

Tim Gregorčič*, Andrej Rozman**, Blaž Repe***



UPORABA METODE MAKSIMALNE ENTROPIJE PRI PROUČEVANJU POTENCIALNEGA VPLIVA PODNEBNIH SPREMOMB NA SLOVENSKE GOZDOVE

*Izvirni znanstveni članek
COBISS 1.01
DOI: 10.4312/dela.57.57-88*

Izvleček

V prispevku je predstavljen razvoj postopka proučevanja potencialnih vplivov podnebnih sprememb na slovenske gozdove v obdobju 2081–2100. Razvoj metodologije temelji na modeliranju ekoloških niš z uporabo metode maksimalne entropije. V raziskavi smo upoštevali dva podnebna scenarija smeri skupnega družbenogospodarskega razvoja (optimističnega SSP1-2,6 in pesimističnega SSP5-8,5). Slovenske gozdove smo razdelili na trinajst gozdnih vegetacijskih tipov. Statistični rezultati so pokazali, da je razvita metodologija primerna za namene tovrstnega proučevanja.

Ključne besede: podnebne spremembe, slovenski gozdovi, metoda maksimalne entropije, Maxent, smeri skupnega družbenogospodarskega razvoja, GIS

• *Škarpna 8, SI-8230 Mokronog

• **Oddelek za gozdarstvo in obnovljive gozdne vire, Biotehniška fakulteta Univerze v Ljubljani, Večna pot 83, SI-1000 Ljubljana

• ***Oddelek za geografijo, Filozofska fakulteta Univerze v Ljubljani, Aškerčeva 2, SI-1000 Ljubljana

• e-pošta: tim.gregorcic@gmail.com, Andrej.Rozman@bf.uni-lj.si, Blaz.Repe@ff.uni-lj.si

• ORCID: 0000-0003-0797-5452 (A. Rozman), 0000-0002-5530-4840 (B. Repe)

PREDICTING POTENTIAL CLIMATE CHANGE IMPACTS ON SLOVENIAN FORESTS USING THE MAXIMUM ENTROPY METHOD

Abstract

This article presents the development of a methodology for analysing the potential impacts of climate change on Slovenian forests in the period between 2081 and 2100. The development of the methodology is based on the use of Maxent software for modelling ecological niches. In this study, 2 common socio-economic pathway scenarios are used, the optimistic SSP1-2.6 and the pessimistic SSP5-8.5. Slovenian forests are divided into 13 forest vegetation types. The statistical results prove that the developed methodology is suitable for analysing the potential impacts of climate change on Slovenian forests in the period between 2081 and 2100.

Keywords: climate change, Slovenian forests, maximum entropy method, Maxent, shared socioeconomic pathways, GIS

.....

1 UVOD

Zemljino podnebje se danes naglo spreminja (Bertalanič in sod., 2018). Z vidika blaženja in prilagajanja na te spremembe želi znanost odgovoriti na mnoga vprašanja, ki zadevajo potencialne vplive podnebnih sprememb na različne Zemljine naravne in družbene podsisteme (Daddi in sod., 2020). Na tem področju pomembno vlogo igra tudi fitogeografija, saj spremembe podnebja predvsem kot močan stresor že vplivajo na biosfero po celotnem svetu in slovensko območje ni izjema (Bertalanič in sod., 2018). Slovenija je danes gozdnata država z relativno visoko vegetacijsko pestrostjo (Bončina in sod., 2021; Kutnar, Kobler, Bergant, 2009), kar žal ni povsem samoumevno v prihodnosti, saj s spreminjanjem podnebja pričakujemo tudi spremembe rastiščnih pogojev, v katerih uspevajo današnji gozdni vegetacijski tipi (GVT). Tovrstne spremembe je možno oceniti z modeliranjem ekoloških niš. Cilj naše raziskave je bil razvoj postopka proučevanja potencialnih vplivov podnebnih sprememb na slovenske gozdove za obdobje 2081–2100 z uporabo metode maksimalne entropije, ki se v svetu za te namene uporablja vedno pogosteje.

2 TEORETSKA IZHODIŠČA

2.1 Podnebne spremembe v antropocenu


Podnebje je Zemljin podsistem, ki se je v geološki preteklosti z menjavanjem glacialnih in interglacialnih obdobij neprestano spreminjal (Ogrin, 2005). Danes se soočamo z obdobjem intenzivnega segrevanja podnebja, ki ga zaradi povzročitelja, ki ga geološka preteklost do danes ni poznala, ločimo od vseh dosedanjih podnebnih nihanj. V znanosti velja konsenz, da je za spreminjanje podnebja v 20. in 21. stoletju odgovoren človek. Po mnenju mnogih je to tudi eden od glavnih razlogov za nastop novega geološkega obdobja, imenovanega antropocen. Čeprav dogovora o nastopu antropocena v znanosti še ni, mnogi avtorji utemeljujejo, zakaj je uveljavitev tega geološkega obdobja smiselna oziroma celo potrebna. Po mnenju DellaSala in sod. (2018) ima človeštvo na planetarni ravni na okolje tako močan vpliv, da je uveljavitev antropocena kot novega geološkega obdobja upravičena. Ellis (2019) opozarja, da z vidika razvoja biogeografije nastop antropocena označuje dejstvo, da se zaradi obdobja velikih okoljskih sprememb konvencionalni raziskovalni pristopi v biogeografiji za pojasnjevanje različnih procesov izkazujejo za nezadostne in so potrebni prenove. Leichenko in O'Brien (2020) utemeljujeta pomen uveljavitve antropocena tudi skozi izobraževalno prizmo. Uveljavitev obdobja razumeta kot odmik od konvencionalne holocenske obravnave podnebnih sprememb. Menita, da bi s tem miselnim preskokom družba lažje prešla od iskanja konvencionalnih rešitev za morda največji izziv 21. stoletja na bolj inovativne pristope. Predlog uveljavitve antropocena je naveden tudi v zadnjem poročilu Medvladnega foruma za podnebne spremembe (IPCC) (Chen in sod., 2021). Mnenjem omenjenih avtorjev se pisci prispevka pridružujemo, zato v nadaljevanju obravnavamo spreminjanje podnebja kot podnebne spremembe antropocena, ki ga definiramo kot geološko dobo, v kateri človeška vrsta tako močno posega v različne planetarne procese, da lahko njeno delovanje označimo za odločilni dejavnik, saj so njeni vplivi jasno vidni (Results of binding vote ..., 2019).

Organizacija združenih narodov je že leta 1992 v Okvirni konvenciji Združenih Narodov o spremembi podnebja (*United Nations Framework convention on Climate Change* oz. UNFCCC) podnebne spremembe definirala kot »pojavnost spreminjanja podnebja, ki je posledica človekovih dejavnosti, ki neposredno in posredno spreminjajo sestavo atmosfere na globalni ravni, pojav pa se od siceršnje spremenljivosti podnebja ločuje po intenzivnosti sprememb v kratkem časovnem obdobju« (OZN, 1992, str. 7). Definicija IPCC je širša. Podnebne spremembe so definirane kot spremembe stanja podnebja, ki jih je mogoče zaznati (npr. z uporabo statističnih metod) na podlagi sprememb v povprečju in/ali spremenljivosti njegovih lastnosti in ki traja daljše obdobje, običajno desetletja ali dlje. Spremembe podnebja so lahko posledica naravnih notranjih ali zunanjih dejavnikov, kot so variabilnost Sončeve aktivnosti, vulkanski izbruhi in trajne antropogene spremembe v sestavi ozračja in rabi tal. UNFCCC torej

razlikuje med podnebnimi spremembami, ki jih lahko pripišemo človekovim dejavnostim, in spremenljivostjo podnebja, ki je del naravnih ciklov, medtem ko IPCC oboje pojmuje kot podnebne spremembe (Mach, Planton, von Stechow, 2014).

Slika 1 za leto 2019 prikazuje dejavnike, ki pozitivno oziroma negativno vplivajo na skupno energetska bilanco Zemlje. Podnebje se segreva, ker je ta od ravnovesnega referenčnega stanja leta iz 1750, ki predstavlja predindustrijsko obdobje, vedno bolj oddaljena v smeri pozitivne osi. Ključni razlog za to so človekovi izpusti toplogrednih plinov v ozračje, med katerimi prevladujeta predvsem CO₂ in CH₄. Nekateri antropogeni sevalni prispevki na skupno energetska bilanco planeta vplivajo tudi negativno (aerosoli in spremembe rabe tal), a s tem le blažijo prevladujoči vpliv antropogeno emitiranih toplogrednih plinov (Forster in sod., 2021; Mathez, Smerdon, 2018).

Slika 1: Sevalni prispevki različnih vplivov na podnebne spremembe v letu 2019 glede na predindustrijsko obdobje.



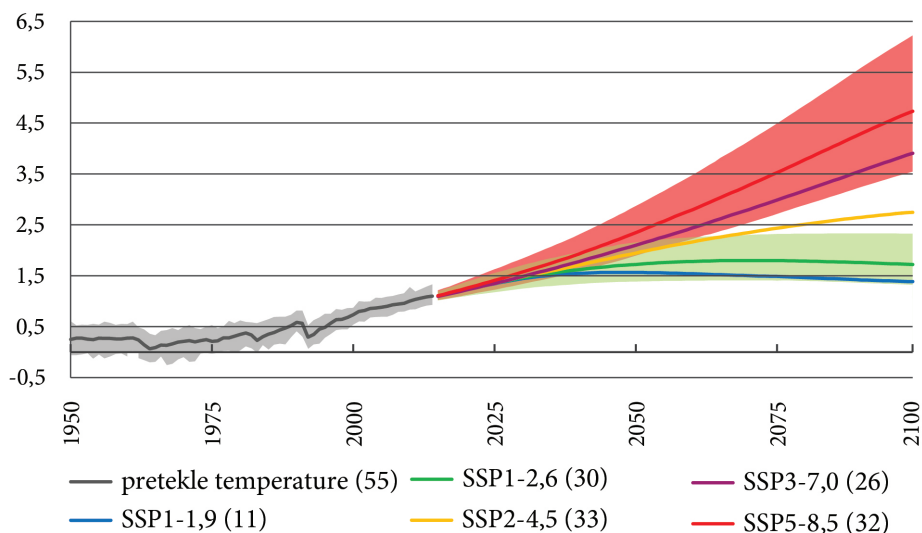
Vir podatkov: Forster in sod., 2021.

2.2 Smeri skupnega družbenogospodarskega razvoja do leta 2100

Zadnje poročilo IPCC iz leta 2021 predstavlja nove podnebne scenarije, imenovane »smeri skupnega družbenogospodarskega razvoja«¹ (ang. *Shared Socioeconomic Pathways* oz. *SSP*), ki so nasledniki scenarijev RCP (Forster in sod., 2021). Poimenujemo jih glede na ocenjeni učinkoviti sevalni prispevek ob koncu 21. stoletja, in sicer SSP1-1,9, SSP1-2,6, SSP2-4,5, SSP3-7,0 ter SSP5-8,5. Ti scenariji napovedujejo segrevanje ozračja od 1,5 do 4,8 °C (slika 2). Že njihovo ime nakazuje, da so bili zasnovani na podlagi razumevanja, kako različni družbenogospodarski vzvodi (demografski razvoj, gospodarski razvoj, izobrazbena struktura prebivalstva, stopnja urbanizacije) vplivajo na rabo energije, rabo tal in količino antropogenih izpustov toplogrednih plinov. Dejanski odziv družbe na eksistencialni izziv, ki ga predstavljajo podnebne spremembe, je zaradi mnogih dejavnikov težko napovedati. Zato je pri interpretaciji scenarijev SSP te treba obravnavati kot možne smeri razvoja in ne kot deterministične napovedi (Riahi in sod., 2021).

Slika 2: Hod povprečnih globalnih temperatur glede na pet scenarijev SSP.

Sprememba povprečne globalne temperature ozračja glede na obdobje 1850–1900



Vir podatkov: CEDA, 2021; Lee in sod., 2021.

1 Zaradi novosti termina »Shared Socioeconomic Pathways« v slovenski literaturi še ni uradnega prevoda, zato je termin »smeri skupnega družbenogospodarskega razvoja« predlog uradnega poimenovanja.

Pri proučevanju vpliva podnebnih sprememb na slovenske gozdove smo se odločili, da bomo primerjali potencialne vplive v primeru uresničitve scenarijev SSP1-2,6 in SSP5-8,5. Scenarij SSP1-2,6 imenujemo tudi srednja smer razvoja. Po tem scenariju naj bi se povprečna globalna temperatura v obdobju 2081–2100 zvišala za 2,0 °C (1,3–2,8 °C) glede na obdobje 1850–1900 (Lee in sod., 2021), pri čemer bi družba ogljično nevtralnost dosegla v drugi polovici 21. st. (Chen in sod., 2021). Gre za scenarij, ki je med realističnimi najbolj optimističen. Za ta scenarij smo se odločili, ker verjamemo, da družba z odgovornim kolektivnim odzivom podnebne spremembe lahko omeji na dvig povprečne temperature za 2,0 °C (1,3–2,8 °C) glede na obdobje 1850–1900. Uresničitev cilja Pariškega sporazuma o omejitvi segrevanja ozračja na 1,5 °C predstavlja scenarij SSP1-1,9, a ta ni več uresničljiv (Forster in sod., 2021).

Scenarij SSP5-8,5 je najbolj pesimističen scenarij, po katerem bi družba povsem temeljila na fosilnih gorivih. Povprečna globalna temperatura ozračja bi se v obdobju 2081–2100 zvišala za 4,8 °C (3,6–6,5 °C) glede na obdobje 1850–1900 (Lee in sod., 2021). Čeprav današnji trendi blaženja podnebnih sprememb nakazujejo na to, da svet ne bo ubral poti nadaljnjega razvoja, temelječega na izkoriščanju fosilnih goriv, smo pesimistični scenarij SSP5-8,5 izbrali zato, da proučimo, kaj bi popolno podnebno opustošenje pomenilo za slovenske gozdove.

2.3 Podnebni modeli

Podnebni modeli so kompleksni in napredni matematični sistemi, ki poskušajo v najboljši možni meri razumeti in simulirati delovanje Zemljinega podnebnega sistema na različnih prostorskih ravneh, pri čemer vključujejo različne fizikalne, kemijske in biološke spremenljivke in mehanizme tega sistema ter interakcije med njimi. Glavni cilj razvoja podnebnih modelov je simulacija različnih podnebnih komponent prihodnosti glede na podnebne scenarije. Njihovi rezultati predstavljajo povratno informacijo o posledicah različnih variant razvoja človeške družbe v naslednjih desetletjih, ki vplivajo na potek spreminjanja podnebja (IPCC, 2014). Podnebni modeli, ki smo jih uporabili v razvoju metodologije, izhajajo iz šeste faze cikličnega razvojnega projekta, imenovanega »Primerjava sklopljenih modelov« (CMIP6). Rezultate te faze projekta vsebuje tudi zadnje poročilo IPCC (Lee in sod., 2021).

Podnebni modeli, ki smo jih uporabili pri razvoju metodologije, se imenujejo modeli Zemljinega sistema (angl. *Earth System Models* oz. ESM) in predstavljajo višek razumevanja Zemljinega podnebnega sistema (Taylor, Stouffer, Meehl, 2012). Zadnje poročilo IPCC rezultate modeliranja temperaturnih in padavinskih sprememb iz CMIP6 ocenjuje s kvalitativno oceno »visoka stopnja zaupanja«. Kljub temu velja, da modeliranje padavinskih sprememb vsebuje več negotovosti kot modeliranje temperaturnih sprememb (Lee in sod., 2021). Poleg tega je treba opozoriti tudi na splošne negotovosti ESM, čeprav so tehnično vedno bolj dovršeni. Za modeliranje potencialnih vplivov podnebnih sprememb na slovenske gozdove smo uporabili 3 ESM:

- CNRM-ESM2-1. ESM je razvila ena od evropskih delovnih skupin CMIP6, ki se imenuje CNRM – CERFACS. Izbrani model je nadgradnja CNRM-CM5 iz faze CMIP5 (Séférian in sod., 2019).
- BCC-CSM2-MR. ESM je razvila kitajska delovna skupina CMIP6. Tudi ta model je nadgradnja njegovega predhodnika BCC-CSM1-1 iz CMIP5 (Wu in sod., 2019). Rezultati modela so se že izkazali za učinkovite pri uporabi metode maksimalne entropije na območju Južne Evrope, v katero je bila vključena tudi Slovenija (Jamal in sod., 2021). Za območje Slovenije je tudi Kuralt (2016) že uporabil model BCC-CSM1-1 za proučevanje vpliva podnebnih sprememb na potencialno razširjenost črne vdove (*Latrodectus tredecimguttatus*).
- MIROC6. ESM je razvila japonska delovna skupina CMIP6, njegov predhodnik pa je CMIP5. Izbran je bil, ker spada med modele, ki najbolje simulirajo cirkulacijo atmosfere na območju Evrope (Fernandez-Granja in sod., 2021).

2.4 Modeliranje ekoloških niš in razširjenosti vrst

Modeliranje razširjenosti vrst je nabor znanstvenih definicij, metod in tehnik, ki razlagajo soodvisnost med prostorsko razporeditvijo živalskih in rastlinskih vrst ter njihovim abiotskim življenjskim okoljem. Modeli razširjenosti vrst (angl. *Species Distribution Models*) so kvantitativne in empirične metode ter orodja, s katerimi iščemo omenjene povezave (Elith, Franklin, 2013). Današnje modeliranje ekoloških vrst sta omogočili dve odločilni veji znanstvenega raziskovanja: sistematično terensko kartiranje vrst živih bitij in njihovega naravnega okolja ter močan metodološki razvoj fizične geografije v povezavi z geografskimi informacijskimi sistemi (vse bolj natančni digitalni modeli nadmorskih višin, prostorske interpolacije, daljinsko zaznavanje itd.) (Elith, Leathwick, 2009).

V znanstveni literaturi se srečujemo z veliko terminološko nedorečenostjo okoli uporabe dveh temeljnih pojmov: »modeliranje razširjenosti vrst« in »modeliranje ekoloških niš«. Geografski terminološki slovar (2021) ekološko nišo definira kot »celoto neživih in živih okoljskih dejavnikov, sestavin ekosistema, ki bistveno vplivajo na preživetje posamezne vrste organizmov in na njeno vlogo v okolju«. Termin »modeliranje ekoloških niš« je primeren za študije, ki obravnavajo potencialne spremembe razporeditve vrst zaradi spremenjenih življenjskih razmer in okoliščin, medtem ko je izraz »modeliranje razširjenosti vrst« primeren za študije, v katerih rezultati modela predstavljajo realno, in-situ stanje razširjenosti izbrane vrste (Townsend Peterson, Soberon, 2012). Pri vprašanju pravnega izbora termina torej ni odločilen izbor metode, temveč namen modeliranja. V primeru razvoja metodologije, ki jo opisujemo, je zato pravilna uporaba termina »modeliranje ekoloških niš«.

Modeliranje ekoloških niš je temeljilo na naslednjih predpostavkah (De Marco in sod., 2008; Guisan, Thuiller, Zimmermann, 2017):

- Proučevana vrsta v svojem habitatu biva v dinamičnem ravnovesju.

- Razumemo odvisnost pojavnosti vrste od vseh ključnih okoljskih gradientov (temperaturnih, vodnih ...), ki omogočajo njeno uspevanje, in jih v relevantni prostorski ločljivosti vključujemo v model.
- Okolje bo vrstam dostopno v enaki meri, kakor je danes.
- V model je zajeta celotna ekološka niša, ki bo ostala stabilna, kot je danes.

Poleg omenjenih teoretskih smo temeljili tudi na štirih metodoloških predpostavkah (Guisan, Thuiller, Zimmermann, 2017):

- Glede na namen raziskave je uporabljena prava metoda modeliranja ekoloških niš.
- Neodvisne spremenljivke ne vsebujejo napak.
- Podatki o prisotnosti vrste so nepristranski.
- Točke z informacijo o prisotnosti vrste so izbrane naključno.

Kritiki opozarjajo tudi na nekatere pomanjkljivosti omenjenih teoretskih predpostavk. Ob drastični spremembi podnebnih razmer vrste izstopijo iz dinamičnega ravnovesja. Z okoljskimi spremembami, med katere spadajo tudi podnebne spremembe, se lahko spremenijo ključni omejevalni dejavniki, ki jih danes ne moremo predvideti. Enako velja za spremembo biotskih odnosov med vrstami in v njih. Ob okoljskih spremembah lahko pričakujemo tudi spremembo genetskih struktur vrst, kar sicer velja predvsem za dolgoročne spremembe in ne nekajdesetletne. Današnji trendi prostorskega obnašanja vrst so lahko ob spremembah življenjskega okolja zamajani ali spremenjeni. Kritiki opozarjajo tudi na to, da so vhodni podatki za modeliranje ekoloških niš lahko prostorsko netočni, kar privede do statistično korektnih, a vsebinsko napačnih rezultatov (Dormann, 2006; Miller, 2010; Sinclair, White, Newell, 2010).

2.5 Metoda maksimalne entropije in programsko orodje Maxent

Poznamo več vrst entropije. Pri razvoju metodologije smo uporabili Shannovo entropijo. Definirana je kot količina, s katero kvantitativno izrazimo negotovost izida določenega poskusa ali sistema. Proučevani sistem sestavljajo določeni mehanizmi. Tiste, ki poznamo, lahko vključimo v izračun entropije kot omejitve (angl. *constraints*). Z njimi zmanjšamo stopnjo negotovosti, ki je del verjetnostne porazdelitve. Po načelu maksimalne entropije se moramo pri izboru najprimernejše verjetnostne porazdelitve odločiti za tisto, ki ob upoštevanju vseh omejitev vsebujejo največjo mero negotovosti oziroma maksimalno entropijo (Penfield, 2013; Jaynes, 1957).

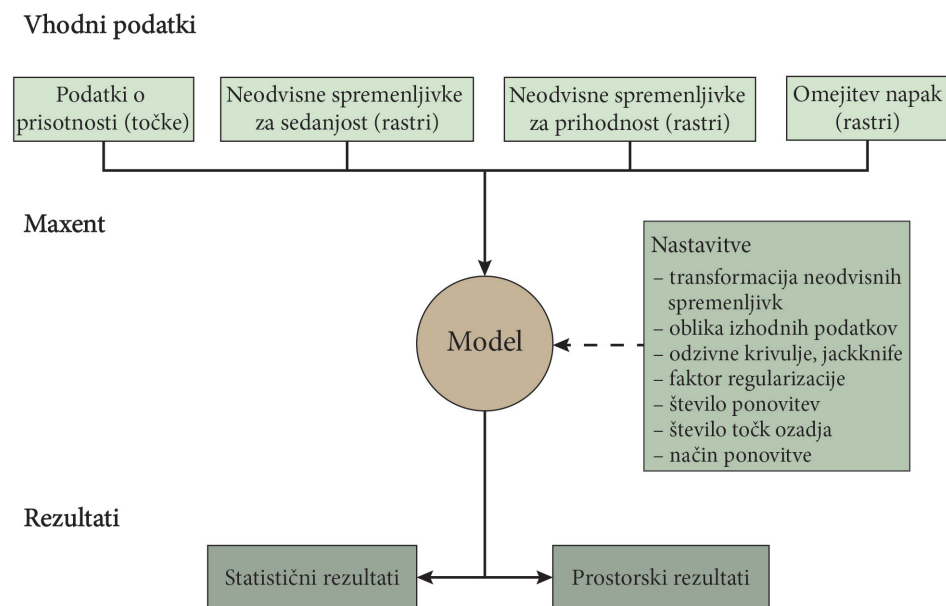
Za modeliranje ekoloških niš z uporabo metode maksimalne entropije smo uporabili programske orodje Maxent. Programsko orodje je bilo razvito leta 2004 in je od takrat brezplačno dostopno na spletu (Phillips, Dudik, Schapire, 2004). V zadnjih letih lahko iz baz znanstvenih objav razberemo močan porast uporabe orodja, ki zanima različne znanstvene discipline (ekologijo, veje fizične geografije, gozdarstvo itd.) (Web of Science, 2022). Maxent je posebno priljubljen za modeliranje ekoloških

niš (Ngarega, Masocha, Schneider, 2021; Saha, Rahman, Alam, 2021; Sun, Long, Jia, 2021; Zhao in sod., 2021; Zhao in sod., 2021).

Ogrodje delovanja programskega orodja Maxent prikazuje slika 3. Vhodne podatke delimo na tri sklope. V prvega umeščamo neodvisne spremenljivke v obliki rastrskih slojev podatkov, ki imajo z vidika Shannove entropije funkcijo omejitev. Ker so odnosi vrst do kombinacije različnih identificiranih dejavnikov (neodvisnih spremenljivk) izredno kompleksni, jih ne moremo razlagati s preprostimi linearnimi funkcijami. Programsko orodje zato izvaja različne transformacije osnovnih neodvisnih spremenljivk. V drugi sklop vhodnih podatkov uvrščamo iste neodvisne spremenljivke, le da vsebujejo vrednosti za prihodnost oz. preteklost. Ta sklop je torej relevanten le v primeru modeliranja ekoloških niš in ne v primeru modeliranja razširjenosti vrst. V tretji sklop spadajo točkovni podatki o prisotnosti vrste na proučevanem območju. Točke morajo biti izbrane naključno. Priporočljivo je upoštevati pravilo palca, ki pravi, da je primerno število točk prisotnosti desetkratnik števila uporabljenih neodvisnih spremenljivk (Guisan, Thuiller, Zimmermann, 2017). Poleg dveh oziroma treh obveznih sklopov vhodnih podatkov je priporočljivo tudi, da v zagon programskega orodja vključimo tudi podatkovni sloj za omejitev napak modeliranja (Barbet-Massin in sod., 2012). Poleg vhodnih podatkov lahko pred zagonom programskega orodja z nastavitvami vplivamo tudi na izvedbo analize in vrsto končnih rezultatov (Merow, Smith, Silander, 2013).

Izhodne podatke modeliranja delimo na statistične in prostorske, v veliki meri pa so odvisni od vhodnih nastavitvev. V statističnem delu programskega orodja najprej generira grafikon opustitve in napovedanih površin (slika 5). Na njem so prikazane mere opustitve (angl. *omission rate*) za učne in testne točke. Drugi grafikon, ki ga generira programskega orodje, je najpomembnejši in se imenuje grafikon lastnosti delovanja sprejemnika (angl. *receiver operating characteristics*) oziroma grafikon krivulj ROC (slika 6). Površina pod krivuljo ROC se imenuje AUC (angl. *area under the receiver operating characteristic curve*), njena vrednost pa je merilo verodostojnosti rezultatov modeliranja (Phillips, 2017; Phillips in sod., 2017). Če vrednost AUC znaša več kot 0,7, lahko rezultate modeliranja označimo kot statistično uspešne (Araujo in sod., 2005). V primeru specifičnih nastavitvev programskega orodja izriše tudi odzivno krivuljo za posamezno neodvisno spremenljivko, ki grafično prikazuje odvisnost rezultatov modeliranja od nje. Metoda maksimalne entropije izračuna še doprinos posamezne neodvisne spremenljivke h končnim rezultatom, ki je izražen v odstotkih. Za še natančnejši izračun doprinosa lahko izvedemo tudi analizo Jackknife (Phillips, 2017).

Slika 3: Shematski prikaz delovanja programskega orodja Maxent.



Avtor: Tim Gregorčič, 2022.

2.6 Gozdni vegetacijski tipi Slovenije

V slovenskih gozdovih najdemo 78 poglavitnih gozdnih rastiščnih tipov, pri katerih vsak obsega specifične rastiščne razmere (Bončina in sod., 2021). Vseh 78 gozdnih rastiščnih tipov smo smiselno združili v 13 skupin GVT, kot so to storili Kutnar, Koblner in Bergant (2009, str. 34):

- acidofilna bukovja (GVT1),
- acidofilna rdečeborovja (GVT2),
- podgorska bukovja (GVT3),
- gorska bukovja (GVT4),
- (visoko)gorska bukovja v (pred)alpskem območju (GVT5),
- (visoko)gorska bukovja v (pred)dinarskem območju (GVT6),
- termofilna bukovja (GVT7),
- kolinska hrastova-belogabrovja (GVT8),
- nižinska vrbovja, jelševja in dobovja (GVT9),
- termofilna črnogabrovja, hrastovja, rdečeborovja in črnoborovja (GVT10),
- jelovja (GVT11),
- smrekovja (GVT12) in
- ruševje (GVT13).

Vsak GVT vsebuje gozdne rastiščne tipe, ki so jim skupne podobne rastiščne razmere s posebnim poudarkom na podnebnih dejavnikih. S tem smo se odločili za mezoekološko modeliranje ekoloških niš (MacKey, Lindenmayer, 2001). Združevanje gozdnih rastiščnih tipov je bilo potrebno zaradi statističnih omejitev modeliranja, ki so povezane z majhno površino določenih rastiščnih tipov in razmeroma veliko prostorsko ločljivostjo neodvisnih spremenljivk.

3 METODOLOGIJA

3.1 Nabor neodvisnih spremenljivk

Med neodvisnimi spremenljivkami, ki smo jih uporabili za modeliranje ekoloških niš, so bile najpomembnejše tako imenovane bioklimatske spremenljivke. Te so našete v preglednici 1. Njihova podrobnejša opisna in kvantitativna predstavitev je na voljo v delu O'Donnella in Ignizia (2012). Gre za izpeljanke osnovnih podnebnih parametrov (povprečna mesečna temperatura zraka, povprečna mesečna maksimalna temperatura zraka, povprečna mesečna minimalna temperatura zraka in mesečna količina padavin), ki služijo za maksimiranje korelacije med prisotnostjo vrste in lokalnimi podnebnimi značilnostmi (Attorre in sod., 2007). Na področju modeliranja ekoloških niš so široko uporabljene (Portilla Cabrera, Selvaraj, 2020; Du in sod., 2021; Zeng in sod., 2021; Saha, Rahman, Alam, 2021). Sloji bioklimatskih spremenljivk za podnebje prihodnosti so na voljo na portalu WorldClim (Fick, Hijmans, 2017).

Preglednica 1: Bioklimatske spremenljivke.

Bioklimatska spremenljivka	Povprečna letna temperatura zraka	Letno povprečje dnevnega temperaturnega hoda	Izotermalnost	Sezonskost temperatur zraka	Najvišja temperatura zraka najtoplejšega meseca
Oznaka	BIO1	BIO2	BIO3	BIO4	BIO5
Bioklimatska spremenljivka	Najnižja temperatura zraka najhladnejšega meseca	Absolutni letni temperaturni hod	Povprečna temperatura zraka najvlažnejšega četrletja	Povprečna temperatura zraka najbolj sušnega četrletja	Povprečna temperatura zraka najtoplejšega četrletja
Oznaka	BIO6	BIO7	BIO8	BIO9	BIO10

Bioklimatska spremenljivka	Povprečna temperatura zraka najhladnejšega četrtertletja	Letna količina padavin	Količina padavin najbolj namočenega meseca	Količina padavin najbolj sušnega meseca	Sezonskost padavin
Oznaka	BIO11	BIO12	BIO13	BIO14	BIO15
Bioklimatska spremenljivka	Količina padavin najbolj namočenega četrtertletja	Količina padavin najbolj sušnega četrtertletja	Količina padavin najtoplejšega četrtertletja	Količina padavin najhladnejšega četrtertletja	
Oznaka	BIO16	BIO17	BIO18	BIO19	

Vir podatkov: O'Donnell, Ignizio, 2012.

Najmanjša prostorska ločljivost podatkov za prihodnost, ki je bila na voljo, je znašala 2,5 kotne minute. To je za modeliranje na območju Slovenije premalo natančno. Odločili smo se, da bomo prostorsko ločljivost neodvisnih spremenljivk izboljšali na 500 m. Uporabili smo kombinacijo metod, ki so jih razvili Poggio, Simonetti in Gimona (2018). Če ni navedeno drugače, je obdelava prostorskih podatkov potekala z uporabo programskega orodja ArcGIS Pro 2.9.0.

Za Slovenijo smo za obdobje 1970–2000 izračunali vseh 19 bioklimatskih spremenljivk s prostorsko ločljivostjo 500 m. Z ARSO smo pridobili homogenizirane podatke vseh merilnih mest, na katerih so v obdobju 1970–2000 merili omenjene osnovne podnebne parametre (47 merilnih mest za povprečne mesečne temperature, 42 za povprečne mesečne maksimalne temperature, 38 za povprečne mesečne minimalne temperature in 223 za mesečne količine padavin). Ker smo od agencije pridobili mesečne podatke za vsa leta v zelenem obdobju, smo najprej izračunali obdobjna povprečja. Za izdelavo rastrskih temperaturnih slojev smo uporabili metode Ninyerola, Ponsa in Roura (2000; 2007) in jih prilagodili glede na dejavnike, ki vplivajo na slovenske podnebne razmere. Ker na temperaturne razmere v Sloveniji odločilno vplivajo Sončevo obsevanje, nadmorska višina, reliefne danosti in raba tal (Ogrin, Plut, 2012), smo za izdelavo rastrskih slojev uporabili naslednje neodvisne spremenljivke:

- mesečno kvazisončevo obsevanje (izračunano z orodjem *Solar Radiation*),
- nadmorske višine,
- konkavnost površja (izračunano z orodjem *StochasticDepressionAnalysis* v programskem orodju *WhiteboxTools*) in
- logaritmirano oddaljenost od morja (izračunano z orodjem *Euclidean Distance* in *Raster Calculator*). Ta dejavnik smo preoblikovali z logaritmsko funkcijo, ker so bili determinacijski koeficienti R^2 ob izvajanju multiple linearne regresijske analize v naslednjem koraku tako višji.

Na vseh ustvarjenih rastrskih slojih smo z vsemi točkami, ki so predstavljale lokacije merilnih mest za posamezni temperaturni parameter, izvedli vzorčenje. S pridobljenimi podatki smo s pomočjo programskega orodja SPSS izvedli multiplo linearno regresijsko analizo variante *backward stepwise* (kasneje MLR). S tem smo določili funkcijsko povezanost med relevantnimi podnebnimi dejavniki in mesečnimi vrednostmi treh temperaturnih spremenljivk. Če je MLR spremenljivko ohranila kljub njeni statistični neznačilnosti, smo pozneje izvedli še analizo parcialne korelacije in se glede na njeno statistično (ne)značilnost odločili, ali spremenljivko ohranimo v analizi ali jo izključimo. Parcialno korelacijo je mogoče izračunati le za razmernostne spremenljivke. Konkavnost reliefa je nominalna spremenljivka, zato zanjo nismo mogli izračunati parcialne korelacije. Ko MLR spremenljivke kljub njeni statistični neznačilnosti ni izključila, smo analizo ponovili in spremenljivko izključili sami. Za to smo se odločili, ker za najhladnejše mesece, ko konkavnost reliefa igra največjo vlogo pri distribuciji temperatur, programsko orodje spremenljivke ni vključilo v analizo, ni pa je izključilo v mesecih, ko konkavnost reliefa ne igra pomembne vloge. Izmed vseh analiz vrednost najnižjega determinacijskega koeficienta znaša 0,694. To pomeni, da so izbrane neodvisne spremenljivke v visoki korelaciji z odvisno spremenljivko.

Glede na izračunane regresijske koeficiente smo ustvarili rastrske sloje surovih mesečnih temperaturnih podatkov. Z izbranimi podnebnimi dejavniki in uporabo MLR je pričakovano prišlo do razlik med izmerjenimi in ustvarjenimi vrednostmi. Potrebni so bili popravki surovih podatkov. Izračunali smo razliko med izmerjenimi in napovedanimi vrednostmi ter jih prostorsko interpolirali z metodo *Ordinary Kriging*. Izmed funkcij variograma smo izbrali med sferično, J-Bessel, K-Bessel, racionalno kvadratno, eksponentno, krožno, Gaussovo, tetrasferično, stabilno in učinkom luknje. Izbor funkcije je bil odvisen od tega, katera je v določenem mesecu privedla do najboljših rezultatov. To smo preverili z analizo grafikona navzkrižne preverbe. Ustvarjene sloje interpoliranih razlik smo prišteli slojem surovih mesečnih temperaturnih podatkov in s tem ustvarili končnih 36 temperaturnih slojev.

Za ustvarjanje slojev mesečnih količin padavin smo poskusili uporabiti isto metodo. Na prostorsko razporeditev padavin v Sloveniji najpomembneje vpliva oddaljenost od alpsko-dinarske orografske pregrade (Ogrin, Plut, 2012). Za neodvisne spremenljivke smo uporabili podatke o nadmorski višini, geografski širini, geografski dolžini in oddaljenosti od alpsko-dinarske pregrade. Zaradi multikolinearnosti med slednjima dvema neodvisnima spremenljivkama smo zadnje iz analiz izključili. Iz rezultatov analize MLR se je izkazalo, da neodvisne spremenljivke močno pripomorejo h končnemu modelu, vseeno pa pojava ne pojasnijo dovolj, da bi bili rezultati uporabni. Ta ugotovitev potrjuje tudi teoretično izhodišče, da je modeliranje padavin bolj kompleksno in manj uspešno od modeliranja temperaturnih razmer (Forster in sod., 2021). Namesto MLR smo padavinske sloje ustvarili neposredno iz prostorske interpolacije vrednosti točk merilnih mest z uporabo metode *Empirical Bayesian Kriging*. Tudi te prostorske interpolacije smo analizirali z grafikoni navzkrižne preverbe in ugotovili, da rezultati dosegajo visoko stopnjo točnosti.

Z ustvarjenimi temperaturnimi in padavinskimi podatki smo nato s programskim orodjem SAGA 8.0.1 izračunali 19 bioklimatskih spremenljivk za obdobje 1970–2000.

S portala WorldClim smo pridobili podatke za vseh devetnajst bioklimatskih spremenljivk za tri izbrane ESM, omenjene v poglavju 1.1.2. Da bi zmanjšali pristranskost končnih rezultatov, ki bi bila posledica izbora zgolj določenega ESM, smo iz njih izračunali povprečne vrednosti. Poleg tega smo s portala pridobili taiste spremenljivke za obdobje 1970–2000. Vsi sloji, ki smo jih pridobili s portala, so imeli prostorsko ločljivost 2,5 kotnih minut. Od bioklimatskih podatkov za prihodnost smo odšteli bioklimatske podatke za preteklost in s tem izračunali relativne razlike. Te smo prišteli prej ustvarjenim slojem bioklimatskih spremenljivk v prostorski ločljivosti 500 m za obdobje 1970–2000 in s tem ustvarili končne sloje, primerne za modeliranje.

Poleg bioklimatskih spremenljivk smo za modeliranje uporabili tudi sloj reakcije prsti. Pri ustvarjanju sloja je šlo zgolj za približek dejanskega stanja, saj metodologija ni temeljila na izmerjenih vrednostih pH, temveč na podlagi teoretskih predpostavk o reakciji tipov prsti. Na podlagi pedološke karte Slovenije (MKGP, 2007) smo določili štiri tipe: avtomorfne prsti s pretežno evtričnimi lastnostmi (litosoli, regosoli, rendzine, jerine, evtrične rjave, rjave pokarbonatne, koluvialno-deluvialne in rigolane prsti), avtomorfne prsti s pretežno distričnimi lastnostmi (izprane, distrične rjave, šotne prsti in rankerji), hidromorfne prsti s pretežno evtričnimi lastnostmi in hidromorfne prsti s pretežno distričnimi lastnostmi. V zadnja dva tipa smo glede na reakcijo umestili razvite in nerazvite obrečne prsti, oglejene ter psevdoglejene prsti (Repe, 2010).

Uspevanje GVT9 je determinirano z velikimi količinami podtalne vode (Bončina in sod., 2021), zato smo pri modeliranju te ekološke niše uporabili še evklidsko oddaljenost od hidrografske mreže (ARSO, 2006) in rezultate indeksa topografskega vlažnosti (TIV), ki smo ga izračunali s programskim orodjem SAGA.

3.2 Končni vhodni podatki

Sloj reakcije prsti smo uporabili pri modeliranju vseh ekoloških niš. Hidrogeografski spremenljivki sta bili, kot že omenjeno, uporabljeni le za modeliranje ekološke niše GVT9. Od 19 bioklimatskih spremenljivk za posamezni vegetacijski tip nikoli nismo izbrali vseh, ki so nam bile na voljo, saj nismo želeli prevelikega prileganja rezultatov. Vključili smo tiste, ki med sabo niso v preveliki pozitivni ali negativni korelaciji. Z 10.000 naključnimi vzorčnimi točkami smo na preučevanem območju vzorčili vrednosti vseh bioklimatskih spremenljivk za obdobje 1970–2000 in s programskim orodjem R Studio izračunali matriko Pearsonovih koeficientov. V primerih, ko je negativna ali pozitivna korelacija med dvema spremenljivkama znašala več kot 0,8 oz. manj kot $-0,8$, smo eno od njih izločili. Izločiti je bilo treba tisto, ki manj pripomore k točnosti končnih rezultatov. To smo izvedeli tako, da smo izvedli modelno analizo s programskim orodjem Maxent, v katero smo vključili vseh 20 oziroma 22 neodvisnih spremenljivk, in se osredotočili zgolj na rezultate analize Jackknife.

Za podatke o prisotnosti GVT smo uporabili podatke gozdnovegetacijske karte Slovenije v merilu 1 : 100.000 (Košir in sod., 1974; Košir in sod., 2007). Za vse GVT razen za GVT9, GVT11 in GVT13 smo naključno ustvarili 200 točk. Pri omenjenih izjemah smo zaradi majhne površine vegetacijskih tipov na eni strani ter dokaj velike prostorske ločljivosti podatkov na drugi število točk morali zmanjšati na 130. Del GVT8 na skrajnih jugozahodnih območjih države smo priključili GVT10 ter se s tem približali stanju novoopredeljenih območij toploljubnih listnatih gozdov po Bončini in sod. (2021).

Sloje za omejitve napak smo ustvarili z metodo *Sample by Buffered MCP (minimum convex polygon)*, ki je na voljo v zunanji zbirki orodij, namenjenih modeliranju ekoloških niš. Zbirka temelji na programskem jeziku Python in jo je mogoče vključiti v delovni proces v programskem orodju ArcGIS Pro (Brown, 2014).

V naslednjem koraku smo izvedli modeliranje. Za preverjanje točnosti rezultatov smo v nastavitvah določili, da naključno odvezamemo 20 % točk prisotnosti in z njimi izvedemo navzkrižno preverjanje. Modelno analizo smo izvedli za vsak vegetacijski tip in glede na rezultate proučili vrstni red pomembnosti neodvisnih spremenljivk. Ob upoštevanju korelacijskih koeficientov smo na koncu za vsak vegetacijski tip izbrali neodvisne spremenljivke, ki so za model najpomembnejše in ki obenem niso v preveliki medsebojni korelaciji (preglednica 2). Analize Jackknife so pokazale tudi, da v nekaterih primerih vključenost spremenljivke končni rezultat poslabša. To se je zgodilo pri GVT4 (BIO18), GVT7 (BIO6) in GVT11 (BIO7, BIO2). V teh primerih smo ločeno od opisane metodologije spremenljivke *a priori* izključili.

Preglednica 2: Končni izbor neodvisnih spremenljivk za posamezni GVT.

	BIO1	BIO2	BIO3	BIO4	BIO5	BIO6	BIO7	BIO8	BIO9	BIO10	BIO11
GVT1	×	✓	×	×	×	✓	✓	✓	✓	✓	×
GVT2	✓	×	✓	✓	×	×	✓	✓	✓	×	×
GVT3	×	×	✓	✓	✓	✓	✓	✓	✓	×	×
GVT4	×	×	✓	×	×	✓	✓	✓	✓	✓	×
GVT5	×	✓	×	✓	✓	✓	✓	✓	✓	×	×
GVT6	×	×	✓	×	×	✓	✓	✓	✓	✓	×
GVT7	×	×	✓	✓	✓	×	✓	✓	✓	×	×
GVT8	×	×	✓	✓	✓	✓	✓	✓	✓	×	×
GVT9	×	×	✓	×	×	✓	✓	✓	✓	✓	×
GVT10	×	×	✓	✓	×	×	✓	✓	✓	×	✓
GVT11	×	×	×	✓	×	✓	×	✓	✓	×	✓
GVT12	×	✓	×	×	×	✓	✓	✓	✓	✓	×
GVT13	×	✓	×	×	×	✓	✓	✓	✓	✓	×

	BIO12	BIO13	BIO14	BIO15	BIO16	BIO17	BIO18	BIO19	pH prsti	TIV	Odd. od hidro. mreže
GVT1	✓	×	×	✓	×	×	×	×	✓	×	×
GVT2	✓	×	×	✓	×	×	×	×	✓	×	×
GVT3	×	×	×	✓	×	×	✓	✓	✓	×	×
GVT4	×	×	×	✓	×	×	×	✓	✓	×	×
GVT5	×	×	×	✓	×	×	✓	✓	✓	×	×
GVT6	×	×	×	✓	×	✓	×	×	✓	×	×
GVT7	×	×	×	✓	×	×	✓	✓	✓	×	×
GVT8	×	×	×	✓	×	×	✓	✓	✓	×	×
GVT9	×	×	×	✓	×	×	✓	✓	✓	✓	✓
GVT10	×	×	×	✓	×	×	✓	✓	✓	×	×
GVT11	×	×	×	✓	×	×	✓	✓	✓	×	×
GVT12	✓	×	×	✓	×	×	×	×	✓	×	×
GVT13	×	×	×	✓	×	×	✓	✓	✓	×	×

3.3 Modeliranje ekoloških niš

Končne modelne analize smo ponovili z nastavitvami, ki so opisane v poglavju 3.2, a smo od neodvisnih spremenljivk uporabili le izbrane (preglednica 2). Vključili smo še bioklimatske spremenljivke z vrednostmi izbranih podnebnih scenarijev, s čimer smo ustvarili projekcije potencialnih razporeditev ekoloških niš v prihodnosti. Za izboljšanje rezultatov smo pri GVT1 in GVT2 uporabili tudi faktor regularizacije z vrednostjo 0,8. To je bilo potrebno, ker smo ugotovili, da je ob uporabi standardne vrednosti 1 razporeditev ekoloških niš za današnje obdobje preobsežna. To je indikator, da bi bile tudi projekcije ob uporabi regulacijskega koeficienta s to vrednostjo neizbežno manj točne.

Rezultate smo za sintezo združili tako, da smo vse sloje glede na njihove največje vrednosti združili v enega. Od tega sloja smo nato odšteli vse sloje osnovnih rezultatov verjetnosti. Vrednosti 0 so imele celice, kjer je imel posamezni GVT glede na vse ostale verjetnosti drugih tipov največjo možnost razširjenosti ekološke niše. Ta območja smo izluščili in jih obrezali z današnjimi gozdnimi površinami, s čimer smo prišli do končnih rezultatov, ki so primerni za nadaljnje analize sprememb ekoloških niš. Za vizualizacijo rezultatov smo te naknadno še generalizirali.

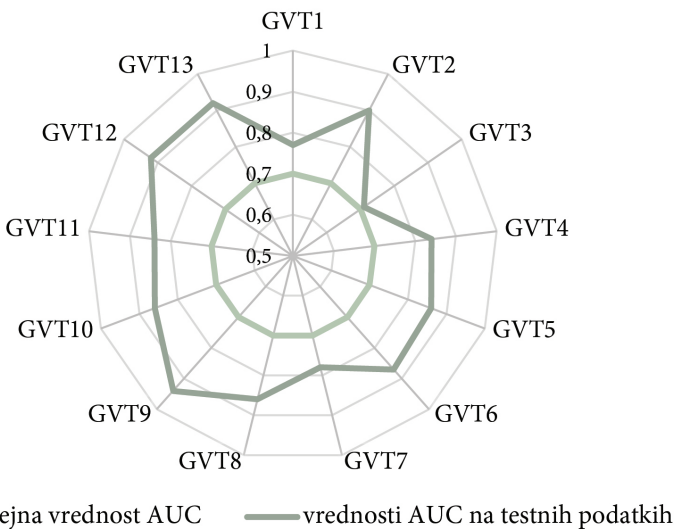
4 REZULTATI

Pri modeliranju ekoloških niš s programskim orodjem Maxent ob upoštevanju vseh predpostavk, ki so navedene v poglavju 1.2., so vse vrednosti AUC za testne podatke znašale več kot 0,7, s čimer lahko rezultate označimo kot statistično uspešne (preglednica 3 in slika 4). GVT3, GVT1 in GVT7 so dosegli zmerno mero statistične uspešnosti ($0,80 > AUC > 0,70$). GVT4, GVT11, GVT10, GVT8, GVT5 in GVT6 so dosegli dobro mero statistične uspešnosti ($0,90 > AUC > 0,80$). GVT2, GVT12, GVT13 in GVT9 so dosegli odlično mero statistične uspešnosti ($AUC > 0,90$) (Araujo in sod., 2005).

Preglednica 3: Vrednosti AUC.

GVT	AUC	GVT	AUC
GVT9	0,94	GVT10	0,86
GVT13	0,92	GVT11	0,84
GVT12	0,92	GVT4	0,84
GVT2	0,90	GVT7	0,78
GVT6	0,87	GVT1	0,77
GVT5	0,86	GVT3	0,71
GVT8	0,86		

Slika 4: Vrednosti AUC.



Avtor: Tim Gregorčič, 2022.

4.1 Študija primera: termofilna črnogabrovja, hrastovja, rdečeborovja in črnoborovja (GVT10)

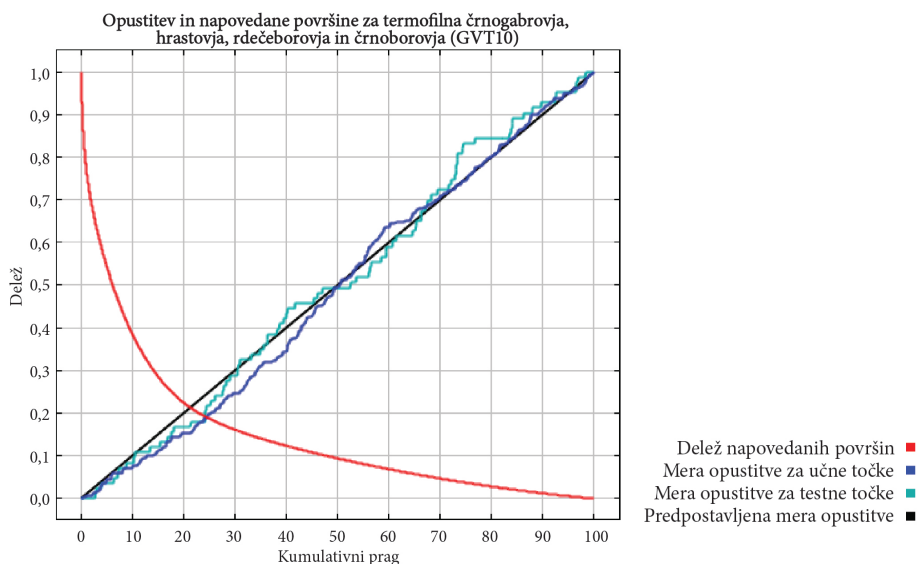
Poglavje 4.1 je na primeru GVT10 namenjeno predstavitvi osnovnih izhodnih podatkov, ki jih proizvede programsko orodje Maxent. Za GVT10 smo se odločili, ker lahko pričakujemo, da bodo njegovi rastiščni pogoji med tistimi, ki bodo doživeli največjo razširitev (Kutnar, Kobler, Bergant, 2009). Osnovni statistični del rezultatov modeliranja ekološke niše za GVT10 prikazujeta grafikona 4 in 5. Pomembna sta za vrednotenje uspešnosti in verodostojnosti modeliranja.

Rdeča črta na grafikonu opustitve in napovedanih površin (slika 5) kaže delež napovedanih površin v odvisnosti od izbranega kumulativnega praga. Pri kumulativnem pragu 0 % so na voljo vse površine (vrednost 1), pri pragu 100 % pa ni površin, ki bi bile na voljo. Drugi del grafikona predstavlja meri opustitve za učne in testne točke. Učne točke predstavljajo delež točk prisotnosti, ki jih programsko orodje uporabi za prepoznavanje vrednosti neodvisnih spremenljivk, ki so primerne za prisotnost vrste. Testne točke predstavljajo delež točk prisotnosti, ki jih programsko orodje uporabi za vrednotenje uspešnosti modeliranja. Opustitev je definirana kot delež točk prisotnosti vrste, ki v rezultatu modeliranja ležijo v celicah, ki jih metoda ni določila kot primerne za prisotnost proučevane vrste (Phillips, Anderson, Schapire, 2006). Pri kumulativnem pragu 0 tako ni točk, ki se ne bi nahajale na območju napovedanih površin. Pri kumulativnem pragu 100 % velja ravno obratno. Črti obeh mer opustitve morata čim bolj slediti predpostavljeni meri opustitve (Phillips, 2017). Iz grafikona 4 je razvidno, da rezultati temu pogoju ustrezajo, kar nakazuje na uspešnost modeliranja in kvalitetne rezultate.

Slika 6 je najpomembnejša in prikazuje krivulji ROC. Gre za funkcijo med deležem napovedanih površin ($1 - \text{specifičnost}$) in občutljivostjo. Specifičnost (angl. *specificity*) predstavlja površine, ki jih določeni prag ne zaobjema, občutljivost pa predstavlja delež točk prisotnosti vrste, ki ležijo v rastrskih celicah, ki jih je metoda prepoznala kot primerne za prisotnost vrste (Phillips, 2017; Phillips in sod., 2017). Pri pragu 0 % ni točk, ki bi se nahajale znotraj napovedanih površin, ker teh ni. Pri pragu 100 % so znotraj napovedanih površin vse točke, saj prag zaobjema celotno proučevano območje. Z grafa je razvidno, da se poteka obeh črt zadovoljivo ujemata in da vrednost AUC za testne podatke znaša 0,86. Kot omenjeno, to rezultate modela ocenjuje z dobro mero statistične uspešnosti (Araujo in sod., 2005). Hipotetična črna črta ROC predstavlja AUC vrednost 0,5. Gre za situacijo, v primeru katere bi bila napoved kljub vsem omejitvam (uporabljenim neodvisnim spremenljivkam) povsem naključna, rezultati pa povsem neuporabni.

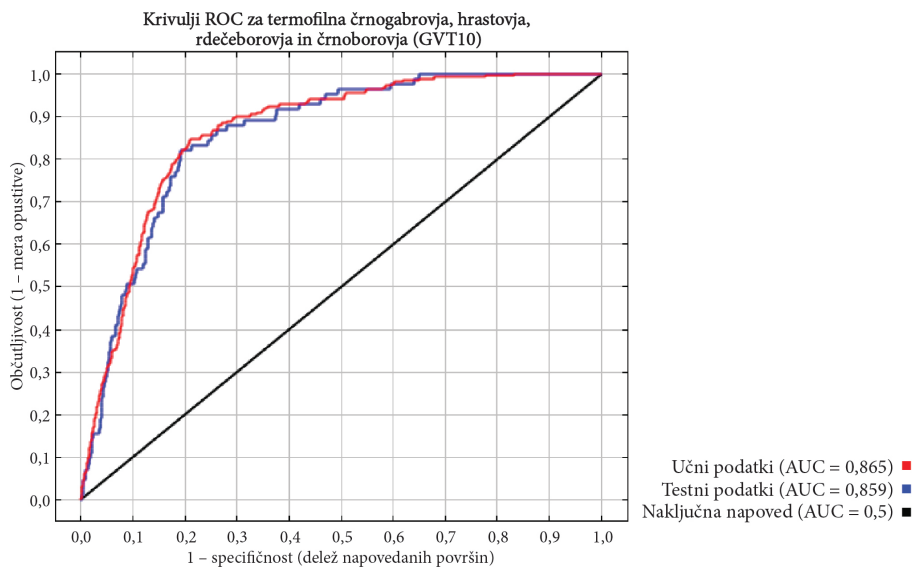
Slika 7 predstavlja končne prostorske rezultate modeliranja. Pri njih so upoštewane vse ostale verjetnosti prisotnosti ostalih GVT in so bili generalizirani za potrebe kartografskega prikaza.

Slika 5: Opustitev in napovedane površine za GVT10.



Avtor: Tim Gregorčič, 2022.

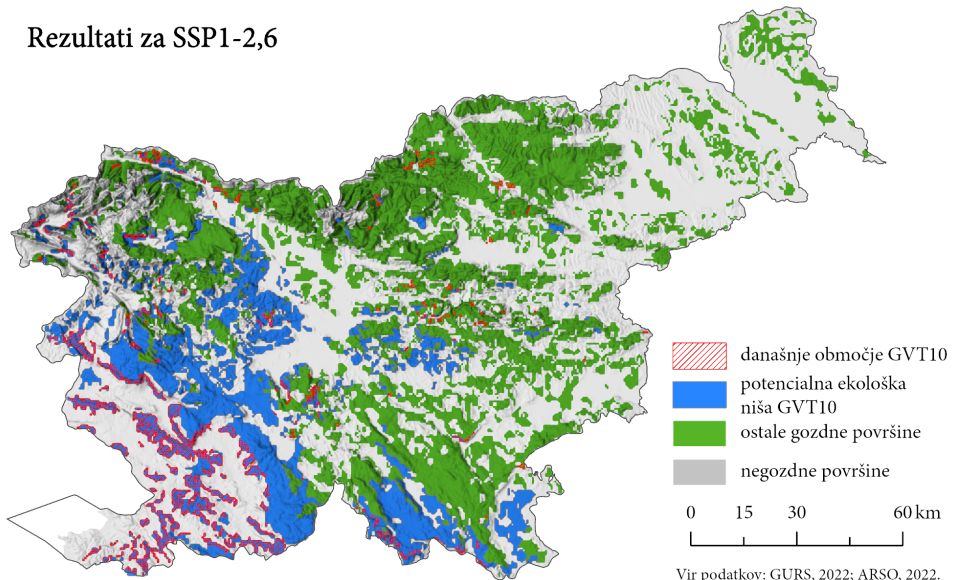
Slika 6: Krivulji ROC za GVT10.



Avtor: Tim Gregorčič, 2022.


Slika 7: Prostorski rezultati modeliranja potencialne ekološke niše za GVT10.

Rezultati za SSP1-2,6



Vir podatkov: GURS, 2022; ARSO, 2022.
Kartografija in oblikovanje: Tim Gregorčič, Ljubljana, 2022.

Rezultati za SSP5-8,5



Vir podatkov: GURS, 2022; ARSO, 2022.
Kartografija in oblikovanje: Tim Gregorčič, Ljubljana, 2022.

5 RAZPRAVA IN ZAKLJUČEK

Metoda maksimalne entropije in programsko orodje Maxent sta do sedaj že bila nekajkrat uporabljena za proučevanje različnih pojavov na območju Slovenije. Kuralt (2016) je modeliral potencialno razširjenost pajka črne vdove (*Latrodectus tredecimguttatus*) glede na različne podnebne scenarije RCP. Kalan in sod. (2017) so Maxent uporabili za modeliranje potencialnih arealov invazivnih tigrastih komarjev (*Aedes albopictus*) in invazivnih japonskih komarjev (*Aedes japonicus japonicus*). To je sicer metodološko lahko sporno, saj vrsti zaradi svoje invazivnosti še nista v dinamičnem ravnovesju, kar je ena od predpostavk modeliranja razširjenosti vrst oz. ekoloških niš. Šet (2019) je metodo uporabil za modeliranje razširjenosti kriptičnih vrst rodu *Niphargus* v današnjih podnebnih pogojih. Enako tudi Knez (2020), ki je modelirala potencialne habitate za naselitev evropskega bizona (*Bison bonasus*) v Sloveniji.

V našem primeru se uporaba maksimalne entropije in Maxenta razlikuje od pristopov omenjenih avtorjev po namenu in metodologiji. Modeliranje s programskim orodjem Maxent smo prvič uporabili za proučevanje potencialnih vplivov podnebnih sprememb na slovenske gozdove. Prvič smo uporabili tudi podnebne scenarije imenovane »smeri skupnega družbenogospodarskega razvoja«. Z metodološkega vidika se naša raziskava od omenjenih študij bistveno razlikuje v tem, da nismo modelirali potencialnih vplivov na en GVT, kot so ostali avtorji to počeli zgolj za eno živalsko vrsto. Metodo smo uporabili za modeliranje trinajstih GVT, s čimer se je porodila potreba po drugačnem pristopu določevanja končnih ekoloških niš glede na verjetnost prisotnosti. Pri modeliranju ene vrste je treba namreč zgolj določiti prag sprejemljive verjetnosti prisotnosti glede na določene predpostavke.

Glede na statistične rezultate modeliranja ocenjujemo, da je metoda maksimalne entropije za proučevanje vpliva podnebnih sprememb primerna in učinkovita. Kljub rezultatom, ki to potrjujejo, moramo opozoriti, da je njihova dejanska kakovost odvisna od kakovosti vhodnih podatkov. Tudi s pomanjkljivimi vhodnimi podatki lahko metoda doseže dobre rezultate, ki pa so do neke mere vprašljivi. Med razvojem metodologije smo veliko pozornosti namenili kakovostni pripravi vhodnih podatkov, a smo kljub temu naleteli na nekaj omejitvenih dejavnikov, ki so preprečevali še kakovostnejšo pripravo. Prvi se nanaša na mrežo temperaturnih merilnih mest, ki je bila mnogo redkejša od mreže merilnih mest količine padavin. Ob večjem številu merilnih mest bi lahko izvedli natančnejše interpolacije, ki bi imele manj napak, čeprav se jim nikoli ne bi mogli popolnoma izogniti. Poleg tega smo za ustvarjanje podnebnih slojev izbrali metodo, ki velja za relativno preprosto. Z izborom kompleksnejših metod bi prišli tudi do točnejših rezultatov (Di Piazza in sod., 2011; Viggiano in sod., 2019).

Zavedamo se tudi, da v modeliranje niso bili vključeni vsi vplivi, ki bodo (lahko) vplivali na slovenske gozdove v prihodnosti. Nekatere pomembne neodvisne spremenljivke smo izpustili načrtno, saj smo njihov vpliv primerno metodološko nadomestili. To velja za ekspozičijo in naklon površja, ki sta pomembna rastiščna dejavnika. Teh dveh neodvisnih spremenljivk v modeliranje nismo vključili, ker izračun

insolacije, katerega rezultati so bili uporabljeni za izdelavo temperaturnih slojev, že vključuje naklon in ekspozicijo površja. Nekateri podatkovni sloji, ki bi jih sicer morali nujno vključiti v modeliranje (npr. spremembe vlažnosti prsti glede na podnebne scenarije, globina prsti, vsebnost organske snovi v prsteh, vpliv prihodnjih podnebnih razmer na stopnjo razkroja in kroženja organske snovi, vodna kapaciteta prsti itd.), ne obstajajo ali pa niso dostopni. Poleg tega obstajajo tudi vplivi, ki bodo ob intenzifikaciji podnebnih sprememb nedvomno vplivali na slovenske gozdove, a jih metoda ne more vključiti. To so ekstremni vremenski pojavi, pojav novih škodljivcev in razširjanje obstoječih itd. Zavedamo se tudi, da človek tako kompleksnih naravnih sistemov najverjetneje nikoli ne bo docela razumel in povsem verodostojno modeliral, zato je v metodologijo nemogoče vključiti vse dejavnike, ki vplivajo na razširjanje slovenskih gozdov danes ali v prihodnosti.

Dodatna pomanjkljivost se nanaša tudi na vhodne podatke o prisotnosti GVT. Podatkov o gozdni vegetaciji v nekajdesetkilometrskem pasu zunaj državne meje nismo imeli na voljo, zato smo v modeliranje naravnih procesov umestili mejo, ki v resnici ne obstaja. Za predele ob severni meji Slovenija to sicer ne velja, saj karavanški gorski grebeni dejansko predstavljajo tudi očitno vegetacijsko pregrado in ločnico.

Priiložnosti nadaljnega razvoja metodologije za proučevanje potencialnih vplivov podnebnih sprememb na slovenske gozdove tako vidimo v izboljšanju prostorske natančnosti in točnosti vhodnih podatkov, dodatni identifikaciji in vključitvi relevantnih neodvisnih spremenljivk in v testiranju drugih orodij za modeliranje ekoloških niš, ki bi lahko privedla do novih spoznanj o potencialnih smereh razvoja ekoloških niš GVT v prihodnosti.

Literatura in viri

- Araujo, M. B., Pearson, R. G., Thuillers, W., Erhard, M., 2005. Validation of species–climate impact models under climate change. *Global Change Biology*, 11, 9, str. 1504–1513. DOI: 10.1111/j.1365-2486.2005.01000.x.
- ARSO [Agencija Republike Slovenije za okolje], 2006. Vodna telesa površinskih voda (linija). URL: http://gis.arso.gov.si/evode/profile.aspx?id=atlas_voda_Lidar@Arso&culture=en-US (citirano 27. 7. 2022).
- ARSO [Agencija Republike Slovenije za okolje], 2013. Digitalni model višin. URL: http://gis.arso.gov.si/evode/profile.aspx?id=atlas_voda_Lidar@Arso&culture=en-US (citirano 27. 7. 2022).
- ARSO, 2022. Podatki o količini padavin, povprečnih mesečnih temperaturah, povprečnih mesečnih minimalnih temperaturah in povprečnih mesečnih maksimalnih temperaturah (interni vir, 27. 7. 2022). Ljubljana.
- Attorre, F., Alfo, M., De Scantis, M., Francesconi, F., Bruno, F., 2007. Comparison of interpolation methods for mapping climatic and bioclimatic variables at regional

- scale. *International Journal of Climatology*, 27, 13, str. 1825–1843. DOI: 10.1002/joc.1495.
- Barbet-Massin, M., Jiguet, F., Albert, C. H., Thuiller, W., 2012. Selecting pseudo-absences for species distribution models: how, where and how many? *Methods in Ecology and Evolution*, 3, 2, str. 327–338. DOI: 10.1111/j.2041-210X.2011.00172.x.
- Bertalanič, M., Dolinar, M., Draskler, A., Honzak, L., Kobold, M., Kozjek, K., Lokošek, N., Medved, A., Vertačnik, G., Vlahovič, Ž., Žust, A., 2018. Ocena podnebnih sprememb v Sloveniji do konca 21. stoletja. Sintezno poročilo – prvi del. Ljubljana: Ministrstvo za okolje in prostor. URL: <http://meteo.arso.gov.si/met/sl/climate/change/> (citirano 21. 7. 2022).
- Bončina, A., Rozman, A., Dakskobler, I., Klopčič, M., Babij, V., Poljanec, A., 2021. Gozdni rastiščni tipi Slovenije. Vegetacijske, sestojne in upravljaljske značilnosti. Ljubljana: Oddelek za gozdarstvo in obnovljive gozdne vire, Biotehniška fakulteta Univerze v Ljubljani in Zavod za gozdove Slovenije.
- Brown, J. L., 2014. SDMtoolbox: a python-based GIS toolkit for landscape genetic, biogeographic and species distribution model analyses. *Methods in Ecology Evolution*, 5, 7, str. 694–700. DOI: 10.1111/2041-210X.12200.
- CEDA [Centre of Environmental Data Analysis], 2021. Summary for Policymakers of the Working Group I Contribution to the IPCC Sixth Assessment Report. URL: <https://catalogue.ceda.ac.uk/uuid/ae4f1eb6fce24adc92ddca1a7838a5c> (citirano 21. 7. 2022).
- Chen, D., Rojas, M., Samset, B. H., Cobb, K., Diongue Niang, A., Edwards, P., Emori, S., Faria, S. H., Hawkins, E., Hope, P., Huybrechts, P., Meinshausen, M., Mustafa, S. K., Plattner, K. K., 2021. Framing, Context, and Methods. In *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. V: Masson-Delmotte, V., Zhai, P., Pirani, A., Connors, S. L., Péan, C., Berger, S., Caud, N., Chen, Y., Goldfarb, L., Gomis, M. I., Huang, M., Leitzell, K., Lonnoy, E., Matthews, J. B. R., Maycock, T. K., Waterfield, T., Yelekçi, O., Yu, R., Zhou, B. (ur.). IPCC, 2021: *Climate change 2021: The physical science basis. Contribution of Working Group I to the Sixth assessment report of the Intergovernmental Panel on Climate Change*. Cambridge, New York: Cambridge University Press, str. 553-672. DOI: 10.1017/9781009157896.003.
- Chen, D., Rojas, M., Samset, H., Cobb, K., Diongue Niang, A., Edwards, P., Emori, S., Faria, S. H., Hawkins, E., Hope, P., Huybrechts, P., Meinshausen, M., Mustafa, S. K., Plattner, G. K., Treguier, A. M., 2021. Framing, context, and methods. *Climate change 2021: The physical science basis. Contribution of Working Group I to the Sixth assessment report of the Intergovernmental Panel on Climate Change (copy-editing version)*. Cambridge in New York: Cambridge University Press. URL: <https://www.ipcc.ch/report/sixth-assessment-report-working-group-i/> (citirano 2. 7. 2022).

- Crutzen, P. J., Stoermer, E. F., 2000. The »Anthropocene«. *Global Change Newsletters*, 41, str. 17–18. URL: <http://www.igbp.net/download/18.316f18321323470177580001401/1376383088452/NL41.pdf> (citirano 2. 7. 2022).
- Daddi, T., Bleischwitz, R., Todaro, N.M., Gusmerotti, N. M., De Giacomo, M. R., 2020. The influence of institutional pressures on climate mitigation and adaptation strategies. *Journal of Cleaner Production*, 244, str. 1–9. DOI: 10.1016/j.jclepro.2019.118879.
- De Marco, P., Felizola Dinis-Filho, J. A., Bini, L. M., 2008. Spatial analysis improves species distribution modelling during range expansion. *Biology Letters*, 4, 5, str. 576–580. DOI: 10.1098/rsbl.2008.0210.
- DellaSala, D. A., Goldstein, M. I., Elias, S. A., Jennings, B., Lacher Jr., T. E., Mineau, P., Pyare, S., 2018. The anthropocene: How the great acceleration is transforming the planet at unprecedented levels. *Encyclopedia of the Anthropocene*, 1, str. 1-7. DOI: 10.1016/B978-0-12-809665-9.09957-2.
- Di Piazza, A., Lo Conti, F., Noto, L. V., Viola, F., La Loggia, G., 2011. Comparative analysis of different techniques for spatial interpolation of rainfall data to create a serially complete monthly time series of precipitation for Sicily, Italy. *International Journal of Applied Earth Observation and Geoinformation*, 13, 3, str. 396–408. DOI: 10.1016/j.jag.2011.01.005.
- Dormann, C. F., 2006. Promising the future? Global change projections of species distributions. *Basic and Applied Ecology*, 8, 5, str. 387–397. DOI: 10.1016/j.baae.2006.11.001.
- Du, Z., He, Y., Wang, H., Wang, C., Duan, Y., 2021. Potential geographical distribution and habitat shift of the genus *Ammopiptanthus* in China under current and future climate change based on the MaxEnt model. *Journal of Arid Environments*, 184, str. 1–9. DOI: 10.1016/j.jaridenv.2020.104328.
- Elith, J., Franklin, J., 2013. Species distribution modeling. V: Levin, S. A. (ur.). *Encyclopedia of biodiversity*, second edition. Cambridge: Academic Press, str. 692–705. URL: DOI: 10.1016/B978-0-12-384719-5.00318-X.
- Elith, J., Leathwick, J. R., 2009. Species distribution models: Ecological explanation and prediction across space and time. *Annual Review of Ecology, Evolution, and Systematics*, 40, str. 677–697. DOI: 10.1146/annurev.ecolsys.110308.120159.
- Ellis, E. C., 2019. Evolution: Biodiversity in the anthropocene. *Current Biology*, 29, 19, str. 831–833. DOI: 10.1016/j.cub.2019.07.073.
- Fernandez-Granja, J. A., Casanueva, A., Bedia, J., Fernandez, J., 2021. Improved atmospheric circulation over Europe by the new generation of CMIP6 earth system models. *Climate Dynamics*, 56, 11, str. 3527–3540. DOI: 10.1007/s00382-021-05652-9.
- Fick, S. E., Hijmans, R. J., 2017. WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas. *International Journal of Climatology*, 37, 12, str. 4302–4315. DOI: 10.1002/joc.5086.

- Forster, P., Storelvmo, T., Armour, K., Collins, W., Dufresne, J. -L., Frame, D., Lunt, D. J., Mauritsen, T., Palmer, M. D., Watanabe, M., Wild, M., Zhang, H., 2021. The Earth's Energy Budget, Climate Feedbacks, and Climate Sensitivity. V: Masson-Delmotte, V., Zhai, P., Pirani, A., Connors, S. L., Péan, C., Berger, S., Caud, N., Chen, Y., Goldfarb, L., Gomis, M. I., Huang, M., Leitzell, K., Lonnoy, E., Matthews, J. B. R., Maycock, T. K., Waterfield, T., Yelekçi, O., Yu, R., Zhou, B. (ur.). IPCC, 2021: Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge, New York: Cambridge University Press, str. 553-672. DOI: 10.1017/9781009157896.009.
- Geografski terminološki slovar, 2021. URL: <https://fran.si/148/geografski-terminoloski-slovar> (citirano 7. 7. 2022).
- Guisan, A., Thuiller, W., Zimmermann, N. E., 2017. Habitat suitability and distribution models. With applications in R. Cambridge: Cambridge University Press. DOI: 10.1017/9781139028271.
- GURS [Geodetska uprava Republike Slovenije], 2006. Evidenca državne meje. URL: <https://eprostor.gov.si/imps/srv/slv/catalog.search#/metadata/2270f9a6-178c-4a0e-989a-1b530b496722> (citirano 27. 7. 2022).
- IPCC, 2014. Climate change 2014: Synthesis report. Ženeva, IPCC. URL: <https://www.ipcc.ch/report/ar5/syr/> (citirano 7. 7. 2022).
- Jamal, Z. A., Abou-Shaara, H. F., Qamer, S., Alotaibi, M. A., Ali Khan, K., Fiaz Khan, M., Bashir, M. A., Hannan, A., AL-Kahtani, S. N., Taha, E. A., Anjum, S. I., Attaullah, M., Raza, G., Ansari, M J., 2021. Future expansion of small hive beetles, *Aethina tumida*, towards North Africa and South Europe based on temperature factors using maximum entropy algorithm. *Journal of King Saud University – Science*, 33, 1, str. 1–7. DOI: 10.1016/j.jksus.2020.101242.
- Jaynes E. T., 1957. Information theory and statistical mechanics. II. *Physical Review*, 108, 2, str. 171–190. DOI: 10.1103/PhysRev.108.171.
- Jouzel, J., Masson-Delmotte, V., Cattani, O., Dreyfus, G., Falourd, S., Hoffmann, G., Minster, B., Nouet, J., Barnola, J. M., Chappellaz, J., Fischer, H., Gallet, J. C., Johnsen, S., Leuenberger, M., Loulergue, L., Luethi, D., Oerter, H., Parrenin, F., Raisbeck, G., Raynaud, D., Schilt, A., Schwander, J., Selmo, E., Souchez, R., Spahni, R., Stauffer, B., Steffensen, J. P., Stenni, B., Stocker, T. F., Tison, J. L., Werner, M., Wolff, E. W., 2007. Orbital and millennial antarctic climate variability over the past 800,000 years. *Science*, 317, 5839, str. 793–796. DOI: 10.1126/science.1141038.
- Kalan, K., Ivović, V., Glasnović, P., Buzan, E., 2017. Presence and potential distribution of *Aedes albopictus* and *Aedes japonicus japonicus* (Diptera: Culicidae) in Slovenia. *Journal of Medical Etymology*, 54, 6, str. 1510 – 1518. DOI: 10.1093/jme/tjx150.
- Knez, N., 2021. Določanje potencialnih habitatov za naselitev evropskega bizona v Sloveniji. Ljubljana: Univerza v Ljubljani. URL: <https://repozitorij.uni-lj.si/IzpisGradiva.php?id=116930&lang=slv> (citirano 20. 7. 2022).

- Košir, Ž., Zorn Pogorelc, M., Kalan, J., Marinček, L., Smole, I., Čampa, L., Šolar, M., Anko, B., Accetto, B., Robič, D., Toman, V., Žgajnar, L., Torelli, N., 1974. Gozdnovegetacijska karta Slovenije, M 1 : 100.000. Ljubljana: Biro za gozdarsko načrtovanje.
- Košir, Ž., Zorn Pogorelc, M., Kalan, J., Marinček, L., Smole, I., Čampa, L., Šolar, M., Anko, B., Accetto, B., Robič, D., Toman, V., Žgajnar, L., Torelli, N., Tavčar, I., Kutnar, L., Kralj, A., Skudnik, M., Kobal, M., 2007. Gozdnovegetacijska karta Slovenije. Ljubljana (digitalna verzija). Biro za gozdarsko načrtovanje, Gozdarski inštitut Slovenije.
- Kuralt, Ž., 2016. Bioklimatski model potencialne razširjenosti črne vdove (*Latrodectus tredecimguttatus*): magistrsko delo, magistrski študij - 2. stopnja. Ljubljana: Univerza v Ljubljani. URL: <https://repozitorij.uni-lj.si/IzpisGradiva.php?id=123483&lang=slv> (citirano 20. 7. 2022).
- Kutnar, L., Kobler, A., Bergant, K., 2009. Vpliv podnebnih sprememb na pričakovano prostorsko prerezporeditev tipov gozdne vegetacije. Zbornik gozdarstva in lesarstva, 89, str. 33–42. URL: <https://www.dlib.si/details/URN:NBN:SI:DOC-LU9Q-BI8H/> (citirano 12. 7. 2022).
- Lee, J., -Y., Marotzake, J., Bala, G., Cao, L., Corti, S., Dunne, J. P., Engelbrecht, F., Fischer, E., Eyfe, J. C., Jones, C., Maycock, A., Mutemi, J., Ndiaye, O., Panickal, S., Zhou, T., 2021. Future Global Climate: Scenario-Based Projections and Near-Term Information. In *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. V: Masson-Delmotte, V., Zhai, P., Pirani, A., Connors, S. L., Péan, C., Berger, S., Caud, N., Chen, Y., Goldfarb, L., Gomis, M. I., Huang, M., Leitzell, K., Lonnoy, E., Matthews, J. B. R., Maycock, T. K., Waterfield, T., Yelekçi, O., Yu, R., Zhou, B. (ur.). IPCC, 2021: *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge, New York: Cambridge University Press, str. 553-672. DOI: 10.1017/9781009157896.006.
- Leichenko, R., O'Brien, K., 2020. Teaching climate change in the Anthropocene: An integrative approach. *Anthropocene*, 30, 100241. DOI: 10.1016/j.ance.2020.100241.
- Mach, K. J., Planton, S., von Stechow, C., 2014. IPCC, 2014: Annex II: Glossary. V: Core writing team, Pachauri, R. K., Meyer, L. A. *Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Geneva: IPCC, str. 117-130. URL: <https://www.ipcc.ch/report/ar5/syr/> (citirano 17. 10. 2022).
- MacKey, B. G., Lindenmayer, D. B., 2001. Towards a hierarchical framework for modelling the spatial distribution of animals. *Journal of Biogeography*, 28, 9, str. 1147–1166. URL: <https://www.jstor.org/stable/827505> (citirano 12. 7. 2022).
- Mathez, E. A., Smerdon, J. E., 2018. *Climate change: the science of global warming and our energy future*. Druga izdaja. New York: Columbia University Press. URL:

- <http://search.ebscohost.com.nukweb.nuk.uni-lj.si/login.aspx?direct=true&db=nlebk&AN=1905399&site=ehost-live> (citirano 2. 7. 2022).
- Merow, C., Smith, M. J., Silander, J. A., 2013. A practical guide to MaxEnt for modeling species' distributions: what it does, and why inputs and settings matter. *Ecography*, 36, 10, str. 1058–1069. DOI: 10.1111/j.1600-0587.2013.07872.x.
- Miller, J., 2010. Species distribution modeling. *Geography Compass*, 4, 6, str. 490–509. DOI: 10.1111/j.1749-8198.2010.00351.x.
- MKGP [Ministrstvo za kmetijstvo, gozdarstvo in prehrano], 2007. Grafični in pisni podatki Pedološke karte in pedoloških profilov. URL: <https://rkg.gov.si/vstop/> (citirano 27. 7. 2022).
- Ngarega, B. K., Masocha, V. F., Schneider, H., 2021. Forecasting the effects of bioclimatic characteristics and climate change on the potential distribution of *Colophospermum mopane* in southern Africa using Maximum Entropy (Maxent). *Ecological Informatics*, 65, str. 1 – 11. DOI: 10.1016/j.ecoinf.2021.101419.
- Ninyerola, M., Pons, X., Roure, J. M., 2000. A Methodological approach of climatological modelling of air temperature and precipitation through GIS techniques. *International Journal of Climatology*, 20, 14, str. 1823–1841. DOI: 10.1002/1097-0088(20001130)20:14<1823::AID-JOC566>3.0.CO;2-B.
- Ninyerola, M., Pons, X., Roure, J. M., 2007. Objective air temperature mapping for the Iberian Peninsula using spatial interpolation and GIS. *International Journal of Climatology*, 27, 9, str. 1231–1242. DOI: 10.1002/joc.1462.
- O'Donnell, M. S., Ignizio, D. A., 2012. Bioclimatic predictors for supporting ecological applications in the conterminous United States. *USGS Data Series*, 691, str. 1–17. URL: <https://pubs.usgs.gov/ds/691/> (citirano 27. 7. 2022).
- Ogrin, D., 2005. Spreminjanje podnebja v holocenu. *Geografski vestnik*, 77, 1, str. 57–66. URL: https://www.researchgate.net/publication/251381731_SPREMINJANJE_PODNEBJA_V_HOLOCENU (citirano 2. 7. 2022).
- Ogrin, D., Plut, D., 2012. Aplikativna fizična geografija Slovenije. 2. izdaja. Ljubljana: Znanstvena založba Filozofske fakultete.
- OZN [Organizacija združenih narodov], 1992. United Nations Framework Convention on Climate Change, Article 1. URL: https://unfccc.int/files/essential_background/background_publications_htmlpdf/application/pdf/conveng.pdf (citirano 2. 7. 2022).
- Penfield, P., 2013. Chapter 9: Principle of maximum entropy. URL: <https://mtlsites.mit.edu/Courses/6.050/2013/notes/index.html> (citirano 9. 7. 2022).
- Phillips, S. J., 2017. A Brief Tutorial on Maxent. American Museum of Natural History. URL: https://biodiversityinformatics.amnh.org/open_source/maxent/ (citirano 12. 7. 2022).
- Phillips, S. J., Anderson, R. P., Schapire, R. E., 2006. Maximum entropy modeling of species geographic distributions. *Ecological Modelling*, 190, 3-4, str. 231–259. DOI: 10.1016/j.ecolmodel.2005.03.026.

- Phillips, S. J., Dudik, M., Schapire, R. E., 2004. A maximum entropy approach to species distribution modeling. *ICML '04: Proceedings of the twenty-first international conference on Machine learning*, str. 1–8. DOI: 10.1145/1015330.1015412.
- Poggio, L., Simonetti, E., Gimona, A., 2018. Enhancing the WorldClim data set for national and regional applications. *Science of the Total Environment*, 625, str. 1628–1643. DOI: 10.1016/j.scitotenv.2017.12.258.
- Portilla Cabrera, C. V., Selvaraj, J. J., 2020. Geographic shifts in the bioclimatic suitability for *Aedes aegypti* under climate change scenarios in Colombia. *Heliyon*, 6, 1, str. 1–13. DOI: 10.1016/j.heliyon.2019.e03101.
- Repe, B., 2010. Prepoznavanje osnovnih prsti slovenske klasifikacije. *Dela*, 34, str. 143–166. DOI: 10.4312/dela.34.143-166.
- Results of binding vote by AWG Released 21st May 2019. URL: <http://quaternary.stratigraphy.org/working-groups/anthropocene/> (citirano 2. 7. 2022).
- Riahi, K., van Vuuren, D. P., Kriegler, E., Edmonds, J., O'Neill, B. C., Fujimori, S., Bauer, N., Calvin, K., Dellink, R., Fricko, O., Lutz, W., Popp, A., Cuaresma, J. C., Samir, K. C., Leimbach, M., Jiang, L., Kram, T., Rao, S., Emmerling, J., Ebi, K., Hasegawa, T., Havlik, P., Humpenoder, F., Da Silva, L. A., Smith, S., Stehfest, E., Bosetti, V., Eom, J., Gernaat, D., Masui, T., Rogelj, J., Strefler, J., Drouet, L., Krey, V., Luderer, G., Harmsen, M., Takahashi, K., Baumstark, L., Doelman, J. C., Kainuma, M., Klimont, Z., Marangoni, G., Lotze-Campen, H., Obersteiner, M., Tabeau, A., Tavoni, M., 2017. The Shared Socioeconomic Pathways and their energy, land use, and greenhouse gas emissions implications: An overview. *Global Environmental Change*, 42, str. 153–168. DOI: 10.1016/j.gloenvcha.2016.05.009.
- Saha, A., Rahman, S., Alam, S., 2021. Modeling current and future potential distributions of desert locust *Schistocerca gregaria* (Forskål) under climate change scenarios using MaxEnt. *Journal of Asia-Pacific Biodiversity*, 14, 3, str. 399–409. DOI: 10.1016/j.japb.2021.05.001.
- Séférian, R., Nabat, P., Michou, M., Saint-Martin, D., Voldoire, A., Colin, J., Decharme, B., Delire, C., Barhet, S., Chevallier, M., Senesi, S., Franchisteguy, L., Vial, J., Mallet, M., Joetzjer, E., Geffroy, O., Gueremy, J. F., Moine, M. P., Msadek, R., Ribes, A., Rocher, M., Roehrig, R., Salas-y-Melia, D., Sanchez, E., Terray, L., Valcke, S., Waldman, R., Aumont, O., Bopp, L., Deshayes, J., Ethe, C., Madec, G., 2019. Evaluation of CNRM Earth System Model, CNRM-ESM2-1: Role of Earth System Processes in Present-Day and Future Climate. *Journal of Advances in Modeling Earth Systems*, 11, 12, str. 4182–4227. DOI: 10.1029/2019MS001791.
- Sinclair, S. J., White, M. D., Newell, G. R., 2010. How useful are species distribution models for managing biodiversity under future climates? *Ecology and Society*, 15, 1, str. 1–13. DOI: 10.5751/ES-03089-150108.
- Sun, X., Long, Z., Jia, J., 2021. A multi-scale Maxent approach to model habitat suitability for the giant pandas in the Qionglai mountain, China. *Global Ecology and Conservation*, 32, str. 1–12. DOI: 10.1016/j.gecco.2021.e01766.

- Šet, J., 2019. Analiza razširjenosti morfološko kriptičnih vrst rodu *Niphargus*. Ljubljana: Univerza v Ljubljani. URL: <https://repozitorij.uni-lj.si/IzpisGradiva.php?id=113166&lang=slv> (citirano 20. 7. 2022).
- Taylor, K. E., Stouffer, R. J., Meehl, G. A., 2012. An overview of CMIP5 and the experiment design. *Bulletin of the American Meteorological Society*, 93, 4, str. 485–498. DOI: 10.1175/BAMS-D-11-00094.1.
- Townsend Peterson, A., Soberon, J., 2012. Species distribution modeling and ecological niche modeling: Getting the concepts right. *Natureza & Conservação*, 10, 2, str. 1–6. URL: <https://abeco.org.br/edicoes/volume-10> (citirano 28. 9. 2021).
- Viggiano, M., Busetto, L., Ciminia, D., Di Paola, F., Geraldia, E., Ranghetti, L., Ricciardella, E., Romano, F., 2019. A new spatial modeling and interpolation approach for high-resolution temperature maps combining reanalysis data and ground measurements. *Agricultural and Forest Meteorology*, 276–277, str. 1–17. DOI: 10.1016/j.agrformet.2019.05.021.
- Web of Science. URL: <https://clarivate.com/webofsciencegroup/solutions/web-of-science/> (citirano 9. 7. 2022).
- Wu, T., Lu, Y., Fang, Y., Xin, X., Li, L., Li, W., Jie, W., Zhang, J., Liu, Y., Zhang, L., Zhang, F., Wu, F., Li, J., Chu, M., Wang, Z., Shi, X., Liu, X., Wei, M., Huang, A., Zhang, Y., Liu, X., 2019. The Beijing Climate Center Climate System Model (BCC-CSM): the main progress from CMIP5 to CMIP6. *Geoscientific Model Development*, 12, 4, str. 1573–1600. DOI: 10.5194/gmd-12-1573-2019.
- Zeng, J., Li, C., Liu, C., Li, Y., Hu, Z., He, M., Zhang, H., Yan, H., 2021. Ecological assessment of current and future *Pogostemon cablin* Benth. potential planting regions in China based on MaxEnt and ArcGIS models. *Journal of Applied Research on Medicinal and Aromatic Plants*, 24, str. 1–9. DOI: 10.1016/j.jarmap.2021.100308.
- Zhao, G., Cui, X., Sun, J., Li, T., Wang, Q., Ye, X., Fan, B., 2021. Analysis of the distribution pattern of Chinese *Ziziphus jujuba* under climate change based on optimized biomod2 and MaxEnt models. *Ecological Indicators*, 132, str. 1–11. DOI: 10.1016/j.ecolind.2021.108256.
- Zhao, Y., Deng, X., Xiang, W., Chen, L., Ouyang, S., 2021. Predicting potential suitable habitats of Chinese fir under current and future climatic scenarios based on Maxent model. *Ecological Informatics*, 64, str. 1–10. DOI: 10.1016/j.ecoinf.2021.101393.

PREDICTING POTENTIAL CLIMATE CHANGE IMPACTS ON SLOVENIAN FORESTS USING THE MAXIMUM ENTROPY METHOD

Summary

The earth's climate has changed in the course of the earth's history through the transitions into ice ages and interglacial periods until today (Ogrin, 2005). Today, the climate is also changing (Bertalanič et al., 2018), but there is scientific consensus that humans are responsible for these changes for the first time in Earth's history due to the massive greenhouse gas (GHG) emissions they cause. The two most problematic GHGs are CO₂ and CH₄ respectively, which in combination with other GHGs contribute to the Earth's positive effective radiative forcing, leading to higher global temperatures, altered precipitation characteristics, more extreme weather events, etc. (Lee et al., 2021). From the perspective of climate change mitigation and adaptation, many scientific disciplines are trying to figure out how climate change might affect different environmental and social systems on Earth (Daddi et al., 2020). In this scientific field, phytogeography plays an important role, as we can already consider climate change as a non-negligible ecological stressor for the biosphere, and Slovenia is no exception.

Slovenia is a densely forested country with relatively high forest vegetation diversity (Bončina et al., 2021; Kutnar, Kobler, Bergant, 2009). This should not be taken for granted, as climate change is also expected to alter the site conditions of Slovenian forests. These potential changes can be assessed through ecological niche modelling. The main objective of this study was to develop a methodology to investigate the potential impacts of climate change on Slovenian forests in the period between 2081 and 2100 using Maxent software based on maximum entropy principles (Phillips, Dudik, Schapire, 2004).

Following the latest IPCC report from 2021, we used 2 of 5 climate scenarios called Shared Socioeconomic Pathways (SSP), which are the successors to the RCP climate scenarios (Lee et al., 2021). They are named after the estimated effective radiative forcing at the end of the 21st century (SSP1-1.9, SSP1-2.6, SSP2-4.5, SSP3-7.0 and SSP5-8.5) and predict the increase in global average temperatures between 1.5 and 4.8° C compared to the period 1850–1900. The first scenario we chose SSP was SSP1-2.6. If realised, it is expected to increase global average temperature by 2.0° C (1.3–2.8° C) compared to the period 1850–1900 (Lee et al., 2021). This scenario is the most optimistic and at the same time the most realistic. It was chosen because we believe that society can achieve this goal by responding responsibly and collectively to this challenge, while SSP1-1.9, which is a goal of the Paris Agreement to limit the mean global temperature increase to 1.5° C, is no longer realistic (Forster et al., 2021). The second

SSP scenario chosen was SSP5-8.5, which, if realised, is expected to increase global mean temperature by 4.8° C (3.6–6.5° C) compared to the 1850-1900 period (Lee et al., 2021). Although today's trends indicate that we are unlikely to follow this destructive fossil fuel-based path of future development, we chose this scenario to find out how total climate deterioration could affect Slovenian forests.

We have obtained future climate data based on selected scenarios for 3 different Earth System Models (ESM). They were developed during the recent CMIP6 phase of climate model development. The first ESM, named CNRM-ESM2-1, was developed by CNRM – CERFACS, one of the European working groups (Séférian et al., 2019). The second ESM, named BCC-CSM2-MR, was developed by one of the Chinese groups (Wu et al., 2019). The results of this model have already proven useful for Maxent modelling in southern Europe, including Slovenia (Jamal et al., 2021). Kuralt (2016) also used the previous version of this model (BCC-CSM1-1 from CMIP5) for Maxent modelling of the potential distribution of the Mediterranean black widow (*Latrodectus tredecimguttatus*) in Slovenia. The third model we have chosen is called MIROC6. It was developed by the Japanese working group and is said to be one of the models that are well suited for predicting climate extremes in Europe (Fernandez-Granja in sod., 2021).

The Maxent software was introduced in 2004 (Phillips, Dudik, Schapire, 2004). It is freely available on the internet and is widely used for modelling ecological niches (Web of Science, 2022). The software requires 3 basic data sets for ecological niche modelling: species sample data, raster environmental layers (covariates) and future data for the same environmental layers. It is also advisable to include the bias file in the modelling process. For the species sample data, we divided the Slovenian forest areas into 13 forest vegetation types (Kutnar, Kobler, Bergant, 2009) and created random points. We used the following environmental criteria for the raster environmental layers and future data for the same environmental layers: soil pH, topographic wetness index (TWI), Euclidean distance to water bodies and 19 bioclimatic variables. We created all layers using GIS. The bioclimatic variables were downloaded from the WorldClim portal (Fick, Hijmans, 2017). We could not use these variables directly as they were available at a resolution of 2.5 arcmin, which was not suitable for our case as a more detailed data resolution was required. Therefore, we used several methodological approaches to improve the raster cell resolution to 500 m. We had adopted a combination of methods from Ninyerola, Ponsa in Roura (2000; 2007), Poggio, Simonetti and Gimona (2018) and then adapted them to Slovenian conditions. We also included bias files in our methodology. We created them using the Python-based SD-Mtoolbox library within ArcGIS Pro 2.9.0 (Brown, 2014). The methodology used is called Sample by Buffered MCP.

The basic output data can be divided into a statistical and a spatial part. In the statistical part, the two main output diagrams are “omission and predicted area” and “sensitivity vs. 1-specificity”. The second diagram shows ROC curves and AUC values.

AUC values Quality of results. After testing the methodology for all 13 forest vegetation types, we obtained excellent results for 4 of them ($AUC > 0.90$), good results for 6 of them ($0.90 > AUC > 0.80$) and satisfactory results for 3 of them ($0.80 > AUC > 0.70$). This shows that our methodology was developed appropriately. The separate spatial output results had to be additionally merged into one data set and generalised for visualisation.

(Translated by the authors)