

## KLOPNI MENINGOENCEFALITIS IN PODNEBNE SPREMEMBE V SLOVENIJI

### **Daša Donša**

Mag. biologije in ekologije z naravovarstvom, ast.  
Oddelek za biologijo  
Fakulteta za naravoslovje in matematiko  
Univerza v Mariboru  
Koroška cesta 160, SI2000 Maribor, Slovenija  
e-mail: dasa.donsa1@um.si

### **Veno Jaša Grujić**

Mag. biologije in ekologije z naravovarstvom, ast.  
Oddelek za razredni pouk in Oddelek za biologijo  
Pedagoška fakulteta in Fakulteta za naravoslovje in matematiko  
Koroška cesta 160, SI - 2000 Maribor  
e-mail: veno.grujic@um.si

### **Nataša Pipenbaher**

Dr., uni. dipl. inž. kmetijstva, doc.  
Oddelek za biologijo  
Fakulteta za naravoslovje in matematiko  
Univerza v Mariboru  
Koroška cesta 160, SI-2000 Maribor, Slovenija  
e-mail: natasa.pipenbaher@um.si

### **Danijel Ivajnsič**

Dr., profesor biologije in geografije, izr. prof.  
Oddelek za biologijo in Oddelek za geografijo  
Fakulteta za naravoslovje in matematiko in Filozofska fakulteta  
Univerza v Mariboru  
Koroška cesta 160, SI2000 Maribor, Slovenija  
e-mail: dani.ivajnsic@um.si

UDK: 616.995.42:551.583

COBISS: 1.01

### **Izvleček**

#### **Klopni meningoencefalitis in podnebne spremembe v Sloveniji**

Klopi imajo, kot vektorji nalezljivih bolezni, pomembno vlogo pri ogrožanju javnega zdravja. Slovenija je po registrirani incidenci klopnega meningoencefalitisa (KME) v svetovnem vrhu. Obravnavano bolezen prenaša vrsta gozdni klop (*Ixodes ricinus*). Abundanca in prostorska razširjenost gozdnih klopi je močno odvisna od biotskih in abiotskih dejavnikov. Posledično na prostorski odtis bolezni KME vplivajo tudi podnebne spremembe. Z implementacijo modelov regresijskih dreves in geografsko obtežene multiple regresije ter 246 prediktorskih spremenljivk razlagamo obstoječi (trenutne podnebne razmere) in bodoči (časovno okno 2070 in toplogredni scenarij RCP 8.5) vzorec žarišč bolezni KME na nivoju slovenskih občin. Kot končni produkt raziskave je izdelana še trenutna in bodoča ocena tveganja za okužbo s KME na kilometrski

mreži. Tovrstni rezultat lahko služi kot podporni prostorski informacijski sistem za obveščanje in preprečevanje okužbe z KME.

**Ključne besede**

Klopne bolezni, ocena tveganja, podnebne spremembe, prostorsko modeliranje.

**Abstract**

**Tick-borne encephalitis and climate change in Slovenia**

Ticks, as vectors of various infectious diseases, play an important role in endangering public health. Slovenia is one of the leading countries in terms of the registered incidence of tick-borne meningoencephalitis (TBE). TBE is transmitted by the castor bean tick species (*Ixodes ricinus*). Abundance and spatial distribution of this species is highly dependent on biotic and abiotic factors. As a result, the spatial footprint of TBE is also affected by climate change. With the application of regression tree and geographically weighted multiple regression models, including 246 predictor variables, we explain the existing (current climate conditions) and future (year 2070, according to RCP8.5 climate scenario) spatial pattern of TBE foci at the level of Slovenian municipalities. As a final product of the research, a current and future risk assessment for TBE infection on the grid of 1km<sup>2</sup> has been developed. Such results could be used as a supportive spatial information system for informing and preventing KME infection.

**Keywords**

Tick-borne diseases, risk assessment, climate change, spatial modelling.

## 1. Uvod

Klope klasificiramo kot specializirane obligatne krvosese iz podrazreda pršic (Acari), ki se kot ektoparaziti hranijo na sesalcih, pticah, plazilcih ter dvoživkah (Anderson & Magnarelli, 2008). So prenašalci širokega nabora bakterij, virusov ter parazitov, ki lahko pri človeku povzročajo resne zdravstvene težave (Heyman idr., 2010). Takoj za komarji, veljajo za najpomembnejše vektorje nalezljivih boleznih (Nava, 2009). Klope se s patogenim organizmom okuži med hranjenjem na okuženem gostitelju, nato pa povzročitelja bolezni prenese na svoje naslednje gostitelje (Anderson & Magnarelli, 2008). Z vidika pogostosti in tveganja za javno zdravje je najpomembnejša družina ščitastih klopov (Parola & Raoult, 2001) v katero spada gozdni klop (*Ixodes ricinus*), ki je v Evropi splošno razširjena vrsta (Rahlenbeck idr., 2016). Le-ta je, v primerjavi z drugimi vrstami, zelo občutljiv na temperaturo in vlago v okolju, prav tako so vse razvojne faze te vrste neodporne na izsušitev. Za uspešno iskanje gostiteljev in preživetje gozdni klopi potrebujejo vsaj 70–80 % relativne zračne vlage, zato se med prežanjem na gostitelja pogosto vračajo v nižje ležeče in bolj vlažne predele, kar jim omogoča rehidracijo (Hauser idr., 2018). Tako je prisotnost te vrste običajno omejena na listni opad in nižje rastočo vegetacijo v listopadnem ali mešanem gozdu. Na območjih z večjo količino padavin pa jih lahko najdemo tudi v iglastih gozdovih in odprtih rastiščih, kot so travniki in pašniki (Anderson & Magnarelli, 2008). Njihovi pomembni habitati so tudi gozdni rob, grmičevje, gozdne jase, ter parki in vrtovi (Rahlenbeck idr., 2016).

Gozdni klop je na območju Evrope glavni prenašalec pomembnih klopnih boleznih, kot sta lymfska boreliozna (LB) in klopni meningoencefalitis (KME) (Azagi idr., 2020).ocene kažejo, da je v Evropi z virusom KME okužene od 0,5 do 5 % populacije gozdnih klopov (Dumpis idr., 1999), pri čemer spada Slovenija med evropske države z najvišjo incidenco te bolezni (Bogovic, 2015). Danes je KME endemičen po skoraj vsej Sloveniji, po visokem številu okužb pa močno izstopata Gorenjska in Koroška statistična regija (Grgič-Vitek & Klavs, 2011).

Ker so klopi eksotermne živali spremembe okoljskih pogojev direktno vplivajo na njihov razvoj, vedenje ter populacijsko dinamiko. Posredno bodo spremembe podnebnih pogojev vplivale tudi na bolezni, ki jih klopi prenašajo, kar predstavlja dodatno grožnjo javnemu zdravju (Gage idr., 2008). V zadnjih desetletjih so se številne klopne bolezni na območju Severne Amerike in Evrazije močno razširile (Ostfeld & Brunner, 2015). Širjenje populacij klopov v višje nadmorske višine ter severnejše predele je že zabeleženo v Veliki Britaniji (Gilbert, 2010), Češki (Daniel idr., 2003), Norveški (Jore idr., 2011) in Švedski (Lindgren idr., 2000). Povečana incidenca ter prostorsko širjenje teh boleznih tako sovпада s trendi globalnega segrevanja (Ostfeld & Brunner, 2015).

Za boljše razumevanje prostorskega odtisa incidence KME smo v prispevku izdelali oceno tveganja za okužbo s KME tako v trenutnem časovnem okvirju kot za konec 21. stoletja. Zanimalo nas je, ali so v Sloveniji zaznavna značilna žarišča obolelih za KME, in ali lahko ta žarišča pojasnimo z uporabo okoljskih in demografskih posrednih kazalcev ter pristopom prostorskega modeliranja. Osrednji namen prispevka je bil tudi oceniti posreden vpliv podnebnih sprememb na prostorsko distribucijo KME v Sloveniji ter napovedati, katere slovenske regije bodo v prihodnosti najbolj izpostavljene potencialni okužbi s to boleznijo.

## 2. Metode dela

### 2.1 Odvisna spremenljivka

Za potrebe modelirana prostorskega vzorca KME v Sloveniji smo kot odvisno spremenljivko uporabili povprečno vrednost števila okužb s KME na občino v časovnem obdobju 2015-2018. Podatek o številu obolelih za KME smo pridobili z povpraševanjem pri zdravstvenem podatkovnem centru Statistične pisarne Nacionalnega inštituta za javno zdravje (NIJZ, 2014). Ker so občine v Sloveniji različnih prostorskih dimenzij in imajo različno število prebivalcev, smo povprečno vrednost odvisne spremenljivke normirali s povprečnim številom prebivalcev na nivoju občin. V nadaljnjih analizah smo uporabljali tako pridobljeno normirano vrednost števila okuženih s KME ( $Y_{KME}$ ) na občino.

### 2.2 Neodvisne spremenljivke

Kot neodvisne spremenljivke smo uporabili 246 različnih kazalcev, ki lahko posredno razlagajo razširjenost gozdnega klopa ter potencialno vplivajo na distribucijo klopnih bolezni.

Vektorski sloj za prikaz slovenskih občin in digitalni model reliefa (DMR) prostorske ločljivosti 25 m sta bila pridobljena iz spletne podatkovne baze E-Geodetski podatki (Ministrstvo za okolje in prostor, Geodetska uprava Republike Slovenije, 2020).

Da bi ocenili gostoto in prostorsko razporeditev vegetacije smo uporabili indeks NDVI (*ang. Normalized Difference Vegetation Index*), ki je bil za obdobje 2015-2018 pridobljen s spletne baze EarthData (NASA, 2020). Iz le-teh smo v okolju ArcMap (ESRI, 2020) v nadaljevanju izračunali povprečno vrednost, standardni odklon ter povprečni smerni koeficient linearnega trenda NDVI za omenjeno časovno obdobje. Za oceno posrednega učinka rabe tal na pojavljanje KME smo uporabili 12 nekoreliranih tipov rabe tal, ki opisujejo potencialni habitat gozdnega klopa (Priloga 1). Vektorski podatki rabe tal so bili pridobljeni iz slovenske podatkovne baze MKGP-Portal (Ministrstvo za kmetijstvo, gozdarstvo in prehrano, 2020) za leto 2017 ter iz evropske podatkovne baze Land Copernicus (Copernicus, 2020) za časovno okno 2018. Iz slednje smo za leto 2015 prenesli še spremenljivko, ki opisuje manjše lesne elemente v naravi (*ang. Small Woody Features*). Za nadaljnjo analizo smo uporabljali povprečno vrednost Evklidne razdalje posamezne rabe tal na občino, ki je bila izračunana v programskem okolju ArcMap (ESRI, 2020).

Naslednji sklop prediktorjev so predstavljali potencialni klopni gostitelji. Uporabili smo posredni kazalnik povozov živali, ki smo ga za obdobje 2010–2018 pridobili preko poizvedbe na Zavodu za gozdove Slovenije (Zavod za gozdove Slovenije, 2020). Vrste, ki lahko predstavljajo gostitelja navadnega klopa smo razdelili v 5 kategorij (ptice, glodavci, zveri, kopitarji in zajci). Za vsako kategorijo smo izračunali povprečje povozov v danem časovnem obdobju, ter podatke normirali glede na površino občine. Ker je za okužbo s KME potreben neposreden stik človeka s klopom, smo uporabili tudi izbrane socio-ekonomske prediktorje. Le-te smo pridobili iz podatkovne baze STAGE (Statistični urad Republike Slovenije, 2020), spletnega portala državne uprave GOV.SI (Republika Slovenija, 2020) in baze SiStat (Statistični urad Republike Slovenije, 2020). Izračunali smo povprečno število prebivalcev ter povprečno gostoto prebivalcev na občino v časovnem razponu 2015–2018. Uporabili smo tudi podatek o povprečnem številu prebivalcev, ki so dosegli višjo ali visokošolsko izobrazbo na

občino za časovno obdobje 2015–2017. Prav tako smo uporabili geometrijsko sredino indeksa staranja prebivalstva za časovni razpon 2015–2018 ter harmonično sredino koeficienta razvitosti občin za časovno okno 2015–2019. Za ocenitev vpliva gibanja prebivalstva na tveganje z okužbo s KME smo uporabili povprečno število prenočitev domačih turistov na občino za časovno obdobje 2015–2018, geometrijsko sredino indeksa delovne migracije za obdobje 2015–2018 ter vektorski podatek o cestnem omrežju.

Iz medmrežja CHELSA (CHELSA, 2020) smo pridobili prediktorje za recentne (1970–2013) ter bodoče (2050 in 2070) podnebne razmere. Da bi zaobjeli variabilnost napovedi bioklimatskih lastnosti v prihodnosti, smo uporabili podatke 5-tih značilno različnih globalnih podnebnih modelov za podnebni scenarij RCP8.5: HadGEM2-ES (*ang. Hadley Centre Global Environment Model version 2 – Earth System configuration*), CCSM4 (*ang. The Community Climate System Model 4*), MIROC-ESM (*ang. MIROC Earth System Model*), HadGEM2-CC (*ang. Hadley Centre Global Environment Model version 2 – low top configuration*) in MPI-ESM-LR (*ang. – The Coupled Max Planck Institute Earth System Model at base resolution*).

### 2.3 Prostorska analiza žarišč

Da bi ugotovili ali se visoke ali nizke vrednosti  $Y_{KME}$  v prostoru značilno združujejo v gruče, smo v programskem okolju ArcMap (ESRI, 2020) izvedli prostorsko analizo gruč in osamelcev ter prostorsko analizo žarišč. Pri tem so nas zanimala predvsem statistično značilna prostorska združevanja visokih vrednosti  $Y_{KME}$ , t.i. žarišča, saj je tam stopnja tveganja za okužbo z KME najvišja.

### 2.4 Pred-obdelava neodvisnih spremenljivk

V statističnem okolju R (R Core Team, 2020) smo izvedli korelacijsko analizo neodvisnih (prediktorskih) spremenljivk. Uporabili smo Spearmanov korelacijskih koeficient ( $r_s$ ). V nadaljevanju smo izločili vse močno pozitivno ( $r_s > 0,6$ ) ter močno negativno ( $r_s < 0,6$ ) korelirane spremenljivke, z izjemo digitalnega modela reliefa, NDVI, glavnih komponent podnebnih spremenljivk ter nekaterih tipov rabe tal. Omenjene izjeme so bile potrebne za modeliranje  $Y_{KME}$  v luči bodočih podnebnih sprememb. Ne glede na to, VIF vrednosti vseh izjem so bile pod kritično vrednostjo 5, kar opravičuje njihovo nadaljnjo uporabo v postopku modeliranja.

Da bi zmanjšali število podnebnih spremenljivk, vendar vseeno ohranili njihovo informacijsko moč, smo jih v okolju ArcMap (ESRI, 2020) transformirali z uporabo analize glavnih komponent. Za kalibracijo uporabljenih modelov smo uporabili povprečno vrednost prve in druge glavne komponente za posamezno občino, ki skupaj pojasnujeta 80 % variabilnosti bioklimatskih informacij. Enak metodološki pristop smo ponovili za vseh petih upoštevanih globalnih podnebnih modelov. V zaključni fazi smo nato izračunali povprečno vrednost prve in druge glavne komponente za vsa časovna okna (sedanjost, 2050 in 2070) za posamezno slovensko občino.

Korelirane prediktorje kategorije povozov živali smo, v okolju R (R Core Team, 2020), transformirali s pomočjo faktorjske analize. V nadaljnjih analizah smo uporabili le prva dva faktorja, ki pojasnita 50 % variabilnosti povozov kategorij živali. Enak pristop smo aplicirali tudi pri obravnavi močno koreliranih socio-ekonomskih prediktorjih. Tudi v tem primeru smo za potrebe modeliranja upoštevali prva dva faktorja, ki skupaj nalagata 63 % pojasnjene variabilnosti socio-ekonomskih kazalcev.

V končni obliki smo tako za modeliranje žarišč  $Y_{KME}$  obravnavali 24 nekoreliranih neodvisnih (prediktorskih) spremenljivk (Priloga 1).

## 2.5 Modeliranje

Glede na naravo odvisne spremenljivke ( $Y_{KME}$ ) in pripravljenih neodvisnih spremenljivk (prediktorjev) smo uporabili dva metodološka pristopa modeliranja (geografsko obtežena multipla regresija [ang. *Multivariate Geographically Weighted Regression; MGWR*] in model regresijskih dreves [ang. *Regression Tree Analysis; RT*]). Sprva smo oba modela ustrezno kalibrirali, nato pa za potrebe izračuna ocene tveganja oba povprečili. Model MGWR smo pripravili v programu MGWR 2.2 (Oshan idr., 2019), model RT pa v statističnem okolju R (R Core Team, 2020) z uporabo paketov rpart (Therneau idr., 2019), rpart.plot (Milborrow, 2020), caTools (Tuszynski, 2021) in tree (Ripley, 2019).

Za optimalno pripravo regresijskega drevesa smo vhodne podatke (212 občin) razdelili na: vzorec za učenje (ang. *training data*) (75 % občin) in poskusni vzorec (ang. *test data*) (preostalih 25 % občin). Na podlagi poskusnega vzorca smo razvili algoritem za napoved vrednost  $Y_{KME}$ . S slednjim smo nato napovedali vrednost  $Y_{KME}$  na vzorcu za učenje. Sledila je analiza kompleksnosti razvitega regresijskega drevesa z določitvijo optimalnega števila vozlišč, ki zagotavlja najmanjšo relativno napako napovedi.

Za validacijo in primerjavo kvalitete modelov smo izračunali Moranov indeks avtokorelacije standardiziranih ostankov. K temu smo dodali še naslednje kazalce kakovosti modelov: Moranov preizkus prostorske variabilnosti prediktorjev za model MGWR, pojasnjena varianca, povprečna absolutna napaka napovedi (ang. *Mean Absolute Error [MAE]*), korenjena povprečna absolutna napaka napovedi (ang. *Root Mean Square Error [RMSE]*) in popravljen Akaike informacijski kriterij (ang. *Corrected Akaike Information Criterion [AICc]*) (Priloga 2; Priloga 3).


## 2.6 Izboljševanje prostorske ločljivosti

Z metodo izboljševanja prostorske ločljivosti (ang. *downscaling*) smo, na podlagi razvitih algoritmov in značilnega doprinosa prediktorjev k posameznemu modelu, naše rezultate lahko prostorsko izboljšali. Pri tem smo bili omejeni s tematsko ločljivostjo najšibkejšega sloja (1. in 2. glavne bioklimatske komponente). Na ta način smo pripravili oceno tveganja za okužbo s KME na mreži 1 km<sup>2</sup>, s čimer smo znatno povečali aplikativno vrednost naše raziskave.

# 3. Rezultati

## 3.1 Prostorska analiza žarišč


Prostorska analiza žarišč je pokazala 3 statistično značilne združitve visokih vrednosti  $Y_{KME}$  oz. žarišča: prvo na območju jugovzhodne koroške in severovzhodne savinjske regije, drugo na južnem delu gorenjske regije ter tretjo na stičišču vzhodne primorsko-notranjske, jugovzhodne osrednjeslovenske in zahodne jugovzhodno slovenske regije. Nizke vrednosti pa se značilno ( $\alpha = 0,10$ ) gručijo le v občini Lenart (Podravska regija) (Slika 1).



Slika 1: Prostorska analiza žarišč Y<sub>KME</sub> v Sloveniji.

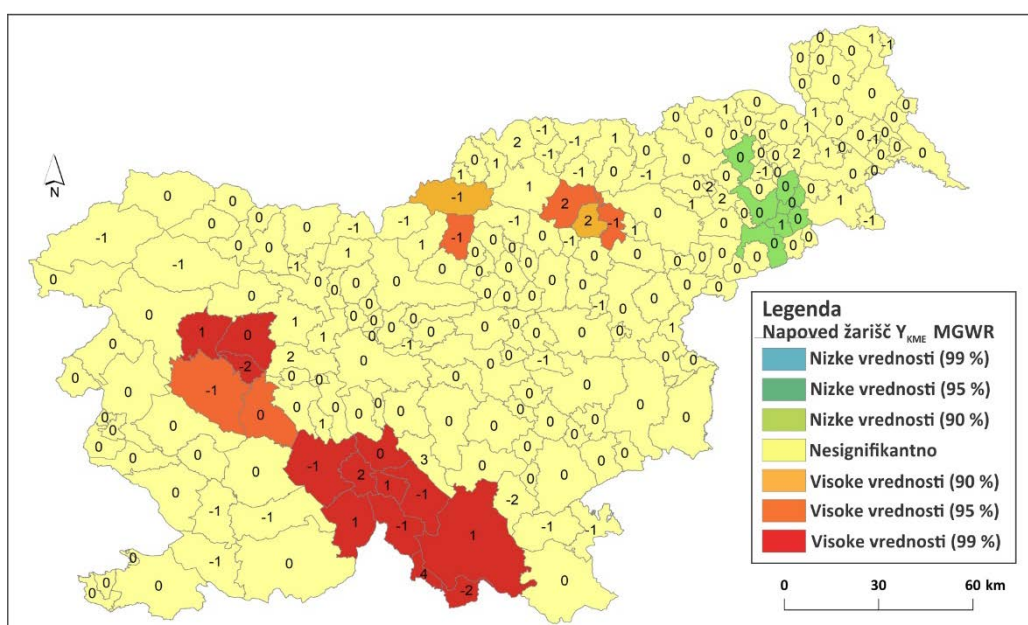
### 3.2 Model MGWR

Nesignifikanten Moranov indeks ( $p > \alpha$ ;  $\alpha = 0,05$ ) ter normalna porazdelitev standardiziranih ostankov odvisne spremenljivke  $Y_{KME}$  sta dokaz za ustrezno specificiran modela MGWR (Slika 2A, B). Model sicer napove nekoliko previsoke normirane vrednosti obolelih z KME v občinah Bloke, Osilnica, Dobropolje, Mislinja in Vitanje (standardni odklon več od 2,5) in premajhne vrednosti  $Y_{KME}$  v občinah Žiri in Kostel (standardni odklon manj od -2,5).



Slika 2: Standardizirani ostanki z modelom MGWR napovedane vrednosti Y<sub>KME</sub> (A) in Moranov preizkus prostorske avtokorelacije standardiziranih ostankov (B).

Preizkus prostorske variabilnosti Monte Carlo je pokazal, da imajo na odvisno spremenljivko  $Y_{KME}$  v prostoru značilno različen vpliv ( $p < \alpha$ ;  $\alpha = 0,05$ ) naslednje neodvisne spremenljivke: nadmorska višina (DMR, ki ima sicer v prostoru povsod pozitiven vpliv), prva in druga glavna komponenta bioklimatskih spremenljivk (PCA1 in PCA2, ki povsod v prostoru na odvisno spremenljivko vplivata negativno), ter raba tal mešani gozd (c\_313), ki na  $Y_{KME}$  v prostoru vpliva. Prostorska analiza žarišč z modelom MGWR napovedane odvisne spremenljivke  $Y_{KME}$  nam je omogočila primerjavo dejanskih in napovedanih žarišča bolezni KME v Sloveniji (Slika 3). Dobili smo dobro napoved združevanje visokih vrednosti  $Y_{KME}$  v južnem delu Slovenije, nekoliko večji žarišči na območju vzhodne goriške ter zahodne osrednjeslovenske regije ter značilno združevanje nižjih vrednosti  $Y_{KME}$  v vzhodni podravski regiji, kar kažejo tudi dejanski podatki. Tudi drugi kazalci kakovosti modela dokazujejo visoko kvaliteto rezultatov (ED = 52 %; MAE = 4,1 RMSE = 3,8; napredek AICc = 426,8).

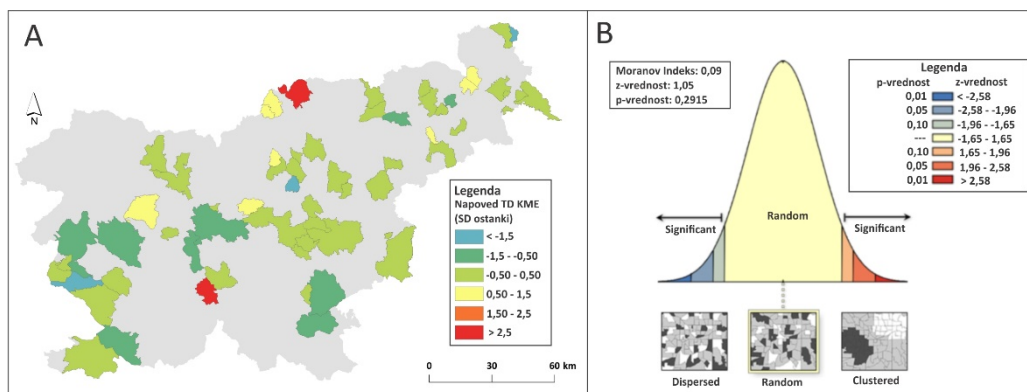


Slika 3: Z MGWR modelom napovedana žarišča  $Y_{KME}$ . Števila predstavljajo odstopanja (ostanke) napovedanih  $Y_{KME}$  od dejanskih  $Y_{KME}$ .

### 3.3 Model RT


Rezultati modela RT imajo prav tako normalno porazdeljene ostanke ( $p < \alpha$ ;  $\alpha = 0,05$ ), ki so v prostoru naključno razporejeni (Moranov indeks = 0,09;  $p = 0,2915$ ;  $\alpha = 0,05$ ) kar dokazuje njegovo statistično ustreznost (Slika 4A, B). V primerjavi z rezultati modela MGWR, je ocena odvisne spremenljivke  $Y_{KME}$  nekoliko kakovostnejša (ED = 62 %; MAE = 3,6; RMSE = 3,3). Tukaj si po doprinosu k razlagi prostorskega vzorca  $Y_{KME}$  sledijo naslednje neodvisne spremenljivke: raba tal (iglasti gozd [17 %]), nadmorska višina (DMR [13 %]), raba tal (manjši lesni elementi v naravi [12 %]) ter prva glavna komponenta bioklimatskih spremenljivk (PCA1 [11 %]) (Priloga 4).





Slika 4: Standardizirani ostanki napovedanih poskusnih podatkov (TD)  $Y_{KME}$  (A) in Moranov preizkus prostorske avtokorelacije standardiziranih ostankov (B).


Na sliki 5 so prikazani rezultati napovedi žarišč odvisne spremenljivke  $Y_{KME}$  z modelom RT. Napoved žarišč  $Y_{KME}$  se z dejanskim združevanjem visokih vrednosti  $Y_{KME}$  v prostoru ujema na stičišču južne osrednjeslovenske regije, vzhodne primorsko-notranjske regije ter zahodne jugovzhodno slovenske regije kot tudi na južnem področju gorenjske statistične regije. Model sicer napove očitno večje združevanje nizkih vrednosti na območju vzhodne Slovenije, kar je nekoliko v neskladju z dejanskimi podatki, a so ostanki na tem območju zelo majhni.



Slika 5: Z modelom RT napovedana žarišča  $Y_{KME}$ . Števila predstavljajo odstopanja (ostanke) napovedanih  $Y_{KME}$  od dejanskih  $Y_{KME}$ .

### 3.4 Prognoza stopnje tveganja za okužbo z KME v Sloveniji

V zaključni fazi prostorske analize smo oba razvita algoritma (MGWR in RT) uporabili zaboljšanje prostorske ločljivosti odvisne spremenljivke  $Y_{KME}$ , ter za pripravo prognoze stopnje tveganja za okužbo s KME v drugi polovici 21. stoletja (2050 in 2070) glede na podnebni scenarij RCP8.5. Na ta način smo lahko bistveno izboljšali prostorsko ločljivost odvisne spremenljivke  $Y_{KME}$  in prešli z občinskega na nivo 1 km<sup>2</sup>. Slika 6A prikazuje recentno stopnjo tveganja za okužbo z KME, ki temelji na povprečju obeh modelov (MGWR in RT). Sliki 6B in 6C prikazujeta postopen časovni razvoj (2050 - dejansko stanje in 2070 - 2050) stopnje tveganja (v relativni skali) za okužbo z KME ob upoštevanju bodočih podnebnih razmer (RCP 8.5). Razvidno je, da se bo zaradi vpliva podnebnih sprememb tveganje za okužbo z KME najbolj zvišalo v severnem in vzhodnem delu Slovenije, kjer lahko pričakujemo tudi do 7 % porast okužb do leta 2070. Med letoma 2050 in 2070 lahko v osrednjem, severozahodnem ter vzhodnem delu pričakujemo do 2,2 % porast okužb s KME. Pričakovano je, da bodo ob koncu 21. stoletja, glede na možnost okužbe z KME, najbolj obremenjene pomurska, podravska, koroška ter savinjska statistična regija.



Slika 6: Prognoza stopnje tveganja za okužbo z KME v sedanosti (DS = dejansko stanje) (povprečje modelov RT in MGWR) (A), ter prognoza stopnje tveganja za okužbo pod pogoji scenarija RCP8.5 med leti 2050 in sedanostjo (B) ter med leti 2070 in 2050 (C). Napovedi za prihodnja časovna okna temeljijo na povprečenju petih statistično značilno različnih globalnih podnebnih modelih (HadGEM2-ES, CCSM4, MIROC-ESM, HadGEM2-CC in MPI-ESM-LR).

#### 4. Diskusija

Za dejansko normirano vrednost obolelih s KME je prostorska analiza žarišč pokazala 3 statistično značilna združevanja visokih vrednosti: prvo na območju jugovzhodne koroške in severovzhodne savinjske regije, drugo na južnem delu gorenjske regije ter tretjo na stičišču vzhodne primorsko-notranjske, jugovzhodne osrednjeslovenske in zahodne jugovzhodno slovenske regije. Po številu okuženih v Sloveniji najbolj izstopata koroška in gorenjska statistična regija, ki sta imeli, v obdobju med leti 2000 in 2009, na letni ravni vsaj dvakrat višjo incidenco okužb s KME v primerjavi z ostalimi predeli Slovenije (Grgič-Vitek & Klavs, 2011).

Ugotovitve kažejo, da se bo lahko zaradi podnebnih sprememb ob koncu 21. stoletja prostorski odtis bolezni KME v Sloveniji razširil. Hkrati se bo povečevala incidenca te bolezni na območjih kjer je prisotna že danes. Bioklimatske neodvisne spremenljivke so se pri obeh postopkih modeliranja (MGWR in RT) pokazale kot ene izmed pomembnejših prediktorjev, ki močno sooblikujejo prostorski vzorec okuženih z KME v Sloveniji. Tudi nadmorska višina (DMR) ima pomemben vpliv na prostorski odtis KME. Tovrstni rezultati se ujemajo z biologijo in ekologijo gozdnega klopa, ki je (pri nas) glavni vektor te bolezni. Spremembe v temperaturi zraka in vodni bilanci namreč močno vplivajo na razvoj, vedenje, reprodukcijo in populacijsko dinamiko klopov, sočasno pa na razvoj patogenov v njih (Gage, Burkot, Eisen, & Hayes, 2008). Tako je abundanca gozdnega klopa je v obratnem sorazmerju z nadmorsko višino (Medlock idr., 2013). Dejstvo, da segrevanje podnebja vpliva na ščitaste klope, je že dobro poznano. Spremembe podnebja vplivajo na ustreznost habitatov in razširjenost klopov. Imajo vpliv na klopne gostitelje, ki so ključnega pomena za obstoj klopov in klopnih bolezni na danem območju (Ostfeld & Brunner, 2015), seveda pa posredno vplivajo tudi na razširjenost bolezni, ki jih klopi prenašajo (Gage idr., 2008).

Naša dognanja, da se prostorski odtis klopnih bolezni širi (Donša idr., 2021), se skladajo z ugotovitvami drugih avtorjev. Tako sta Ostfeld in Brunner (2015) ugotovila, da se številne klopne bolezni, kot sta na primer lymška borelijoza in klopni meningoencefalitis, širijo v večjem delu Severne Amerike in Evrazije. Širjenje populacij klopa v bolj severne predele in v višje nadmorske višine je korelirano s segrevanjem podnebja in je zabeleženo na Švedskem (Lindgren idr., 2000), Norveškem (Jore idr., 2011), Češkem (Daniel idr., 2003) in v Veliki Britaniji (Gilbert, 2010). Povečana incidenca teh bolezni torej sovпада vse močnejšo podnebno krizo (Ostfeld & Brunner, 2015)

Prognoza stopnje tveganja za okužbo z KME je pokazala, da lahko ob koncu 21. stoletja pričakujemo širjenje žarišč te bolezni. Izpostavljene bodo regije v osrednjem in južnem delu Slovenije ter koroška statistična regija. Širjenje KME iz centralnega dela države proti severovzhodu so beležili že sredini 20. stoletja (Kmet idr., 1955). Zaradi vpliva podnebnih sprememb, pa lahko do leta 2070 v Sloveniji pričakujemo tudi do 7 % rast tveganja za okužb s KME.

## 5. Zaključek

Klopi so pomembni prenašalci številnih nalezljivih bolezni in tako močno ogrožajo javno zdravje. Za uspešno omejevanje okužb, tako v sedanosti kot tudi v prihodnosti, je potrebno razumeti kateri dejavniki vplivajo na razširjenost klopov ter posredno tudi na bolezni, ki jih prenašajo. To še posebej velja za podnebne spremembe, saj okoljski dejavniki močno vplivajo na distribucijo, abundanco in razvoj klopov, vpliv pa imajo tudi na klopne gostitelje ter povzročitelje klopnih bolezni. Rezultati naše prostorske analize so pokazali, da imamo v Sloveniji statistično značilna žarišča KME, ki se lahko v prihodnosti razširijo na nova območja. Prav tako pa se bo povečala incidenca bolezni na območjih, kjer je bolezen že prisotna, kar bo še dodatno obremenilo javno zdravje. Ob koncu 21. stoletja bo, pod vplivom podnebnih sprememb, tveganje za okužbo z KME na območju Slovenije poraslo predvsem v vzhodni in severni Sloveniji. Tako bo v prihajajočih desetletjih, še bolj kot to velja danes, za zaščito pred klopnimi boleznimi pomembna preventiva in ozaveščanje javnosti.

## Literatura

- Anderson, J. F., & Magnarelli, L. A. (2008). Biology of Ticks. *Infectious Disease Clinics of North America*, 22(2), 195–215.  
<https://doi.org/10.1016/j.idc.2007.12.006>
- Azagi, T., Hoornstra, D., Kremer, K., Hovius, J. W. R., & Sprong, H. (2020). Evaluation of Disease Causality of Rare Ixodes ricinus-Borne Infections in Europe. *Pathogens*, 9(2), 150. <https://doi.org/10.3390/pathogens9020150>
- Bogovic, P. (2015). Tick-borne encephalitis: A review of epidemiology, clinical characteristics, and management. *World Journal of Clinical Cases*, 3(5), 430.  
<https://doi.org/10.12998/wjcc.v3.i5.430>
- CHELSEA. (2020). *Chelsa Climate*. <https://chelsa-climate.org/>
- Copernicus. (2020). *Land Copernicus*. <https://land.copernicus.eu/>
- Daniel, M., Danielová, V., Kříž, B., Jirsa, A., & Nožička, J. (2003). Shift of the Tick *Ixodes ricinus* and Tick-Borne Encephalitis to Higher Altitudes in Central Europe. *European Journal of Clinical Microbiology and Infectious Diseases*, 22(5), 327–328. <https://doi.org/10.1007/s10096-003-0918-2>
- Donša, D., Grujić, V. J., Pipenbaher, N., & Ivajnišič, D. (2021). The Lyme Borreliosis Spatial Footprint in the 21st Century: A Key Study of Slovenia. *International Journal of Environmental Research and Public Health*, 18(22), 12061.  
<https://doi.org/10.3390/ijerph182212061>
- Dumpis, U., Crook, D., & Oksi, J. (1999). Tick-Borne Encephalitis. *Clinical Infectious Diseases*, 28(4), 882–890. <https://doi.org/10.1086/515195>
- ESRI. (2020). *ArcGIS Desktop: Release 10.8*. Environmental Systems Research Institute.
- Gage, K. L., Burkot, T. R., Eisen, R. J., & Hayes, E. B. (2008). Climate and Vectorborne Diseases. *American Journal of Preventive Medicine*, 35(5), 436–450.  
<https://doi.org/10.1016/j.amepre.2008.08.030>
- Gilbert, L. (2010). Altitudinal patterns of tick and host abundance: A potential role for climate change in regulating tick-borne diseases? *Oecologia*, 162(1), 217–225. <https://doi.org/10.1007/s00442-009-1430-x>
- Grgič-Vitek, M., & Klavs, I. (2011). High burden of tick-borne encephalitis in Slovenia—Challenge for vaccination policy. *Vaccine*, 29(32), 5178–5183.  
<https://doi.org/10.1016/j.vaccine.2011.05.033>

- Hauser, G., Rais, O., Cadenas, F. M., Gonseth, Y., Bouzelboudjen, M., & Gern, L. (2018). Influence of climatic factors on *Ixodes ricinus* nymph abundance and phenology over a long-term monthly observation in Switzerland (2000–2014). *Parasites & Vectors*, *11*(1), 289. <https://doi.org/10.1186/s13071-018-2876-7>
- Heyman, P., Cochez, C., Hofhuis, A., van der Giessen, J., Sprong, H., Porter, S. R., Losson, B., Saegerman, C., Donoso-Mantke, O., Niedrig, M., & Papa, A. (2010). A clear and present danger: Tick-borne diseases in Europe. *Expert Review of Anti-Infective Therapy*, *8*(1), 33–50. <https://doi.org/10.1586/eri.09.118>
- Jore, S., Viljugrein, H., Hofshagen, M., Brun-Hansen, H., Kristoffersen, A. B., Nygård, K., Brun, E., Ottesen, P., Sævik, B. K., & Ytrehus, B. (2011). Multi-source analysis reveals latitudinal and altitudinal shifts in range of *Ixodes ricinus* at its northern distribution limit. *Parasites & Vectors*, *4*(1), 84. <https://doi.org/10.1186/1756-3305-4-84>
- Kmet, J., Vesenjajk-Zmijanac, J., Bedjanic, M., & Rus, S. (1955). Virus meningo-encephalitis in Slovenia. *Bulletin of the World Health Organization*, *12*(4), 491–501.
- Lindgren, E., Tälleklint, L., & Polfeldt, T. (2000). Impact of climatic change on the northern latitude limit and population density of the disease-transmitting European tick *Ixodes ricinus*. *Environmental Health Perspectives*, *108*(2), 119–123. <https://doi.org/10.1289/ehp.00108119>
- Milborrow, S. (2020). *Rpart.plot: Plot „rpart“ Models: An Enhanced Version of „plot.rpart“*. <https://cran.r-project.org/web/packages/rpart.plot/index.html>
- Ministrstvo za kmetijstvo, gozdarstvo in prehrano. (2020). *MKGP-portal*. <https://rkg.gov.si/vstop/>
- Ministrstvo za okolje in prostor, Geodetska uprava Republike Slovenije. (2020). *E-Geodetski podatki*. <https://egp.gu.gov.si/egp/index.html>
- NASA. (2020). *EarthData*. <https://earthdata.nasa.gov/>
- Nava, S. (2009). An overview of systematics and evolution of ticks. *Frontiers in Bioscience, Volume*(14), 2857. <https://doi.org/10.2741/3418>
- NIJZ. (2014). *Podatki*. <https://www.nijz.si/sl/podatki>
- Oshan, T., Li, Z., Kang, W., Wolf, L., & Fotheringham, A. (2019). MGWR: A Python Implementation of Multiscale Geographically Weighted Regression for Investigating Process Spatial Heterogeneity and Scale. *ISPRS International Journal of Geo-Information*, *8*(6), 269. <https://doi.org/10.3390/ijgi8060269>
- Ostfeld, R. S., & Brunner, J. L. (2015). Climate change and *Ixodes* tick-borne diseases of humans. *Philosophical Transactions of the Royal Society B: Biological Sciences*, *370*(1665), 20140051. <https://doi.org/10.1098/rstb.2014.0051>
- Parola, P., & Raoult, D. (2001). Ticks and Tickborne Bacterial Diseases in Humans: An Emerging Infectious Threat. *Clinical Infectious Diseases*, *32*(6), 897–928. <https://doi.org/10.1086/319347>
- R Core Team. (2020). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing.
- Rahlenbeck, S., Fingerle, V., & Doggett, S. (2016). Prevention of tick-borne diseases: An overview. *British Journal of General Practice*, *66*(650), 492–494. <https://doi.org/10.3399/bjgp16X687013>
- Republika Slovenija. (2020). *Portal GOV.SI*. <https://www.gov.si/>
- Ripley, B. (2019). *tree: Classification and Regression Trees*. <https://cran.r-project.org/web/packages/tree/index.html>
- Statistični urad Republike Slovenije. (2020). *SiStat*. <https://pxweb.stat.si/SiStat/sl>

Therneau, T., Atkinson, B., & Ripley, B. (2019). *rpart: Recursive Partitioning and Regression Trees*. <https://cran.r-project.org/web/packages/rpart/index.html>

Tuszynski, J. (2021). *CaTools: Tools: Moving Window Statistics, GIF, Base64, ROC AUC, etc.* <https://cran.r-project.org/web/packages/caTools/index.html>

Zavod za gozdove Slovenije. (2020). *Zavod za gozdove Slovenije*. <http://www.zgs.si>

## **TICK-BORNE ENCEPHALITIS AND CLIMATE CHANGE IN SLOVENIA**

### ***Summary***

Ticks are important carriers of many infectious diseases and thus pose a serious threat to public health. To successfully control infections, both now and in the future, it is necessary to understand which factors affect the prevalence of ticks and, indirectly, the diseases they transmit. This is especially true for climate change, as environmental factors have a strong impact on the distribution, abundance and development of ticks; furthermore, they have an impact on tick hosts and tick-borne pathogens. The results of our spatial analysis showed that we have statistically significant foci of TBE in Slovenia, which may spread to new areas in the future. Moreover, we can expect an increase of TBE incidence in areas where the disease is already present, which will further burden public health. At the end of the 21st century, under the influence of climate change, the risk of TBE infection in Slovenia will increase, especially in eastern and northern Slovenia. Thus, in the coming decades, even more than today, prevention and public awareness will be important factors for protection against tick-borne diseases.

**Priloga 1**

Preglednica p1: Korelacijska matrika neodvisnih spremenljivk, kjer zelena označuje pozitivno korelacijo nad zadano vrednostjo +0,6; rdeča pa negativno korelacijo pod vrednostjo -0,6.

	X20_F2_povozi	X21_F1_preb	X22_F2_preb	X23_ind_sta	X24_koef_razv
X1_DMV_25	-0,21	0,27	-0,10	-0,07	0,19
X2_NDVI_mean	-0,31	0,24	-0,18	-0,16	0,12
X3_NDVI_a_value	0,00	-0,22	0,02	0,08	-0,02
X4_PCA_1_mean	0,04	0,31	-0,03	-0,05	0,32
X5_PCA_2_mean	-0,50	-0,20	-0,09	0,09	-0,30
X6_rt_1800	0,04	-0,22	0,15	-0,16	-0,03
X7_rt_1420	0,14	0,09	0,04	0,25	0,07
X8_rt_1300	0,18	0,17	-0,05	0,19	-0,08
X9_rt_1500	0,11	0,14	-0,05	0,19	-0,02
X10_rt_5000	-0,16	-0,09	-0,10	-0,15	-0,23
X11_rt_1222	0,25	0,25	-0,11	0,11	-0,05
X12_c_122	-0,18	0,06	-0,26	0,19	-0,29
X13_c_231	0,40	-0,08	0,04	0,32	-0,31
X14_c_311	-0,16	-0,05	0,10	-0,09	0,13
X15_c_312	0,25	-0,19	0,05	0,10	-0,19
X16_c_313	0,30	-0,20	0,13	0,25	-0,22
X17_c_321	0,15	-0,19	0,06	-0,17	-0,07
X18_swf	-0,05	0,28	-0,11	0,07	0,10
X19_F1_povozi	-0,35	-0,53	-0,06	-0,07	-0,13
X20_F2_povozi	1,00	0,17	0,22	-0,08	0,18
X21_F1_preb	0,17	1,00	-0,42	-0,16	-0,03
X22_F2_preb	0,22	-0,42	1,00	0,04	0,56
X23_ind_sta	-0,08	-0,16	0,04	1,00	-0,46
X24_koef_razv	0,18	-0,03	0,56	-0,46	1,00



	X14_c_311	X15_c_312	X16_c_313	X17_c_321	X18_swf	X19_F1_povozi
X1_DMV_25	0,26	-0,71	-0,55	-0,67	0,74	-0,44
X2_NDVI_mean	-0,16	-0,46	-0,49	-0,47	0,49	-0,27
X3_NDVI_a_value	0,23	-0,02	0,21	0,00	0,06	0,13
X4_PCA_1_mean	0,03	-0,60	-0,37	-0,72	0,78	-0,55
X5_PCA_2_mean	0,46	-0,09	-0,17	0,18	-0,20	0,36
X6_rt_1800	0,16	0,32	0,21	0,62	-0,51	0,45
X7_rt_1420	0,12	-0,31	0,05	-0,37	0,43	-0,34
X8_rt_1300	0,16	-0,42	0,03	-0,40	0,68	-0,43
X9_rt_1500	-0,07	-0,20	-0,10	-0,26	0,35	-0,36
X10_rt_5000	0,14	0,24	0,06	0,53	-0,42	0,35
X11_rt_1222	0,16	-0,45	0,01	-0,50	0,71	-0,48
X12_c_122	0,02	-0,25	-0,29	-0,39	0,39	-0,28
X13_c_231	-0,06	0,34	0,43	0,21	-0,18	0,03
X14_c_311	1,00	-0,54	-0,30	-0,06	0,16	0,09
X15_c_312	-0,54	1,00	0,54	0,55	-0,72	0,28
X16_c_313	-0,30	0,54	1,00	0,27	-0,32	0,10
X17_c_321	-0,06	0,55	0,27	1,00	-0,71	0,48
X18_swf	0,16	-0,72	-0,32	-0,71	1,00	-0,55
X19_F1_povozi	0,09	0,28	0,10	0,48	-0,55	1,00
X20_F2_povozi	-0,16	0,25	0,30	0,15	-0,05	-0,35
X21_F1_preb	-0,05	-0,19	-0,20	-0,19	0,28	-0,53
X22_F2_preb	0,10	0,05	0,13	0,06	-0,11	-0,06
X23_ind_sta	-0,09	0,10	0,25	-0,17	0,07	-0,07
X24_koef_razv	0,13	-0,19	-0,22	-0,07	0,10	-0,13

	X8_rt_1300	X9_rt_1500	X10_rt_5000	X11_rt_1222	X12_c_122	X13_c_231
X1_DMV_25	0,33	0,19	-0,46	0,42	0,45	-0,48
X2_NDVI_mean	0,03	0,14	-0,18	0,04	0,36	-0,52
X3_NDVI_a_value	0,20	-0,06	-0,05	0,16	-0,07	0,21
X4_PCA_1_mean	0,41	0,29	-0,64	0,50	0,28	-0,25
X5_PCA_2_mean	-0,21	-0,20	0,37	-0,27	0,15	-0,21
X6_rt_1800	-0,12	-0,31	0,58	-0,24	-0,37	0,25
X7_rt_1420	0,47	0,29	-0,42	0,49	-0,03	0,20
X8_rt_1300	1,00	0,24	-0,19	0,88	0,10	0,28
X9_rt_1500	0,24	1,00	-0,31	0,24	0,16	-0,01
X10_rt_5000	-0,19	-0,31	1,00	-0,31	-0,06	0,01
X11_rt_1222	0,88	0,24	-0,31	1,00	0,12	0,25
X12_c_122	0,10	0,16	-0,06	0,12	1,00	-0,24
X13_c_231	0,28	-0,01	0,01	0,25	-0,24	1,00
X14_c_311	0,16	-0,07	0,14	0,16	0,02	-0,06
X15_c_312	-0,42	-0,20	0,24	-0,45	-0,25	0,34
X16_c_313	0,03	-0,10	0,06	0,01	-0,29	0,43
X17_c_321	-0,40	-0,26	0,53	-0,50	-0,39	0,21
X18_swf	0,68	0,35	-0,42	0,71	0,39	-0,18
X19_F1_povozi	-0,43	-0,36	0,35	-0,48	-0,28	0,03
X20_F2_povozi	0,18	0,11	-0,16	0,25	-0,18	0,40
X21_F1_preb	0,17	0,14	-0,09	0,25	0,06	-0,08
X22_F2_preb	-0,05	-0,05	-0,10	-0,11	-0,26	0,04
X23_ind_sta	0,19	0,19	-0,15	0,11	0,19	0,32
X24_koef_razv	-0,08	-0,02	-0,23	-0,05	-0,29	-0,31

	X2_NDVI_mean	X3_NDVI_a_value	X4_PCA_1_mean	X5_PCA_2_mean	X6_rt_1800	X7_rt_1420
X1_DMV_25	0,55	-0,03	0,82	0,07	-0,61	0,21
X2_NDVI_mean	1,00	-0,18	0,52	-0,11	-0,45	-0,06
X3_NDVI_a_value	-0,18	1,00	-0,03	0,21	0,05	0,25
X4_PCA_1_mean	0,52	-0,03	1,00	-0,42	-0,69	0,40
X5_PCA_2_mean	-0,11	0,21	-0,42	1,00	0,23	-0,26
X6_rt_1800	-0,45	0,05	-0,69	0,23	1,00	-0,17
X7_rt_1420	-0,06	0,25	0,40	-0,26	-0,17	1,00
X8_rt_1300	0,03	0,20	0,41	-0,21	-0,12	0,47
X9_rt_1500	0,14	-0,06	0,29	-0,20	-0,31	0,29
X10_rt_5000	-0,18	-0,05	-0,64	0,37	0,58	-0,42
X11_rt_1222	0,04	0,16	0,50	-0,27	-0,24	0,49
X12_c_122	0,36	-0,07	0,28	0,15	-0,37	-0,03
X13_c_231	-0,52	0,21	-0,25	-0,21	0,25	0,20
X14_c_311	-0,16	0,23	0,03	0,46	0,16	0,12
X15_c_312	-0,46	-0,02	-0,60	-0,09	0,32	-0,31
X16_c_313	-0,49	0,21	-0,37	-0,17	0,21	0,05
X17_c_321	-0,47	0,00	-0,72	0,18	0,62	-0,37
X18_swf	0,49	0,06	0,78	-0,20	-0,51	0,43
X19_F1_povozi	-0,27	0,13	-0,55	0,36	0,45	-0,34
X20_F2_povozi	-0,31	0,00	0,04	-0,50	0,04	0,14
X21_F1_preb	0,24	-0,22	0,31	-0,20	-0,22	0,09
X22_F2_preb	-0,18	0,02	-0,03	-0,09	0,15	0,04
X23_ind_sta	-0,16	0,08	-0,05	0,09	-0,16	0,25
X24_koef_razv	0,12	-0,02	0,32	-0,30	-0,03	0,07

X1_DMV_25	1,00
X2_NDVI_mean	0,55
X3_NDVI_a_value	-0,03
X4_PCA_1_mean	0,82
X5_PCA_2_mean	0,07
X6_rt_1800	-0,61
X7_rt_1420	0,21
X8_rt_1300	0,33
X9_rt_1500	0,19
X10_rt_5000	-0,46
X11_rt_1222	0,42
X12_c_122	0,45
X13_c_231	-0,48
X14_c_311	0,26
X15_c_312	-0,71
X16_c_313	-0,55
X17_c_321	-0,67
X18_swf	0,74
X19_F1_povozi	-0,44
X20_F2_povozi	-0,21
X21_F1_preb	0,27
X22_F2_preb	-0,10
X23_ind_sta	-0,07
X24_koef_razv	0,19

Legenda: X1\_DMV\_25=digitalni model višin (rezolucija 25 m); X2\_NDVI\_mean=povprečna vrednost vegetacijskega indeksa NDVI; X3\_NDVI\_a\_value=smerni koeficienta vegetacijskega indeksa NDVI; X4\_PCA\_1\_mean=povprečna vrednost prve glavne komponente bioklimatskih spremenljivk; X5\_PCA\_2\_mean=povprečna vrednost druge glavne komponente bioklimatskih spremenljivk; X6\_rt\_1800=raba tal (kmetijsko zemljišče, poraslo z gozdnim drevjem); X7\_rt\_1420=raba tal (plantaža gozdnega drevja); X8\_rt\_1300=raba tal (trajni travnik); X9\_rt\_1500=raba tal (drevesa in grmičevje); X10\_rt\_5000=raba tal (suho odprto zemljišče s posebnim rastlinskim pokrovom); X11\_rt\_1222=raba tal (ekstenzivni oz. travniški sadovnjak); X12\_c\_122=raba tal (urbane površine z zelenimi zaplatami); X13\_c\_231=raba tal (pašniki); X14\_c\_311=raba tal (listopadni gozd); X15\_c\_312=raba tal (iglasti gozd); X16\_c\_313=raba tal (mešani gozd); X17\_c\_321=raba tal (naravna travišča); 18\_swf= raba tal (manjši lesni elementi v naravi); X19\_F1\_povozi=faktor 1 povozov živali; X20\_F2\_povozi=faktor 2 povoza živali; X21\_F1\_preb=1. demografski faktor; X22\_F2\_preb=2. demografski faktor; X23\_ind\_sta=indeks staranja prebivalstva; X24\_koef\_razv =indeks razvitosti občin.

## Priloga 2

Preglednica p2: Rezultati globalnega Poissonovega regresijskega testa za YKME, testna statistika napovedovalnih spremenljivk in rezultati Monte Carlo testa za prostorsko variabilnost.

Devianca	173,05
Verjetnost logaritma	-188,21
AIC	402,42
AICc	200,89
Delež pojasnjene deviance	0,38
Delež prilagojene deviance	0,35

Spremenljivka	Pričakovan vpliv	Standardna napaka	Pričakovan vpliv/standardna napaka	p-vrednost	p-vrednost prostorske variabilnosti
Konstanta	-0,40	1,78	-0,22	0,823	0,16
X1_DMV_25	8,70	2,25	3,87	0,000	0,02
X3_NDVI_a_value	-1,64	0,35	-4,65	0,000	0,66
X4_PCA_1_mean	-3,57	2,01	-1,77	0,076	0,02
X5_PCA_2_mean	-4,85	2,13	-2,28	0,023	0,03
X6_rt_1800	2,32	0,78	2,96	0,003	0,37
X11_rt_1222	-2,33	0,92	-2,53	0,012	0,31
X12_c_122	0,87	0,45	1,97	0,049	0,44
X15_c_312	-1,80	0,89	-2,02	0,044	0,27
X16_c_313	2,20	1,13	1,94	0,052	0,00
X19_F1_povozi	0,14	0,11	1,30	0,195	0,07
X22_F2_preb	-0,19	0,12	-1,60	0,109	0,83
X24_koef_razv_ob	0,79	1,13	0,70	0,482	0,89

Legenda: X1\_DMV\_25= digitalni model višin (resolucija 25 m); X4\_PCA\_1\_mean=povprečna vrednost prve glavne komponente bioklimatskih spremenljivk; X5\_PCA\_2\_mean= povprečna vrednost druge glavne komponente bioklimatskih spremenljivk; X6\_rt\_1800=raba tal (kmetijsko zemljišče, poraslo z gozdnim drevjem); X8\_rt\_1300=raba tal (trajni travnik); X9\_rt\_1500=raba tal (drevesa in grmičevje); X10\_rt\_5000=raba tal (suho odprto zemljišče s posebnim rastlinskim pokrovom); X12\_c\_122=raba tal (urbane površine z zelenimi zaplatami); X13\_c\_231=raba tal (pašniki); X14\_c\_311=raba tal (listopadni gozd); X16\_c\_313=raba tal (mešani gozd); X17\_c\_321=raba tal (naravna travnišča); 18\_swf= raba tal (manjši lesni elementi v naravi); X19\_F1\_povozi= faktor 1 povozov živali; X22\_F2\_preb=2. demografski faktor; X24\_koef\_razv =indeks razvitosti občin.

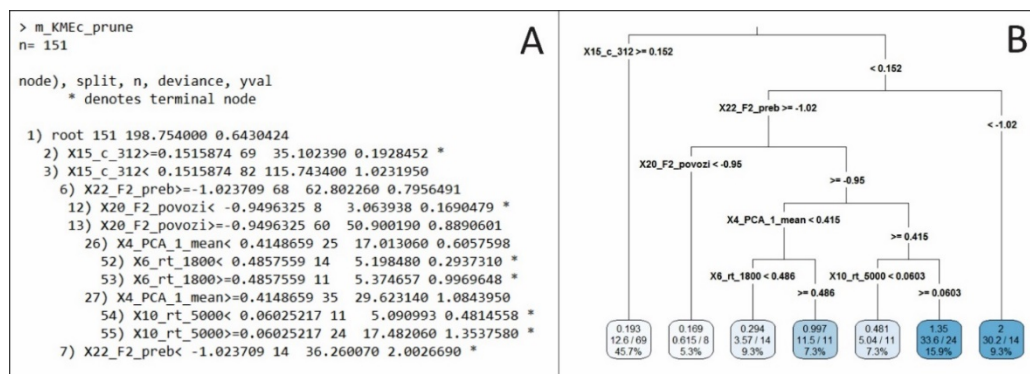
### Priloga 3

Preglednica p3: Rezultati MGWR in povzetek statistike za ocene parametrov MGWR.

<b>Efektivno število parametrov</b>	19,59
<b>Stopinje prostosti</b>	192,41
<b>Devianca</b>	150,69
<b>AIC</b>	189,87
<b>AICc</b>	194,08
<b>BIC</b>	255,62
<b>Prilagojena alfa (95 %)</b>	0,03
<b>Prilagojena kritična t vrednost</b>	2,14

<b>Spremenljivka</b>	<b>Povprečje</b>	<b>Standardni odklon</b>	<b>Minimum</b>	<b>Mediana</b>	<b>Maksimum</b>
<b>Konstanta</b>	1,67	1,74	-0,57	1,50	4,23
<b>X1_DMV_25</b>	9,56	2,81	5,94	9,92	13,24
<b>X3_NDVI_a_value</b>	-1,45	0,09	-1,66	-1,45	-1,28
<b>X4_PCA_1_mean</b>	-4,39	2,52	-8,01	-4,27	-0,92
<b>X5_PCA_2_mean</b>	-6,53	2,61	-9,97	-6,86	-3,35
<b>X6_rt_1800</b>	2,29	0,32	1,92	2,25	2,73
<b>X11_rt_1222</b>	-2,51	0,57	-3,22	-2,71	-1,64
<b>X12_c_122</b>	0,65	0,17	0,36	0,67	0,90
<b>X15_c_312</b>	-2,38	0,46	-3,03	-2,51	-1,60
<b>X16_c_313</b>	0,70	3,51	-6,44	2,69	4,53
<b>X19_F1_povozi</b>	0,10	0,08	-0,03	0,10	0,22
<b>X22_F2_preb</b>	-0,14	0,02	-0,18	-0,13	-0,12
<b>X24_koef_razv_ob</b>	0,25	0,30	-0,42	0,33	0,85

Priloga 4



Slika p1: Regresijsko drevo za YKME. Tekstovni prikaz (A) in grafični prikaz (B) modela RT. Legenda: X15\_c\_312=raba tal (iglasti gozd); X22\_F2\_preb=2. demografski faktor; X20\_F2\_povozi=faktor 2 povoza živali; X4\_PCA\_1\_mean=povprečna vrednost prve glavne komponente bioklimatskih spremenljivk; X6\_rt\_1800=raba tal (kmetijsko zemljišče, poraslo z gozdnim drevjem); X10\_rt\_5000=raba tal (suho odprto zemljišče s posebnim rastlinskim pokrovom).

