digitalnom repozitoriju koji nije komercijalan).	Potpisujući. Potvrđujemo.

Ref:

- [1] Celjak, D., Dorotić Malič, I., Matijević, M., Poljak, Lj., Posavec K. i Turk, I.: „Istraživački podaci - što s njima?” [Istraživački podaci - što s njima? : priručnik o upravljanju istraživačkim podacima | Digitalni repozitorij Srca \(unizg.hr\)](#)