ISPORUČEVINA D.T1.2.1

IZVJEŠĆE O PROHODNOSTI I PREKOGRANIČNOJ POVEZANOSTI STANIŠTA ZA VELIKE ZVIJERI U PREKOGRANIČNOM PODRUČJU HRVATSKE I SLOVENIJE

Ovo izvješće sastavljeno je u okviru projekta „Prekogranična suradnja i usluge ekosustava u dugoročnom očuvanju populacija velikih zvijeri u sjevernim Dinaridima - Carnivora Dinarica“ u radnom paketu T1 „Zajednički pristupi i znanja za prekogranično upravljanje velikih zvijeri“ pod aktivnosti T1.2 „Istraživanje prekogranične povezanosti“. Projekt Carnivora Dinarica sufinanciran je od Europske unije kroz Europski fond za regionalni razvoj kroz program suradnje V–A Interreg Slovenija – Hrvatska.

Autori izvješća: Žan Kuralt, Jaka Črtalič, Hubert Potočnik, Josip Kusak, Đuro Huber, Ana Kolarić, Natarsha Babic, Slaven Reljić

SADRŽAJ IZVJEŠĆA 3

METODE 4

Prelazak granice 4

Veličina teritorija 4

Model prikladnosti staništa i povezanost 4

Model prikladnosti prostora 4

Analiza prostorne povezanosti 7

REZULTATI S RASPRAVOM 8

Telemetrijski praćene životinje u sklopu projekta Carnivora Dinarica 8

Karta teritorija opremljenih životinja u sklopu projekta Carnivora Dinarica 9

Prelazak granice 10

Analiza povezanosti prostora 14

Analiza korištenja habitatnih tipova 15

Analiza propusnosti pograničnog područja pomoću fotozamki 16

ZAKLJUČCI I PREPORUKE NA TEMELJU PROSTORNOG PONAŠANJA PROMATRANIH PRIMJERAKA VELIKIH ZVIJERI **20**

IZVORI 23

SADRŽAJ IZVJEŠĆA

Izvješće o prohodnosti i prekograničnoj povezanosti staništa velikih zvijeri zajednički je dokument s rezultatima telemetrijskog istraživanja prohodnosti granice za velike zvijeri (posebno risa i vuka) i s konkretnim preporukama za očuvanje najvažnijih prekograničnih zelenih koridora, a što uključuje utvrđivanje:

- prostornih potreba velikih zvijeri;
- konkretnih kritičnih dijelova granice;
- preporuka za provedbu mjera ublažavanja.

Temelj izvješća je opsežno prekogranično terensko istraživanje koje uključuje obilježavanje i praćenje velikih zvijeri GPS/GSM telemetrijskom metodom. Istraživanje je dalo važan uvid u ekologiju kretanja velikih zvijeri, korištenja tipova staništa, veličine životnih prostora mužjaka i ženki, dnevni i sezonski ritam kretanja, također i korištenje prirodnih koridora između različitih područja. Na taj način smo najbolje ispitali povezanost populacija velikih zvijeri između Hrvatske i Slovenije te istražili propusnost graničnog područja za velike zvijeri.

Povezanost staništa ključna je za zaštitu velikih zvijeri, kako zbog demografske povezanosti populacije, tako i za genetski protok i potencijalnu metapopulacijsku dinamiku. Istraživanja su pokazala da je npr. populacija risa u obje države već ugrožena zbog križanja srodnika. Ključni faktor koji smanjuje povezanost staništa su razvoj infrastrukture i urbanizacija prostora. Istraživanja povezanosti se obično provode na razini pojedinih država i državne granice se često tretiraju kao "kraj svijeta". Posljedično, izvještaji za integraciju infrastrukture na pograničnom području imaju nedostatke. Ujedno, primijećeno je sve više različitih intervencija u pogranični prirodni prostor, bilo zbog turizma ili postavljanja pomoćnih sredstava za graničnu kontrolu. Svaka daljnja fragmentacija prostora pogoršava stanje populacije. Istraživanje je tako pomoglo u poboljšanju znanja o kvaliteti i povezanosti pograničnih područja za vukove, risove i medvjede.

METODE

Prelazak granice

Za utvrđivanje broja prelazaka granice telemetrijski obilježenih životinja, između uzastopno dobivenih lokacija od pojedinih životinja napravili smo linije i prebrojali križanja tih linija s državnom granicom između Slovenije i Hrvatske. U svrhu analize utjecaja ograde na granici na velike zvijeri, na terenu smo popisali i označili linijske transekte na mjestima gdje je postavljena ograda na granici. Uz pomoć prebrojanih križanja linija kretanja promatranih jedinki i linijskih transekata na kojima je postavljena ograda na granici, dobili smo broj potencijalnih prijelaza dijela granice na kojima je ograda postavljena i usporedili taj broj s prijelazima granice gdje nema ograde. Usporedili smo i obrazac prijelaza granice prije i poslije 2015. godine, godine krajem koje su u graničnom području podignute ograde. Treba napomenuti da su telemetrijski praćene životinje u tim dvjema periodima bile različite jedinke.

Veličina teritorija

Veličine teritorija izračunate su pomoću procjenitelja minimalnog konveksnog poligona (MCP). Koristili smo 100% MCP, što znači da je procjenitelj koristio sve lokacije pojedinih uzoraka za izračunavanje veličine.

Model prikladnosti staništa i povezanost

Analizu prostorne povezanosti izveli smo u nekoliko koraka. Prvo smo razvili model prikladnosti staništa (engl. Habitat Suitability Model - HSM) za sve tri vrste velikih zvijeri. Kontinuirano predviđanje modela zatim je pretvoreno u binarno i tako su identificirane krpe staništa koje su korištene u daljnjoj analizi prostorne povezanosti. Cijela analiza provedena je u programskom okruženju R (R Core Team, 2021) i razvojnom okruženju RStudio (RStudio Team, 2021), a korištena skripta dostupna je na https://github.com/zkuralt/cardi-habitat-connectivity. Tamo su dostupni i grafički prikazi veće rezolucije.

Model prikladnosti prostora

Izradili smo model prostorne prikladnosti za cijelo područje Slovenije i Hrvatske. Za izradu modela koristili smo telemetrijske podatke s GPS/GSM ogrlica obilježenih životinja u okviru projekta Carnivora Dinarica, kao i podatke iz srodnih međunarodnih projekata (DinaRis, Life Slowolf, Life DinAlpBear, Life Lynx, 3Lynx) te manjih projekata za sve 3 velike zvijeri na nacionalnoj razini. Za najbolju moguću prostornu pokrivenost zabilježenih lokacija prisutnosti, u skup podataka osim telemetrije dodali smo i podatke o lokacijama prikupljenih neinvazivnih genetskih uzoraka. Tu se ubrajaju izmeti medvjeda prikupljeni pri akciji procjene brojnosti medvjeda u Hrvatskoj i Sloveniji u okviru LIFE DINALP BEAR projekta, te uzorci dlake i sline risova i vukova prikupljenih u gore navedenim međunarodnim i domaćim projektima. Prije nego što smo nastavili modeliranje, izvršili smo čišćenje skupa podataka, gdje smo prvo uklonili podatke s nedostajućim kao i one duple, s istim koordinatama. Zatim smo upotrijebili pristup prostornog prorjeđivanja (eng. spatial thinning) s paketom "spThin" (Aiello-Lammens i sur., 2015.), gdje smo zadržali položaje međusobno udaljene najmanje 1 km. Prorijeđeni model risa tako je uključivao 1562 položaja, model vuka 2322 položaja a model medvjeda temeljen je na 4874 položaja.

Osim podataka o prisutnosti životinja, u model smo uključili i skup varijabli okoliša (slika 1), koje se grubo mogu podijeliti u dvije grupe. Prva grupa varijabli odnosi se na konfiguraciju terena i obuhvaća digitalni model uzvišenja (eng. digital elevation model - DEM) rezolucije 25 m, na temelju kojeg smo izračunali preostale varijable iz ove grupe s funkcijom „terrain“ iz paketa „raster“ (Hijmans, 2017). To su ekspozicija (eng. aspect), nagib (eng. slope), indeks topografskog položaja (eng. Topographic

Position Indeks – TPI, razlika između vrijednosti kvadranta i prosječne vrijednosti susjednih osam kvadranata), indeks grubosti terena (eng. Terrain Ruggedness Index – TRI, prosjek apsolutnih razlika između vrijednosti kvadranta i vrijednost susjednih osam kvadranata), neravnosti terena (eng. Roughness, razlika između najveće i najniže vrijednosti kvadranta i susjednih osam kvadranata), smjer protoka vode (flowdir) i smjer najvećeg pada terena. Druga grupa varijabli okoliša odnosi se na prirodne površine i antropogene strukture u prostoru - korištenje zemljišta (Copernicus Land Monitoring Service, 2018.) i to su udaljenost od šume, udaljenost od naselja, udaljenost od glavnih cesta i udaljenost od željeznice. Razlučivost varijabli združena je u kvadrante od 500 x 500 metara radi bržeg izračunavanja.

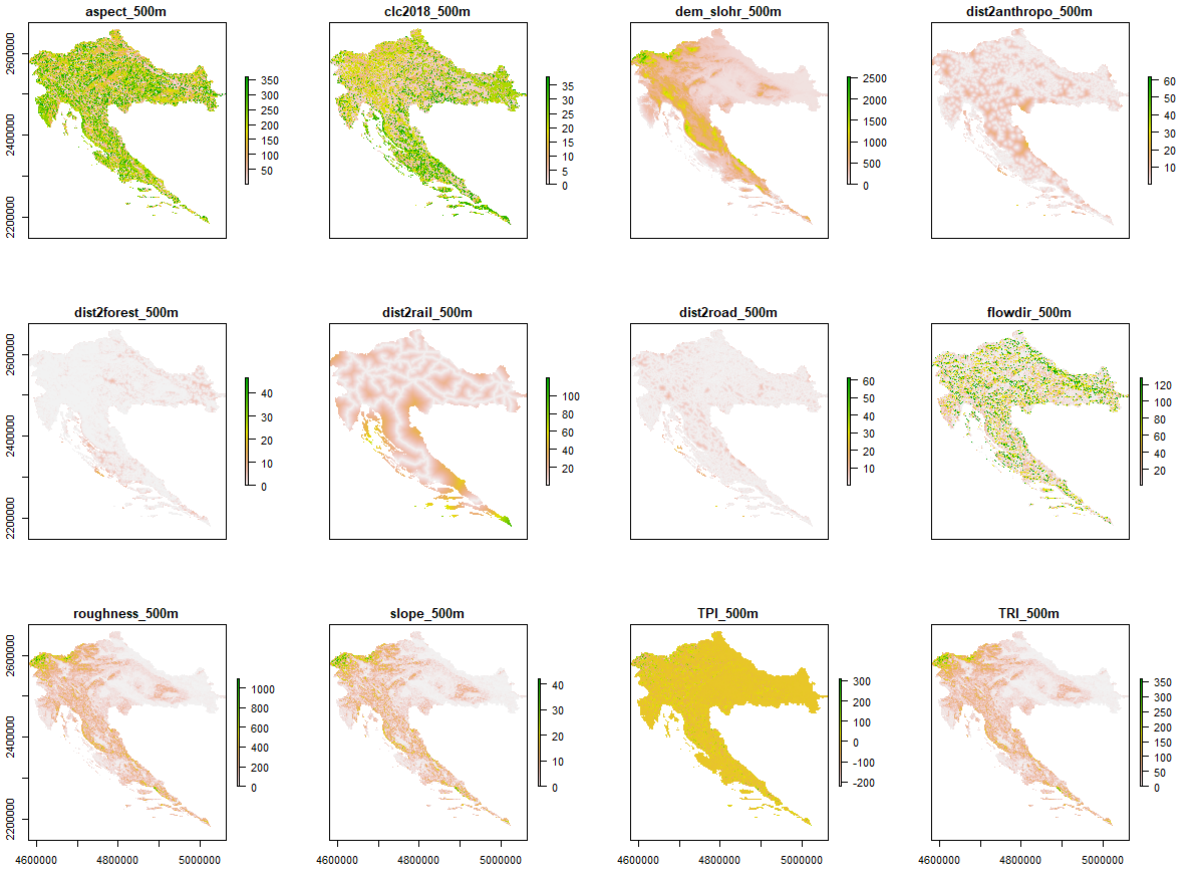

Slika 1: Varijable okoliša.

Potencijalna multikolinearnost varijabli okoliša provjerena je izračunavanjem koeficijenta korelacije (slika 2) i korištenjem HH paketa (Heiberger, 2020.) za izračun VIF-a (faktor inflacije varijacije) i uklanjanje jako koreliranih varijabli, onih s VIF vrijednošću >4 (tablica 1).

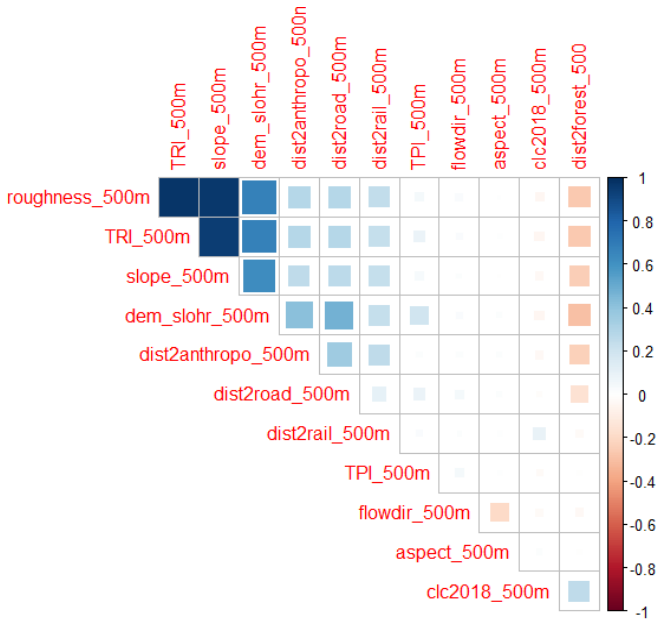

Slika 2 Korelacija između varijabli. Snažno povezane varijable naknadno su uklonjene iz analize.

Tablica 1 Rezultati VIF analize. Vrijednosti u stupcu VIF_1 dobivaju se pomoću svih varijabli. U slučaju VIF_2, varijable s VIF >4 su isključene. VIF vrijednosti svih preostalih varijabli bile su prihvatljive i uključene su u daljnju analizu.

variable	VIF_1	VIF_2
aspect	1.044230	1.043132
clc2018	1.081313	1.081161
dem	2.494538	1.579564
dist2anthropo	1.325092	1.323493
dist2forest	1.203903	1.189545
dist2rail	1.127148	1.110206
dist2road	1.355420	1.350979
flowdir	1.054521	1.047598
roughness	37.465106	/
slope	17.270063	/
TPI	1.093915	1.047786
TRI	20.757907	/

S paketom ENMeval (Kass i sur., 2021.) i maxnet algoritmom (Phillips i sur., 2017.) stvorili smo 27 modela s različitim postavkama za klasu značajki (FC), množitelj regularizacije (RM) i „blok“ distribuciju podataka. Konačni model odabran je na temelju vrijednosti dAICc i napravljeno je binarno predviđanje.

Analiza prostorne povezanosti

Stanišne krpe nastale pretvorbom u binarno predviđanje prvo su filtrirane, čime su uklonjene krpe površine manje od 50 ha. Analiza je nastavljena stvaranjem sloja troška/otpora koji se koristi za izračun putanje najnižeg troška (LCP) između pojedinih krpica. Da bismo to učinili, koristili smo inverzni prethodno razvijeni model prostorne prikladnosti (raspon vrijednosti od 0 do 1), gdje su vrijednosti stanica pomnožene s 10 i na kvadrat kako bismo dobili raspon vrijednosti od 0 do 100. Stanicama na području državne granice između Slovenije i Hrvatske, u kojima postoje tehničke barijere (ograda od panela, žilet žica) utvrdili smo trošak od 1000 jedinica, jer one predstavljaju praktički nepremostivu prepreku za velike zvijeri. Konačni raspon vrijednosti sloja troškova bio je tako između 0 i 1000 jedinica troškova (slika 3). Koristeći MPG (Minimum Planar Graph) metodu, koja je implementirana u paketu „grainscape“ (Chubaty i sur., 2020.), izgradili smo sloj zakrpa staništa i potencijalnih veza među njima na temelju LCP algoritma.

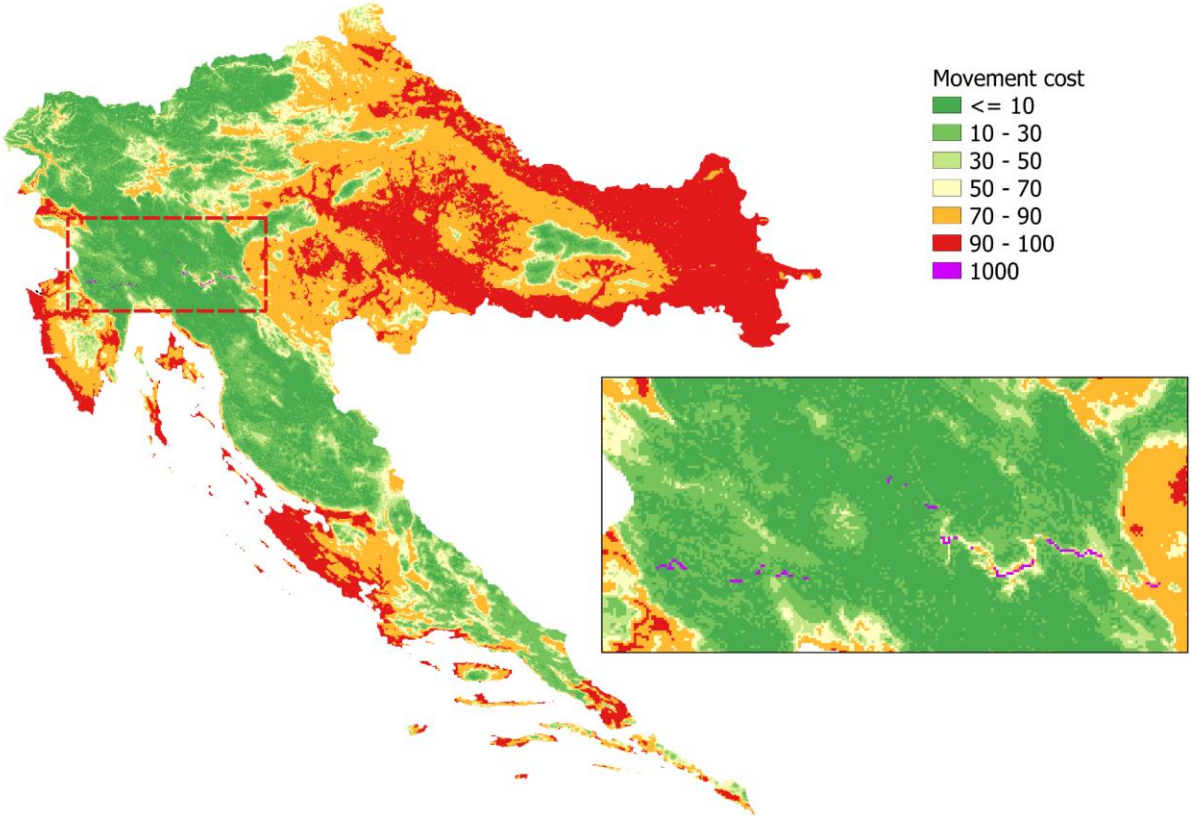

Slika 3 Primjer troškovnog sloja za analizu povezanosti prostora. Zelene nijanse predstavljaju lakši teren za velike zvijeri, dok crvene nijanse otežavaju prelazak terena. Ljubičasta boja predstavlja stanice na slovensko-hrvatskoj granici u kojima postoje tehničke prepreke.

REZULTATI S RASPRAVOM

Telemetrijski praćene životinje u sklopu projekta Carnivora Dinarica

Tablica 2 Pregled telemetrijski praćenih podataka o životinjama

Name	Species	N (fixes)	Home Range (ha)	Track Distance (km)	firstFix	lastFix	Days Monitored
Ana	bear	12394	8203	2558	05/06/2019	17/07/2021	773
Andreja	lynx	110	2198	58	06/03/2019	02/04/2019	28
Anton	wolf	223	24184	218	04/09/2020	11/10/2020	145
Jože	wolf	264	18	164	02/09/2019	16/10/2019	38
Frida	bear	24765	9529	3212	13/06/2019	20/07/2021	768
Lara	lynx	429	11757	266	23/04/2021	05/07/2021	73
Marija	bear	2471	5185	563	03/04/2021	20/07/2021	108
Kornelija	bear	72	7	2	15/07/2019	15/07/2019	1
Franci	bear	3786	1996	69	25/11/2019	30/04/2020	156
Rista	lynx	1192	37181	1332	25/09/2019	06/05/2020	224
Snježana	lynx	5	0	0	26/11/2019	26/11/2019	1
Vita	wolf	760	12574	924	22/05/2020	23/09/2020	123
Herman	Wolf	128	11	96	02/08/2020	18/08/2020	16

U sklopu projekta opremljeno je i telemetrijski praćeno 13 životinja, od čega 5 medvjeda, 4 risa i 4 vuka. Nažalost, svi risovi su se srušili (serijska greška), vuk Herman je nakon 16 dana uspio skinuti ogrlicu, vukovi Jože i Vita su ilegalno odstrijeljeni, a ogrlice su skinuli i medvjed Kornelija i medvjed Franci, pa smo od ovih životinja dobili manje podataka nego što smo očekivali. Zbog nedovoljne količine podataka o vuku Jože i Hermanu, medvjedu Korneliji i risu Snježani, ove nismo uključili u analizu.

Karta teritorija opremljenih životinja u sklopu projekta Carnivora Dinarica

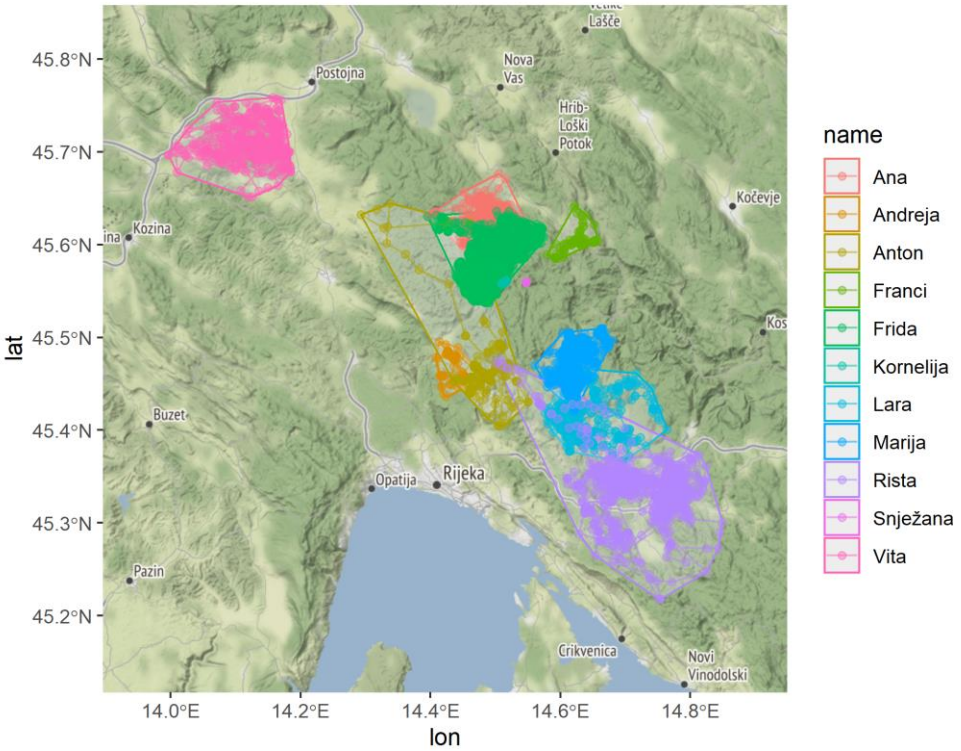

Slika 4 *Karta teritorija telemetrijski praćenih životinja*

Teritorij vukice Vite, koja pripada čoporu Vremščica, nalazila se između Pivke i Senožeča. Procijenjena veličina teritorija je 125 km^2. Pratili smo vukico do 24. rujna 2020. kada je bila ilegalno odstrijeljena. Uz pomoć lokacija vukice uzorkovali smo i mladunce čopora 2020. Genetske analize su pokazale da je vukica Vita sestra reproduktivne vukice. Vuk Anton je opremljen na teritoriju čopora Gomanci/Gorski Kotar na granici Slovenije i Hrvatske na području Snežnika. Nakon zarobljavanja nastavio se kretati zajedno s izvornim čoporom 38 dana, ali je 12. listopada 2020. otišao u disperziju, zato smo za procjenu velikosti teritorija koristili lokacije u razdoblju prije disperzije. Veličina teritorija iznosila je 241 km2. Zbog nedovoljne količine podataka nismo radili izračune za vuka Jožu i Hermana. Kao što je već spomenuto, medvjed Franci i medvjedica Kornelija skinuli su ogrlice, i zato, zbog premalo lokacija ne možemo ispravno procijeniti veličinu njihovog teritorija. Veličina teritorija medvjedice Ane je 8,2 km2, veličina medvjedice Fride 9,5 km2 i medvjedice Marije 5,2 km2. Nažalost, zbog nedostatka podataka, risa se ne može koristiti za procjenu veličine teritorija.

Prelazak granice

Analiza je obuhvatila 364.841 položaj dobivenu telemetrijskim praćenjem 65 medvjeda, 20 vukova i 24 risa od 2007. godine nadalje. Od toga je 5 medvjeda, 2 vuka i 4 risa praćeno i uključeno u ovu analizu u sklopu projekta Carnivora Dinarica.

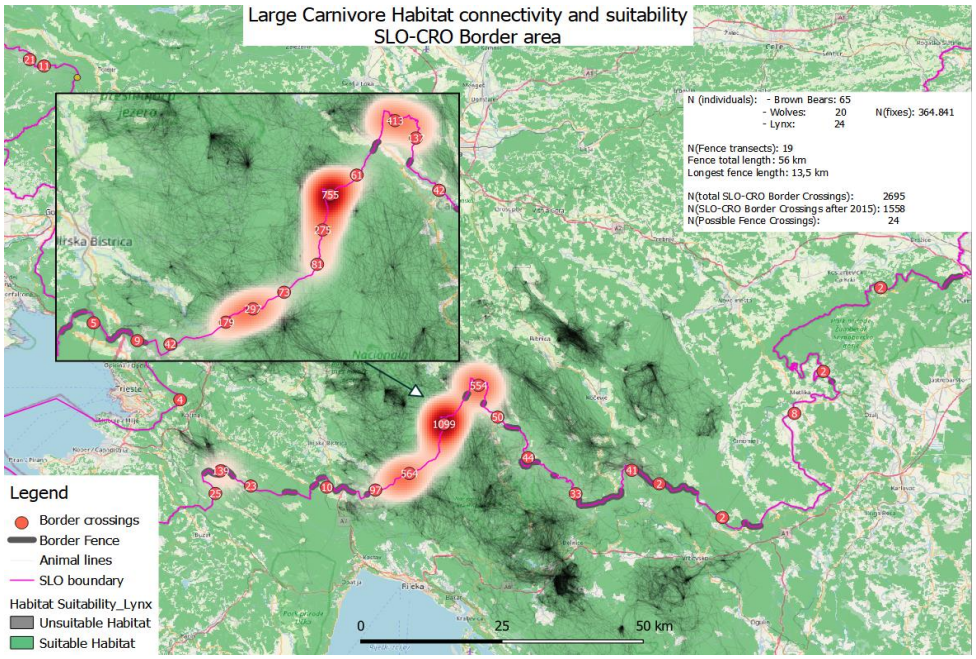

Slika 5 Potencijalni granični prijelazi velikih zvijeri opremljenih s GPS/GSM ogrlicom.

Na granici između Slovenije i Hrvatske zabilježeno je 19 presjeka s ogradom na granici u ukupnoj duljini od 56 km. Najduži transekt s graničnom ogradom ima 13,5 km. Otkrili smo ukupno 2695 prijelaza velikih zvijeri preko državne granice, od čega je 1558 prijelaza bilo nakon 2015. godine, kada su na granici podignute ograde. Nakon 2015. godine otkrili smo samo 24 potencijalna granična prijelaza u područjima s graničnom ogradom, što ukazuje da ograde predstavljaju relativno veliku prepreku.

Granični prijelazi bili su najviše koncentrirani na područjima gdje je najveća gustoća velikih zvijeri, na području Gorskog kotara i kompleksa Snežnik, na području Babnog polja i na području Slavnika.

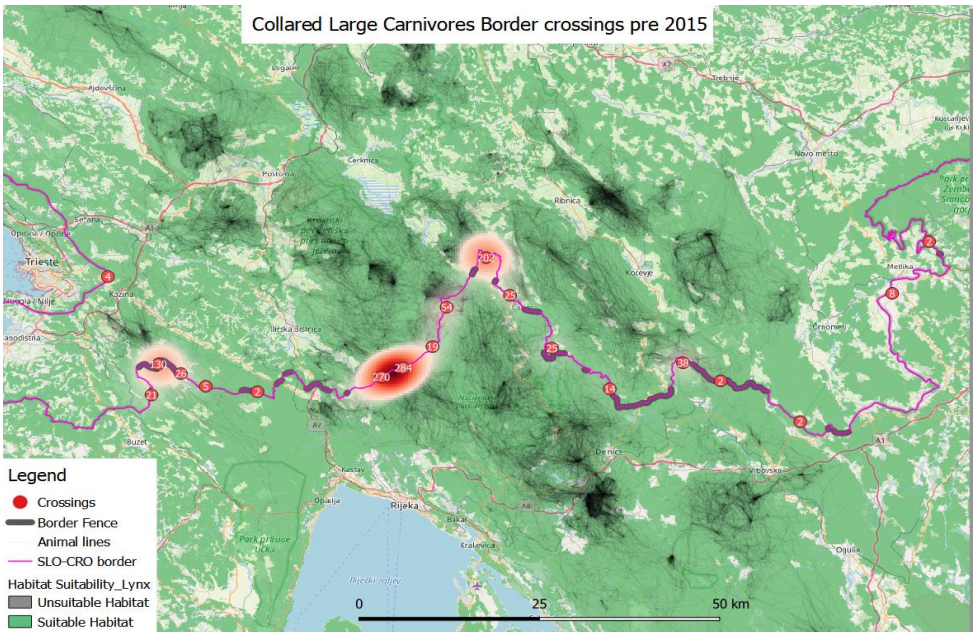

Slika 6 Potencijalni granični prijelazi velikih zvijeri opremljenih s GPS/GSM ogrlicom prije 2015. godine.

Od 2011. do 2013. na području Slavnika praćena su tri vuka. Do 2013. godine na ovom smo području zabilježili 139 prijelaza državne granice. Nakon 2015. podignuta je granična ograda upravo tamo gdje su granični prijelazi ovog čopora bili najviše koncentrirani. Nažalost, nakon podizanja ograde nemamo telemetrijske podatke o vukovima iz ovog područja, ali ipak procjenjujemo da podignuta ograda snažno utječe na obrazac kretanja vukova iz ovog čopora.

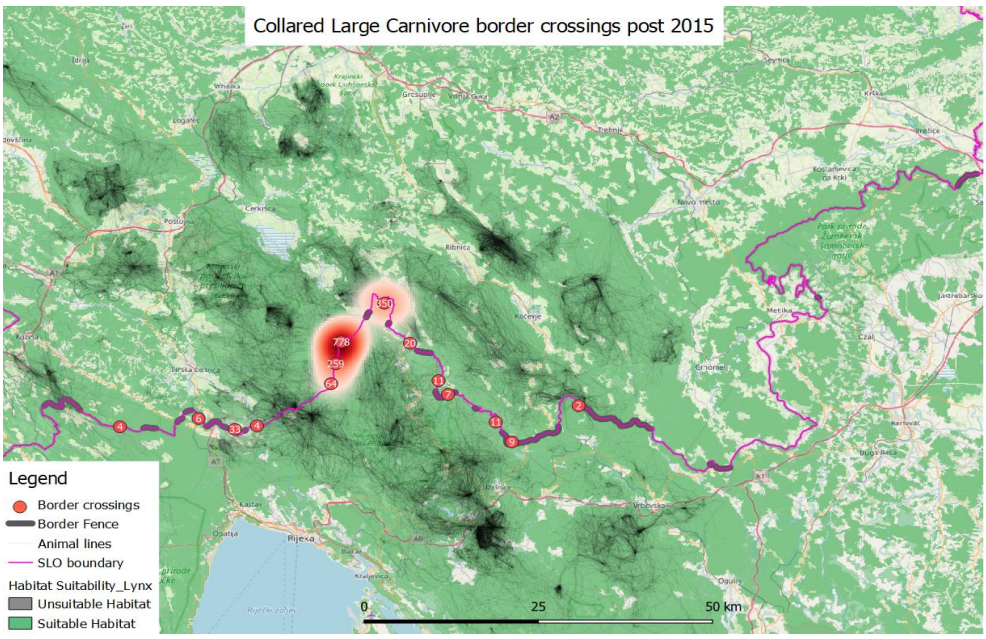

Slika 7 Potencijalni granični prijelazi velikih zvijeri opremljenih s GPS/GSM ogrlicom nakon 2015. godine.

I nakon 2015. najveća koncentracija kretanja telemetrijski praćenih životinja bila je na području kompleksa Snežnik i Gorskog kotara, pa je broj prijelaza državne granice ovdje najveći. Potencijalni granični prijelazi na područjima gdje je postavljena ograda otkriveni su na području Novokračina (10), Trava (2), Osilnice (2), Petrine (9), Laz pri Predgrada (1).

Model prikladnosti prostora

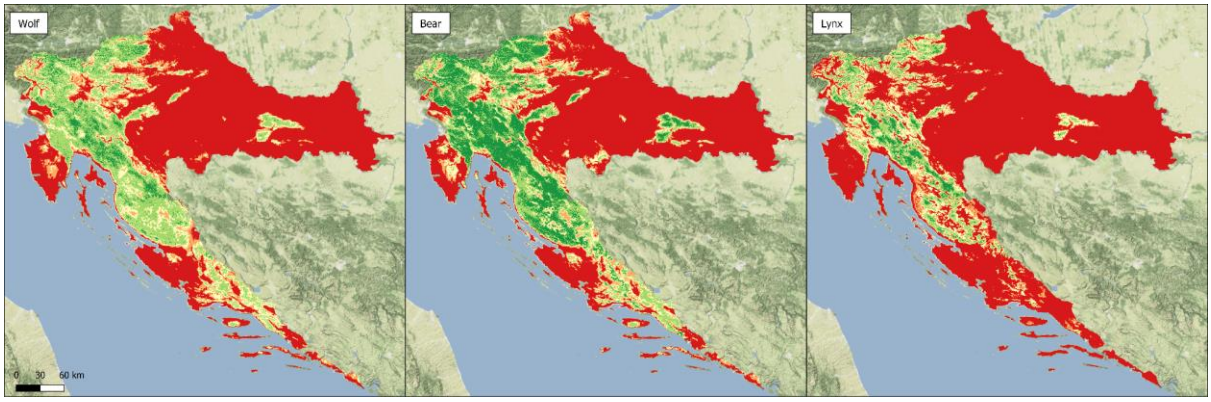

Slika 8 Model prikladnosti prostora za vuka, medvjeda i risa. Zelene nijanse označavaju povoljan prostor, dok crvene nijanse označavaju nepovoljan prostor. Tamnozelene površine mogle bi se protumačiti kao vrlo povoljne ili optimalno stanište.

Predviđanja modela prikladnosti staništa (slika 8) donekle su očekivana i u skladu su s prethodnim publikacijama (npr. Dobbert i sur., 2021 .; Rodriguez Recio i sur., 2018.; Skrbinšek i Krofel, 2008.). Najprikladnija područja su u Dinaridima i Alpama, gdje su već prisutne sve tri vrste velikih zvijeri. Istodobno, predviđanja modela ukazuju i na potencijalna područja koja bi uz odgovarajuću povezanost prostora i prihvaćanje lokalnog stanovništva mogla (ponovno) nastaniti velike zvijeri. U Sloveniji su to uglavnom veće šumske sastojine u sjeveroistočnom dijelu zemlje (npr. Pohorje i Posavsko hribovje).
Unatoč činjenici da modeli za sve tri vrste pokazuju sličnu sliku, također se mogu uočiti neke razlike. Među velikim zvijerima ris je zasigurno najspecifičniji u pogledu prostornih zahtjeva, što se odražava i u predviđanju modela. S druge strane, područja povoljnog prostora za vuka i medvjeda slična su, ali za vuka je manje kvalitetnih područja (tamnozeleno na slikama 8 i 9), koje vukovi biraju kad im se rode mladunci. U užem području istraživanja (slika 9) prevladava povoljno područje za velike zvijeri, koje je uglavnom povezano s gustim šumama koje pokrivaju više dijelove Dinarskih Alpa.

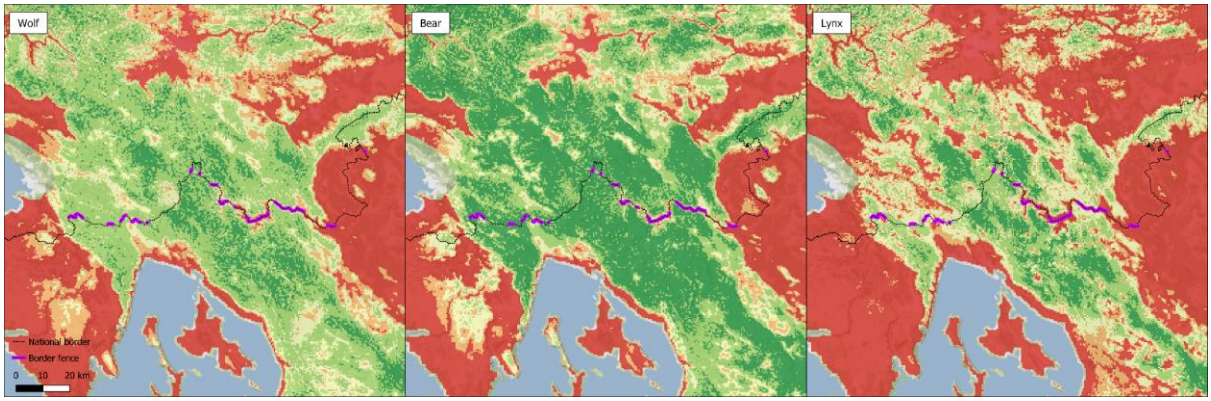

Slika 9 Model prostorne prikladnosti u užem području istraživanja. Isprekidana linija označava državnu granicu, a ružičasta crta označava tehničke prepreke na državnoj granici.

Analiza povezanosti prostora

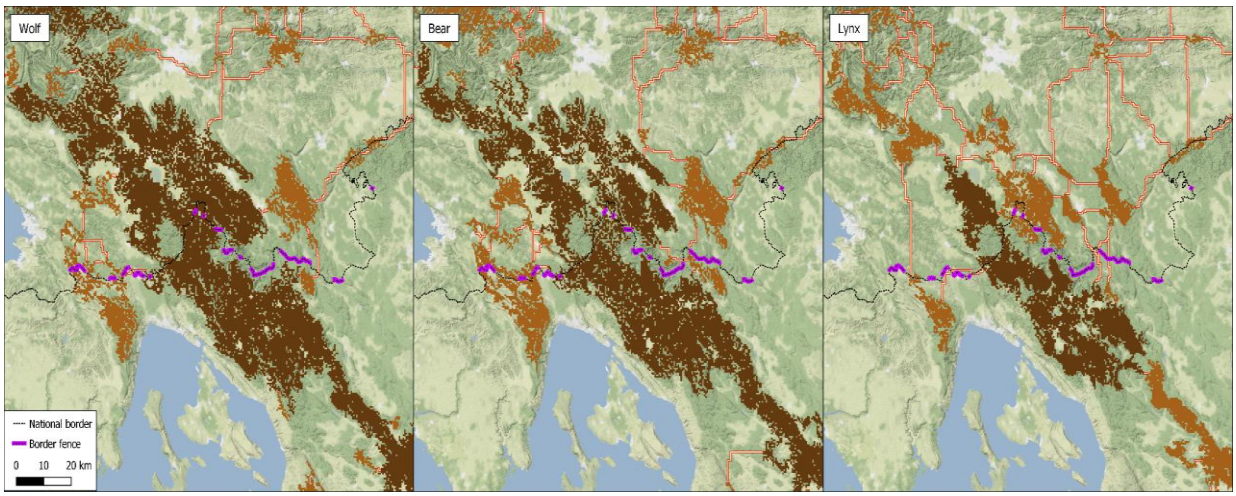

Slika 10 Stanišne krpe (smeđi poligoni) i najpovoljnije veze među njima (žute crte s crvenim obrubom). Najveća zbijena krpa označena je tamnosmeđom nijansom. Isprekidana linija označava državnu granicu, a ružičasta linija označava tehničke prepreke na državnoj granici (Izvor kartografije: Stamen Design, pod CC BY 3.0. Podaci OpenStreetMap -a, pod ODbL)

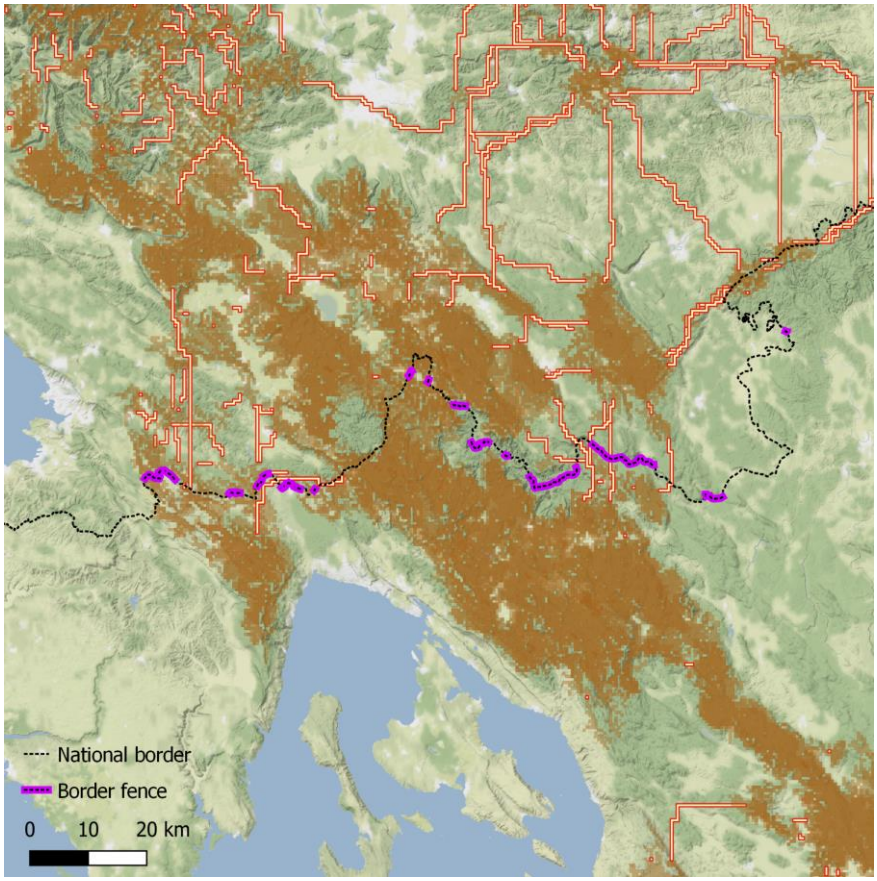

Slika 11 Kombinirani prikaz staništa za velike zvijeri i najpovoljnije veze među stanišnim krpama. Gustoće spojeva predstavljaju potencijalne koridore.

Analiza korištenja habitatnih tipova

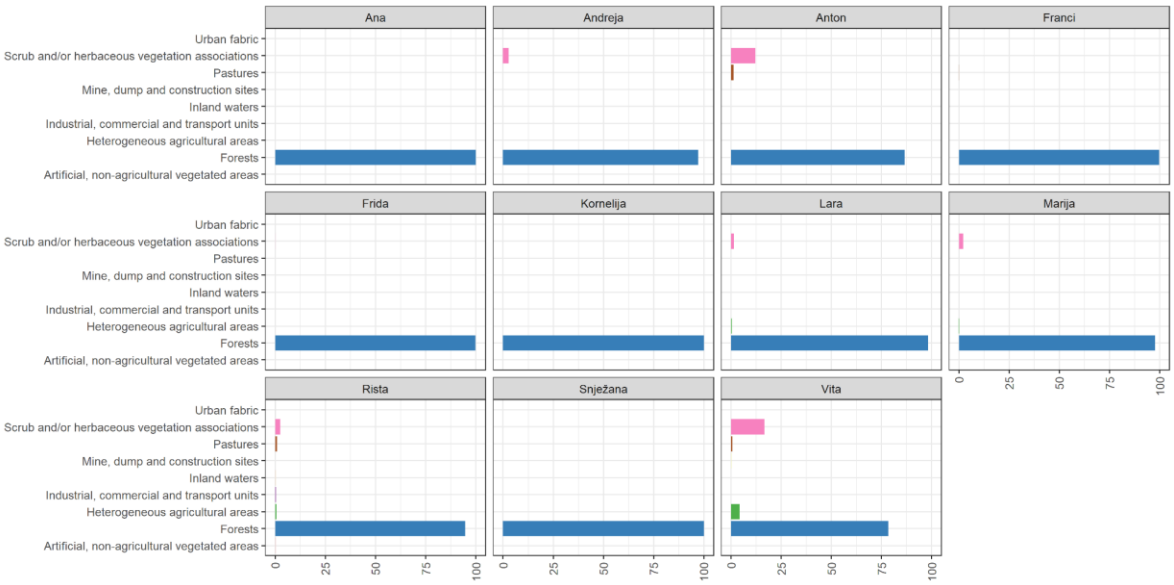

Slika 12 *Analiza korištenja habitatnih tipova telemetrijski praćenih primjeraka*

Praćeni pojedinci kretali su se većinu vremena u šumskim područjima. Ističu se samo rezultati analize korištenja habitatnih tipova od vukova koji su u odnosu na medvjeda i risa koristili nešto više površina obraslih nižim raslinjem ili obraslim šumama.

Tablica 3 Analiza korištenja habitatnih tipova telemetrijski praćenih primjeraka

Name	species	Forests	Scrub and/or herbaceous vegetation associations	Pastures	Heterogeneous agricultural areas	Artificial	non-agricultural vegetated areas	Industrial	commercial and transport units	Inland waters
Ana	bear	99.96	0.04							
Andreja	lynx	97.27	2.73							
Anton	wolf	86.55	12.11	1.35						
Franci	bear	99.87		0.13						
Frida	bear	99.82	0.18							
Kornelija	bear	100								
Lara	lynx	98.14	1.4		0.47					
Marija	bear	97.81	2.1		0.08					
Rista	lynx	94.71	2.52	0.92	0.67	0.25	0.5	0.17	0.25	

Analiza propusnosti pograničnog područja pomoću fotozamki

U okviru projekta Carnivora Dinarica u razdoblju od 29.06.2019. do 16.08.2021. godine na pograničnom području između Hrvatske i Slovenije ukupno je bila postavljena 31 fotozamka s ciljem istraživanja utjecaja ograde na granici na kretanje životinja, s naglaskom na velike zvijeri. Mjesta postavljanja svih 31 fotozamki prikazana su na karti (slika 12), a u tablici 2 su prikazane koordinate svih položaja te vrijeme aktivnosti svake pojedine i svih fotozamki ukupno. Svih 31 fotozamka bile su ukupno aktivne 6361 kamera dana.

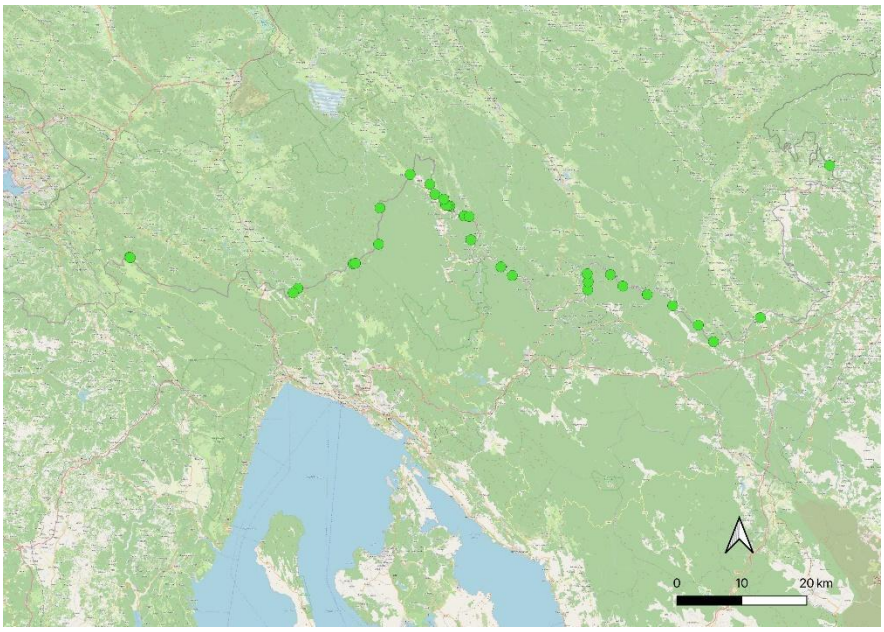

Slika 13 Kartirani položaji 31 fotozamke postavljene na granici između Hrvatske i Slovenije

Tablica 4 Imena položaja postavljenih fotozamki, njihove koordinate, datumi njihovog postavljanja i ukljanjanja te broj dana njihove aktivnosti

Br.	Položaj	X	Y	Postavljeno	Uklonjeno	Kamera dan
1	Prezid	45,64500	14,56027	29.6.2019	4.8.2021	768
2	Čabar north	45,60275	14,64005	19.11.2019	21.5.2020	185
3	Čabar north 2	45,60356	14,63583	22.2.2020	16.8.2021	542
4	Čabar north 3	45,60365	14,63214	29.2.2020	5.4.2020	37
5	Jelen Draga	45,54753	14,50128	17.7.2019	2.4.2021	602
6	Kovači	45,55661	14,68322	30.6.2019	7.10.2020	466
7	Čabranka 1	45,58939	14,66864	31.10.2019	9.2.2020	102
8	Čabranka 2	45,58887	14,67865	1.3.2020	15.3.2021	380
9	Novi Kot	45,63213	14,59963	26.7.2020	4.1.2021	162
10	Grohari	45,61813	14,61030	26.7.2020	16.4.2021	264
11	Gorači	45,61199	14,62772	29.2.2020	27.2.2021	365
12	Vivodina	45,66853	15,38850	13.11.2020	29.7.2021	258

13	Sela Bosiljevska	45,45670	15,25638	12.4.2020	17.5.2020	36
14	Gornji Ložac	45,52011	14,74364	18.10.2020	23.5.2021	217
15	Sedalce	45,50861	14,76635	18.10.2020	23.5.2021	217
16	Planica	45,49100	14,91532	18.10.2020	23.5.2021	217
17	Severin na Kupi	45,44489	15,13432	8.12.2020	14.2.2021	68
18	Hreljin	45,48600	15,03297	8.12.2020	22.5.2021	165
19	Doluš	45,50213	14,91609	19.12.2020	23.5.2021	155
20	Grgelj	45,51254	14,95969	19.12.2020	21.3.2021	92
21	Goršeti	45,49698	14,98434	19.12.2020	22.5.2021	154
22	Gorenji Radenci	45,47115	15,08347	19.12.2020	22.5.2021	154
23	Kot pri Damlju	45,42224	15,16494	14.2.2021	22.5.2021	97
24	Kostel	45,51309	14,91384	21.3.2021	23.5.2021	63
25	Prehod 1	45,51992	14,01131	14.1.2021	15.4.2021	91
26	Prehod 2	45,51929	14,01285	15.2.2021	15.4.2021	59
27	Gumance	45,48372	14,34448	16.12.2020	5.1.2021	20
28	Lisac	45,47727	14,33556	16.12.2020	5.1.2021	20
29	Babno polje	45,59769	14,50220	18.12.2020	15.1.2021	28
30	Katalin	45,51956	14,45227	8.3.2020	29.10.2020	236
31	Mala vrata	45,52029	14,45642	31.7.2020	18.12.2020	141
	TOTAL					6361

Tijekom razdoblja praćenja ukupno je zabilježeno 1898 događaja u kojima su snimljene različite životinjske vrste. Od različitih vrsta sisavaca (slika 13) snimljeni su: jelen (*Cervus elaphus*) 13,2%, srna (*Capreolus capreolus*) 38,1%, divlja svinja (*Sus scrofa*) 4,9%, kuna (*Martes* sp.) 2,5%, jazavac (*Meles meles*) 8,5%, lisica (*Vulpes vulpes*) 20,7%, vuk (Canis lupus) 1,4%, čagalj (*Canis aureus*) 0,1%, medvjed (*Ursus arctos*) 7,9%, divlja mačka (*Felis silvestris*) 1,1%, zec (*Lepus europaeus*) 1,5%, dabar (*Castor fiber*) 0,2%. Zanimljivo je istaknuti da je dvaput fotografirana i crna roda (*Ciconia nigra*, slika 15).

Slika 14 Udio pojedinih vrsta sisavaca zabilježenih uzduž hrvatsko-slovenske granice izražen u postocima

Slika 15 Fotografije crne rode zabilježene uzduž hrvatsko-slovenske granice na položajima Kovači i Čabranka 2

Od ukupno 31 fotozamke njih 7 je postavljeno da snima direktno ogradu na granici sa ciljem istraživanja ponašanja životinja s obzirom na utjecaj ograde kao prepreke njihovom kretanju. Zabilježen je dolazak medvjeda i zeca (slika 15) te srna, jelena, divljih svinja u neposrednu blizinu ograde, njihovo kraće ili duže zadržavanje uz ogradu (čak i do 26 min, slika 16 i slika 17), vraćanje u smjeru otkuda su došle (slika 18), zatim zaobilaženje ograde (slučaj i sa vukom, slika 19), ali nije zabilježeno da su te vrste životinja na bilo koji način uspjele prijeći ogradu.

Slika 16 Medvjed i zec zabilježeni neposredno uz ogradu na granici koja im je predstavljala prepreku

Slika 17 Zadržavanje srne u blizini ograde u trajanju od 26 minuta uz nemogućnost prolaza

Slika 18 Zadržavanje srna u blizini ograde uz nemogućnost prolaza

Slika 19 Vraćanje jelena iz smjera iz kojeg su došli zbog nemogućnosti prolaza

Slika 20 Zaobilaženje ograde od strane vuka na položaju Novi Kot

Na položaju Prezid zabilježeno je da su dvije od navedenih vrsta životinja, lisica i jazavac, uspjeli naći način da im ograda na granici ne predstavlja prepreku u njihovom kretanju i to kopanjem i prolaženjem ispod ograde (Slika 20). Zbog svoje veličine, nije isključeno da bi isti prolaz mogli koristiti divlja mačka i kuna, no to nismo uspjeli zabilježiti kamerama.

Slika 21 Prolazak jazavca i lisice ispod ograde na položaju Prezid

Zaključno možemo utvrditi da ograda na granici predstavlja prepreku u kretanju istraživanih životinjskih vrsta posebno ako je postavljena neprekidno na većoj duljini, kao što je slučaj uz rijeku Kupu na graničnom prijelazu Petrina i od Grgelja do Sodevaca gdje je ograda duža od 10 kilometara. Ograda je bila neprohodna za jelena, srnu, divlju svinju, vuka, medvjeda i zeca, dok za vrste jazavac, lisica, kuna i divlja mačka ne predstavlja prepreku s obzirom da je dokazano da prolaze ispod ograde kopanjem. Na pograničnom području svih 31 fotozamka nije zabilježila niti jednog risa. Također je važno napomenuti da na položajima gdje je praćena ograda na granici nije zabilježen niti jedan pokušaj prelaska migranata preko ograde ili prolazak pored ograde te se postavlja pitanje svrhe prisutnosti ograda na granici.

ZAKLJUČCI I PREPORUKE NA TEMELJU PROSTORNOG PONAŠANJA PROMATRANIH PRIMJERAKA VELIKIH ZVIJERI

Kao što se može zaključiti iz modelske prognoze, opseg staništa se neznatno razlikuje između proučavanih vrsta zbog razlika u biološkim karakteristikama prostornog ponašanja, ali one općenito pokazuju sličan oblik distribucije prikladnog habitata (Slika 10.). U slučaju svih velikih zvijeri, najveće stanište pokriva područje Javornika, Snežnika i Gorskog kotara. Središnje mrlje habitata vuka i medvjeda na jugu dopiru do Like, a na sjeveru do Trnovskog gozda, za vuka čak preko Polhograjskog i Škofjeločkog brda u alpsko područje. Preostale manje stanišne mrlje relativno su dobro povezane sa središnjim stanišnim dijelovima.

Na temelju rezultata modela staništa možemo istaknuti neka granična područja na kojima bi tehničke barijere, posebice panelne ograde, mogle značajno smanjiti propusnost graničnog područja za velike zvijeri, a ujedno smanjiti funkcionalnost staništa - teritorija velikih zvijeri sa svake strane granice, unatoč očuvanom ukupnom staništu za njih. Tehničke barijere na području Slavnika i Čičarije mogle bi biti problematične jer dijele ukupno stanište na dva dijela. Nažalost, u sklopu telemetrijskog istraživanja nismo opremili nijednu životinju na tom području, tako da nemamo stvarnih aktualnih podataka. Tijekom 2010. i 2011. godine telemetrijski smo pratili vukove na ovom području, a podaci pokazuju da su vukovi tamo redovito prelazili državnu granicu (kada nije bilo ograde), a teritorij ćopora pokrivao je područje s obje strane granice.

Područje planinskog lanca Snežnik (od Gomanca do Babnog polja) jedan je od najvažnijih prolaza za velike zvijeri. U slučaju sve tri velike zvijeri, ovo je dio središnjeg staništa, pa je iznimno važno da ono ostane neizgrađeno, jer bi im dulje linijske barijere mogle uvelike smanjiti propusnost i povezanost područja. Dvije postojeće više od 10 kilometara duge ograde (na graničnom prijelazu Petrina i od Grgelja do Sodevaca) mogle bi imati izrazito negativan utjecaj na prohodnost u pograničnom području doline Kolpe, budući da postoje potencijalni koridori staništa (Slika 11.) povezujući Gorski kotar s Goteniškom gorom, Poljanskom gorom i Kočevskim Rogom na sjeveru. Kako bi se održala funkcionalna povezanost područja velikih zvijeri na ovom području, preporučamo skraćivanje postojećih tehničkih barijera na ovom području, posebno područja s žicom za rezanje, koja je vjerojatno djelomično propusna za velike zvijeri, etički je upitna u smislu dobrobiti životinja (ozljeda , smrtnost), čovjeku, međutim, ne predstavlja značajnu prepreku u tranziciji.

Daljnje širenje tehničkih barijera na spomenutom području središnjeg dijela dinarskog staništa intenzivno bi ograničilo protok jedinki i povezanost populaciju velikih zvijeri s obje strane granice. Najjači negativni utjecaj takvog širenja barijera bio bi pogotovo za populaciju risa, koji je i najslabiji disperger između tih vrsta velikih zvijeri. S obzirom na to da je populacija dinarskog risa mala, genetski osiromašena zbog dugotrajne izolacije i malog početnog broja primjeraka – utemeljitelja populacije, svaka dodatna fragmentacija populacije, unatoč doseljavanju (trenutno

u sklopu projekta LIFE Lynx) značila bi njegovo izumiranje ili značajno ugroženo mogućnost uspostavljanja održive metapopulacije na širem području jugoistočnih Alpa, Dinarida te ostatka Balkanskog poluotoka.

Izvori

Aiello-Lammens, M.E., Boria, R.A., Radosavljevic, A., Vilela, B., Anderson, R.P., 2015. spThin: An R package for spatial thinning of species occurrence records for use in ecological niche models. Ecography 38, 541–545.

Chubaty, A.M., Galpern, P., Doctolero, S.C., 2020. The r toolbox grainscape for modelling and visualizing landscape connectivity using spatially explicit networks. Methods Ecol. Evol. https://doi.org/10.1111/2041-210x.13350

Copernicus Land Monitoring Service, 2018. Corine Land Cover 2018.

Dobbert, S., Pape, R., Löffer, J., 2021. Continent-wide modelling of potential habitats and connectivity for the Eurasian lynx (Lynx lynx) in Europe. Erdkunde 75, 69–85.

Heiberger, R.M., 2020. HH: statistical analysis and data display: Heiberger and Holland. R package version 3.1--15.

Hijmans, R.J., 2017. raster: Geographic Data Analysis and Modeling.

Kass, J.M., Muscarella, R., Galante, P.J., Bohl, C.L., Pinilla-Buitrago, G.E., Boria, R.A., Soley-Guardia, M., Anderson, R.P., 2021. ENMeval 2.0: Redesigned for customizable and reproducible modeling of species' niches and distributions. Methods Ecol. Evol. https://doi.org/10.1111/2041-210x.13628

Phillips, S.J., Anderson, R.P., Dudík, M., Schapire, R.E., Blair, M.E., 2017. Opening the black box: an open-source release of Maxent. Ecography 40, 887–893.

R Core Team, 2021. R: A Language and Environment for Statistical Computing.

Rodriguez Recio, M., Jerina, K., Knauer, F., 2018. Action A3: Analysis of spatial connectivity and preparation of environmental impact assessment guidelines.

RStudio Team, 2021. RStudio: Integrated Development Environment for R.

Skrbinšek, T., Krofel, M., 2008. Analiza Kvalitete Habitata, Hrana In Kompeticija. DINA RIS.