PROCJENA VIJABILNOSTI I OPSTOJNOSTI POPULACIJE IVANJSKOG ROVAŠA (Ablepharus kitaibelii) NA PAPUKU U UVJETIMA STOHASTIČKOG OKOLIŠA KROZ STOGODIŠNJI VREMENSKI PERIOD

Damjanović, Ivan

Master's thesis / Diplomski rad

2015

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Department of biology / Sveučilište Josipa Jurja Strossmayera u Osijeku, Odjel za biologiju**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:181:163331

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

ODJEL ZA BIOLOGIJU
Sveučilište Josipa Jurja Strossmayera u Osijeku

Repository / Repozitorij:

Repository of Department of biology, Josip Juraj Strossmayer University of Osijek

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

ODJEL ZA BIOLOGIJU

Diplomski sveučilišni znanstveni studij biologije

Ivan Damjanović

PROCJENA VIJABILNOSTI I OPSTOJNOSTI POPULACIJE IVANJSKOG ROVAŠA (*Ablepharus kitaibelii*) NA PAPUKU U UVJETIMA STOHASTIČKOG OKOLIŠA KROZ STOGODIŠNJI VREMENSKI PERIOD

Diplomski rad

Osijek, 2015.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište Josipa Jurja Strossmayera u Osijeku **Diplomski rad**
Odjel za biologiju
Diplomski sveučilišni znanstveni studij biologije
Znanstveno područje: Prirodne znanosti
Znanstveno polje: Biologija

PROCJENA VIJABILNOSTI I OPSTOJNOSTI POPULACIJE IVANJSKOG ROVAŠA (*Ablepharus kitaibelii*) NA PAPUKU U UVJETIMA STOHASTIČKOG OKOLIŠA KROZ STOGODIŠNJI VREMENSKI PERIOD

Ivan Damjanović

Rad je izrađen na Zavodu za zoologiju Odjela za biologiju, Sveučilišta Josipa Jurja Strossmayera u Osijeku.
Mentor: Prof. dr. sc. *Stjepan Krčmar*
Komentor: Dr. sc. *Dušan Jelić*

Kratak sadržaj diplomskog rada:

Ivanjski rovaš (*Ablepharus kitaibelli*) jedan je od najmanjih vrsta guštera u Europi, a ujedno i najmanja vrsta guštera u Hrvatskoj. Rasprostranjenost vrste u Hrvatskoj ograničena je na izoliranim populacijama na planini Papuk i gradskom parku u Iloku. Podaci su prikupljani na Papuku kroz četverogodišnji vremenski period. Cilj rada bio je procijeniti vijabilnost populacije u sadašnjim uvjetima, opstojnost populacije u stohastičnom okolišu kroz stogodišnji vremenski period i utvrditi glavne čimbenike promjene trenda dinamike rasta populacije. Prema dobivenim rezultatima procjene vijabilnosti, iako je 100 %-tna vjerojatnost opstanka, ukupna dinamika rasta je negativna. Može se zaključiti da bi aktiviranje negativnih čimbenika ubrzalo negativan trend dinamike rasta i gurnulo populaciju u prijevremeno izumiranje. Istraživanje je pokazalo da unutarnji čimbenici, kao mortalitet juvenilnih jedinki, imaju veći utjecaj na opstojnost populacije od vanjskih okolišnih čimbenika, odnosno stohastičnosti sustava. Rezultati istraživanja također su pokazali da se introdukcijom vrste i poboljšanjem stanišnih uvjeta uvelike povećava opstojnost populacije.

Broj stranica: 65
Broj slika: 28
Broj tablica: 22
Broj literaturnih navoda: 77
Jezik izvornika: hrvatski
Ključne riječi: Ivanjski rovaš, vijabilnost, PVA, opstojnost, okolišna stohastičnost, VORTEX
Datum obrane:
Stručno povjerenstvo za obranu:
1. **Doc. dr. sc**. *Alma Mikuška*
2. **Prof. dr. sc.** *Stjepan Krčmar*
3. **Doc.dr.sc.** *Mirta Sudarić Bogojević*

Rad je pohranjen u:
u knjižnici Odjela za biologiju Sveučilišta Josipa Jurja Strossmayera u Osijeku i u Nacionalnoj sveučilišnoj knjižnici u Zagrebu, u elektroničkom obliku, te je objavljen na web stranici Odjela za biologiju.

BASIC DOCUMENTATION CARD

University Josip Juraj Strossmayer in Osijek **MS thesis**
Department of Biology
Graduate Study of Biology
Scientific Area: Natural science
Scientific Field: Biology

ESTIMATE OF VIABILITY AND PERSISTENCE OF THE SNAKE-EYED SKINK (*Ablepharus kitaibelii*) ON PAPUK IN TERMS OF STOHASTIC ENVIRONMENT THROUGH CENTENNIAL TIME PERIOD

Ivan Damjanović

Thesis performed at Department of Biology, University Josip Juraj Strossmayer in Osijek.
Mentor: Prof. Dr. Sc. *Stjepan Krčmar*
Comentor: Dr. sc. *Dušan Jelić*

Short abstract:

Snake-eyed skink (*Ablepharus kitaibelii*) is one of the smallest European lizards and also the smallest lizard species in Croatia. The distribution of species in Croatia is limited to isolated populations on the mountain Papuk and the city park in Ilok. Data were collected on Papuk through a four-year period. The main goals of this study were to evaluate the viability of the population in today's conditions, population persistence in a stochastic environment through centennial time period and to identify the main factors of change of trend dynamics of population growth. According to the results of the estimate of viability, although 100 % is the probability of survival, the overall dynamics of growth is negative. It can be concluded that the activation of negative factors could accelerate the negative trend of the dynamics of growth and pushed the population in the early extinction. Research has shown that internal factors, such as juvenile mortality, have a greater impact on the persistence of the population from external environmental factors, environmental stochasticity respectively. Study results also showed that by introducing the species and by improving habitat conditions significantly increases the population persistence.

Number of pages: 65
Number of figures: 28
Number of tables: 22
Number of referencis: 77
Original in: Croatian
Key words: Snake-eyed skink, viability, PVA, persistence, stohastic environment, VORTEX
Date of thesis defence:
Reviewers:

1. **Doc. dr. sc**. *Alma Mikuška*
2. **Prof. dr. sc.** *Stjepan Krčmar*
3. **Doc.dr.sc.** *Mirta Sudarić Bogojević*

Thesis deposited in
Library of Department of Biology, University of J.J. Strossmayer in Osijek and in National university library in Zagreb in elektronic form. It is also disposable on the website of Departmetnt of Biology, University of J.J. Strossmayer Osijek

Ovaj diplomski rad je izrađen na Odjelu za biologiju Sveučilišta J.J. Strossmayera u Osijeku pod mentorstvom prof.dr.sc. Stjepana Krčmara i vodstvom dr. sc. Dušana Jelića u okviru projekta zaštite ivanjskog rovaša (*Ablepharus kitaibelii*) na Papuku.

Zahvale

Zahvaljujem svom mentoru dr. sc. Dušanu Jeliću na prijedlogu teme, na svim savjetima i pomoći koju mi je pružio tijekom pisanja rada. Jedno veliko hvala na strpljenju i razumjevanju koje je pokazao.

Nadalje, veliko hvala i prof. dr. sc. Stjepanu Krčmaru na savjetima i otvorenosti koje je pokazao u danima pred predaju rada.

Veliko hvala mojoj ekipi sa Papuka, Senki Baškieri, Frani Barišiću i Ani Kolarić, koji su sudjelovali u terenskom prikupljanju podataka.

Hvala mojim dragim kolegama studentima, asistentima i profesorima na svoj pomoći i savjetima tijekom studiranja. Hvala vam što ste se smijali zajedno sa mnom.

Naposlijetku, veliko hvala mojoj obitelj i prijateljma na velikoj podršci i razumijevanju koju mi pružaju.

SADRŽAJ

1. UVOD 1

1.1. ROD *ABLEPHARUS* LICHTENSTEIN, 1823 1
1.2. IVANJSKI ROVAŠ (ABLEPHARUS KITAIBELII) 1
a) Opis vrste 1
b) Opisane podvrste 3
c) Rasprostranjenost 3
d) Opis staništa 4
e) Zaštita 5
1.3. VIJABILNOST POPULACIJE 5
a) Definicija 5
b) PVA - Analiza vijabilnosti populacije 6
c) MVP - Minimalna vijabilna populacija 6
d) Vremenski interval 6
1.4. OPSTOJNOST POPULACIJE 7
a) Definicija 7
b) Opstojnost i biološka sukcesija 7
c) Opstojnost i početna veličina populacije 7
d) Opstojnost i stopa razmnožavanja 7
e) Opstojnost i okolišni uvjeti 8
1.5. OSNOVNI POPULACIJSKI MODEL 8
a) Leslie matrični model 8
b) Ovisnost gustoće 9
c) Allee efekt 9
1.6. MODELI RASTA POPULACIJE 9
a) Deterministički model rasta populacije 10
b) Stohastički model rasta populacije 10
1.7. IZVORI VARIJACIJA KOJI UTJEČU NA OPSTOJNOST 11
a) Varijacija procesa i varijacija uzorkovanja 11
b) Demografska varijacija 11
c) Okolišna varijacija 12
d) Individualna varijacija 13
e) Beta distribucija 14
1.8. PROCJENA VARIJACIJE 15
a) Direktna procjena varijacije 15
b) Indirektna procjena varijacije 15

2. CILJ RADA 17

3. PODRUČJE ISTRAŽIVANJA 18

3.1. PAPUK 18
3.2. VRH TURJAK 19

4. MATERIJALI I METODE 21

4.1. TERENSKI RAD 21
4.2. SASTAVNICE PVA 21
a) Osnovni populacijski model 21
b) Demografska varijacija 21
c) Temporalna varijacija 21
d) Spacijalna varijacija 22
e) Individualna heterogenost 22
f) Genetska varijacija 22
g) Stabilnost sustava 22
4.3. STATISTIČKA OBRADA PODATAKA 23
a) VORTEX – simulator procesa izumiranja 23
b) Microsoft Office paket 23
4.4. POPULACIJSKI MODELI SA RAZLIČITIM SCENARIJIMA 24
a) Osnovni populacijski model 24
b) Populacijski model sa simulacijama mortaliteta juvenilnih jedinki 25
c) Populacijski model sa simulacijama katastrofa 26
d) Populacijski model sa simulacijama degradacije staništa 27
e) Populacijski model sa scenarijem povečanja staništa 28
f) Populacijski model sa scenarijem introdukcije vrste 28
5. REZULTATI 30
5.1. PROCJENA OPSTAJNOSTI POPULACIJE *A. KITAIBELII* S VRHOVA TURJAK I PLIŠ NA PAPUKU U SADAŠNJIM UVIJETIMA 30
5.2. PROCIJENA VJEROJATNOSTI IZUMIRANJA POPULACIJE U NAREDNIH 100 GODINA 31
a) Model dinamike rasta populacije s obzirom na stopu smrtnosti juvenilnih jedinki 32
b) Model dinamike rasta populacije s obzirom na učestalost požara kao primjer vanjskog okolišnog parametra koji utječe na dinamiku rasta populacije 36
c) Model dinamike rasta populacije s obzirom na degradaciju staništa (negativna promjena *K* vrijednosti) 41
5.3. PROCJENA OPSTAJNOSTI POPULACIJE *A. KITAIBELII* NA PAPUKU U SCENARIJU POVEĆANJA VELIČINE STANIŠTA UKLANJANJEM NASADA CRNOG BORA (*PINUS NIGRA*) 45
5.4. PROCJENA OPSTAJNOSTI POPULACIJE *A. KITAIBELII* NA PAPUKU U SCENARIJU S INTRODUKCIJOM VRSTE NA DVA NOVA VRHA LAPJAK I TOPLIČKA GLAVA (100 %-TNO POVEČANJE STANIŠTA) 47
a) Populacija Lapjak 47
b) Populacija Toplička glava 49
c) Temeljna populacija 52
d) Metapopulacija 54
6. RASPRAVA 57
7. ZAKLJUČAK 60
8. LITERATURA 61

1. UVOD

1.1. Rod *Ablepharus* Lichtenstein, 1823

Osnovna značajka vrsta roda *Ablepharus* Lichtenstein, 1823 je nedostatak očnih kapaka. Od nje i dolazi ime roda - latinska riječ *ablepharia* je medicinski naziv za nedostatak očnih kapaka (Szövényi i Jelić, 2011). Ovo svojstvo karakteristično je za zmije, dok se kod guštera rijetko pojavljuje. Kapci, koji su bili prisutni kod predaka, spojili su se i razvili u prozirnu čvrstu opnu koja pokriva površinu oka. Sve vrste imaju izduženo tijelo, duge repove i male udove te su vrlo slične. Žive skrovito, u listincu, ispod kamenja, granja, i u niskoj gustoj vegetaciji (Vitt, 2012).

Prema IUCN (2014) poznato je 6 vrsta:

Ablepharus bivittatus (Menetries, 1832)

Ablepharus budaki (Göçmen, Kumlutas i Tosunoglu, 1996)

Ablepharus chernovi (Darevsky, 1953)

Ablepharus deserti (Strauch, 1868)

Ablepharus kitaibelii (Bibron i Bory de Saint-Vincent, 1833)

Ablepharus rueppellii (Gray, 1839)

Baza podataka gmazova (The Reptile Database, 2014) navodi još 3 vrste:

Ablepharus darvazi (Yeriomchenko i Panfilov, 1990)

Ablepharus grayanus (Stoliczka, 1872)

Ablepharus lindbergi (Wettstein, 1960)

Općenito rasprostranjenje roda je od jugoistočne Europe, uključujući Balkanski poluotok i otočje Egejskog mora, preko Bliskog Istoka, pa sve do Pakistana i zapadnog dijela Indije (Ananjeva i sur., 2006; Vitt, 2012).

1.2. Ivanjski rovaš (Ablepharus kitaibelii)

a) Opis vrste

Ivanjski rovaš, *Ablepharus kitaibelii* (Bibron i Bory, 1833) (Slika 1) pripada redu Squamata i porodici Scincidae. *A. kitaibelli* jedan je od najmanjih vrsta guštera u Europi, a ujedno i najmanja vrsta guštera u Hrvatskoj. Ukupna dužina tijela uglavnom ne prelazi 13 cm. Rep je 1,3 – 1,6 puta duži od tijela (Arnold, 2002; Herczeg i sur., 2007). Karakteristični po nedostatku vidljivih očnih kapaka, ali i vitkom tijelu, s izrazito kratkim nogama, na koje se

nastavlja relativno debeli rep (Arnold, 2002). Spolni dimorfizam postoji – ženke su veće i krupnije od mužjaka (Arnold, 2002). Parenje se odvija tijekom travnja i svibnja, traje 30 do 60 sekundi i pritom mužjak ugrizom drži ženku za bokove (Arnold, 2002; Gruber, 1981). Ženke polažu jaja nekoliko centimetara duboko u tlo u razdoblju od kraja lipnja do početka kolovoza (Gruber, 1981). Inkubacija traje oko devet tjedana. S obzirom na način prehrane treba naglasiti da je *A. kitaibelii* izraziti predator širokog spektra plijena. Uglavnom se hrani sitnim člankonošcima neletačima, što je u korelaciji s njegovom veličinom i načinom kretanja (Herczeg i sur., 2007). Maksimalna starost zabilježena je kod jedinki iz zatočeništva i iznosi 3,5 godina (Arnold, 2002; Gruber, 1981).



Slika 1. *Ablepharus kitaibelii* s vrha Turjak (Papuk) (Fotografirao Ivan Damjanović)

b) Opisane podvrste

Novija literatura na temelju morfologije razlikuje 4 podvrste ivanjskog rovaša:

- ***A. kitaibelii fitzingeri* Mertens, 1952** (nom. nov. pro *Ablepharus pannonicus* Fitzinger, 1824)

Podvrsta karakteristična za Panonsku nizinu. Pojavljuje se u južnim dijelovima Slovačke, Mađarskoj, Hrvatskoj i u sjevernom dijelu Srbije (Ljubisavljević i sur., 2002; Herczeg i sur., 2004; Herczeg i sur., 2007a; Korsós i sur., 2008; Szövényi i Jelić, 2011) (Slika 2).

- ***A. kitaibelii kitaibelii*** (Bibron i Bory, 1833)

Naseljava područje Grčke uključujući i Jonske i Egejske otoke te zapadnu Tursku (europski dio i dio središnje i zapadne Anatolije) (Ljubisavljević i sur., 2002) (Slika 2).

- ***A. kitaibelii stepaneki*** (Fuhn, 1970)

Podvrsta prisutna na sjevernom dijelu Balkanskog poluotoka, jugoistočno od distribucije *A. k. fitzingeri* – u Rumunjskoj, Bugarskoj, Srbiji, Makedoniji, Albaniji (Ljubisavljević i sur., 2002, Szövényi i Jelić, 2011) (Slika 2).

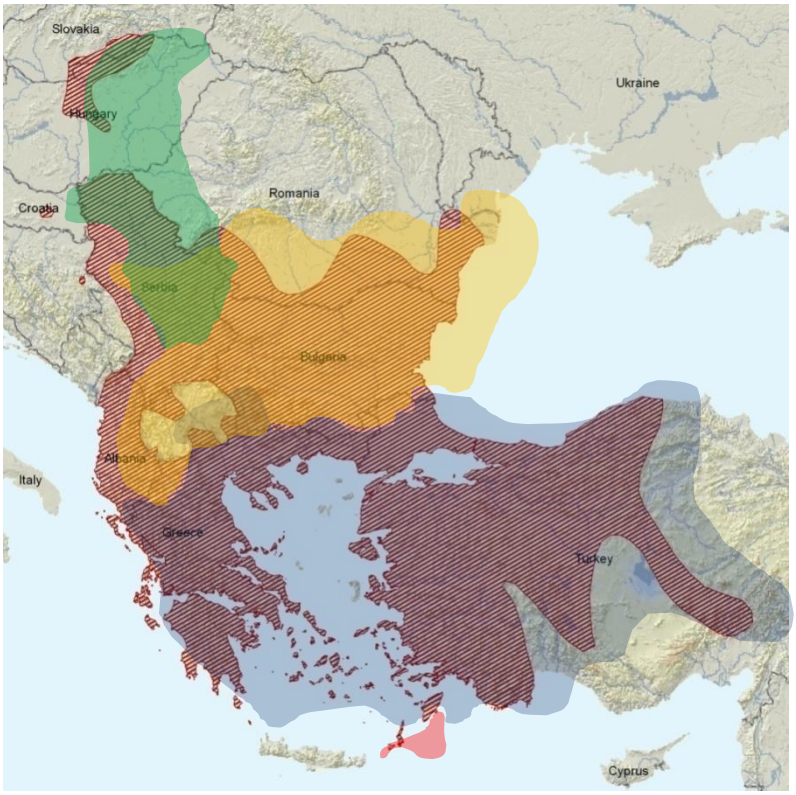
- ***A. kitaibelii fabichi*** (Stepanek, 1938)

Ograničeno rasprostranjena na nekoliko otoka istočno od Krete: Armathia, Kasos, Karpatos i otočić Mikronisi blizu obale Krete (Arnold, 2002; Ljubisavljević i sur., 2002) (Slika 2).

c) Rasprostranjenost

Ivanjski rovaš jedini je predstavnik roda *Ablepharus* u Europi, a ujedno i najsjevernije rasprostranjena vrsta porodice Scincidae na starom kontinentu (Herzeg i sur., 2007; Korsós i sur., 2008; Ljubisavljević i sur., 2002). Rasprostranjen u Europi od južnog dijela Slovačke, preko Mađarske, većim dijelom Srbije, Bugarske, južnim i istočnim dijelom Rumunjske, Makedonije, Albanije, Grčke, uključujući i egejsko i jonsko otočje, istočnog dijela Hrvatske sa izoliranim populacijama na planini Papuk i gradskom parku u Iloku (Szövényi i Jelić, 2011) (Slika 2). U sjeverozapadnom dijelu rasprostranjenosti prisutne su dvije morfološki različite podvrste koje su u interakciji u širokoj prijelaznoj zoni u središnjoj Srbiji (Szövényi i Jelić, 2011). *A. k. fitzingeri* Mertens, 1952 nastanjuje područje Karpatskog bazena (Szövényi i

Jelić, 2011) i ujedno predstavlja najzapadnije i najsjevernije rasprostranjenu podvrstu. Izolirani lokaliteti u Slovačkoj i Mađarskoj i nedavno otkrivene populacije na lokalitetima Turjak (Papuk) i gradski park u Iloku pripadaju gore navedenoj podvrsti (Szövényi i Jelić, 2011). *A. k. fitzingeri* ujedno je i endem Panonske nizine kao zemljopisnog područja (Korsos i sur., 2008). Druga podvrsta, *A. k. stepaneki* Fuhn, 1970, pojavljuje se na sjevernom dijelu Balkanskog poluotoka, jugoistočno od područja rasprostranjenosti *A. k. fitzingeri* (Szövényi i Jelić, 2011).



Slika 2. Okvirna distribucija *A. kitaibelii* i pripadajućih podvrsta. Zeleno označena distribucija *A. k. fitzingeri*, žuto *A. k. stepaneki*, plavo *A. k. kitaibelii*, crveno *A. k. fabichi*, (Izvor: IUCN 2014 (web 1); modificirano prema literaturnim podacima)

d) Opis staništa

Ivanjski rovaš naseljava raznolika staništa nizinskih (stepskih) i brežuljkastih područja na različitim tipovima podloge: pješčenjak, dolomit, vapnenac, bazalt, pijesak, vulkanske stijene (Arnold, 2002; Herczeg i sur., 2004). Preferira staništa otvorenog tipa, travnate površine s niskim, prizemnim žbunjem, golo i stjenovito tlo (Herczeg i sur., 2007), kao i šumska tla bogata listincem. S obzirom na sklonost zakopavanja u supstrat obično se nalazi na podlozi sa slojem tla rastresite strukture koje je porozno i ne zadržava puno vode (Herczeg i

sur.,2007; Pasuljević, 1976). Od šumskih sastojina najčešći je u onima u kojima dominira hrast (*Quercus pubescens*, *Quercus* sp.) i klek (*Juniperus* sp.), a zabilježen je i na rubu kestenove šume, u rijetkoj crnogorici (*Pinus brutia*, *Pinus nigra*, *Pinus* sp.) te mješovitim borovim i hrastovim šumama (Arnold, 2002; Gruber, 1981; Ioannidis i sur., 2008; Korsós i sur., 2008; Kumlutas i sur., 2005; Pasuljević, 1976). Na brežuljkastim terenima ima veću sklonost padine jugoistočne i južne ekspozicije (Arnold, 2002; Pasuljević, 1976). Sklon je ka mikrostaništima koja mu omogućuju brzi bijeg i neposredno sakrivanje od predatora jer po anatomiji i oblikom tijela je smanjene mogućnosti trčanja i razvijena prizemna vegetacija daje mu dodatni oslonac prilikom kretanja i omogućuje lakše i brže skrivanje (Arnold, 2002; Covaciu-Marcov i sur., 2009; Herczeg i sur., 2007; Pasuljević, 1966; Szövényi i Jelić, 2011; Tomović i sur., 2001).

e) Zaštita

Ivanjski rovaš nalazi se u Dodatku II Bernske konvencije (Vijeće Europe, 1994; NN 66/00) i u Dodatku IV Europske direktive o staništima Europske unije (Europska komisija, 1992) kao vrsta kojoj je potrebna stroga zaštita. U Republici Hrvatskoj prema Pravilniku o proglašavanju divljih svojti zaštićenim i strogo zaštićenim Zakona o zaštiti prirode ima status strogo zaštićene svojte (NN 70/05, 139/08, 57/11), a prema Pravilniku o strogo zaštićenim vrstama ima status ugrožene vrste (NN 144/13). Zbog gotovo nepostojećih podataka o prisutnosti vrste, regionalno se vrsta dugo vodila kao "nedovoljno poznata" (DD - Data Deficient) (Janev-Hutinec i sur., 2006). Na temelju novih saznanja o vrsti regionalni status ivanjskog rovaša promijenjen je u kategoriju ugroženih svojti (EN B2ab(iii)) (Szövényi i Jelić, 2011). *A. kitaibelii* prema IUCN-ovoj listi ugroženih vrsta pripada skupini najmanje zabrinjavajuća vrsta (LC - Least Concern) (IUCN, 2014).

1.3. Vijabilnost populacije

a) Definicija

Vijabilnost populacije, ili sposobnost populacije za opstanak, definirana je kao vjerojatnost da populacija, s obzirom na trenutnu veličinu, neće izumrijeti tijekom antropogeno definiranog vremenskog perioda (White, 2000).

Za procjenu vijabilnosti populacije najčešće se koriste dvije osnovne procedure: analiza vijabilnosti popuacije (*Population viability analisys*, PVA) i najmanja vijabilna populacija (*Minimum viability population*, MVP) (White, 2000).

Analize vijabilnosti populacije su izrazito osjetljive na kvalitetu unesenih podataka (King i sur., 2014) a procjena vjerojatnosti izumiranja ovisi o vremenu provedenom u prikupljanju podataka (Reed i sur., 2002) pri čemu nedostatak dugoročnih projekata vodi ka podcjenjivanju vjerojatnosti izumiranja (Reed i sur., 2002).

b) PVA - Analiza vijabilnosti populacije

PVA je skup kvantitativnih metoda i analiza koji predstavlja procjenu vjerojatnosti da će populacija specifične veličine opstati određeni vremenski period, odnosno procjenjuje se vjerojatnost izumiranja populacije (Akçakaya i sur., 2000; Keedwell, 2004; Morris i sur., 2000; Morris i sur., 2002; White, 2000). PVA analiza igra važnu ulogu u izradama programa zaštite i očuvanja ugroženih vrsta (Keedwell, 2004; Mace i Sillero-Zubiri, 1997; Patterson i sur., 2008; Pryde i sur., 2005; Zhang i Zheng, 2007).

c) MVP - Minimalna vijabilna populacija

MVP analiza predstavlja procjenu minimalne vijabilne populacije, koja se definira kao brojčano najmanja populacija za koju se sa pozitivnom vjerojatnošću može reći da će opstati određeno vrijeme u svom prirodnom okruženju (Shaffer, 1981; White, 2000). MVP implicira da postoji kritična vrijednost broja jedinki koji će osigurati uz prihvatljivi rizik, da će populacija opstati u vijabilnom stanju određeni vremenski period, u protivnom će izumrijeti (Gilpin i Soule, 1986; Rai, 2003). Prema Reed i sur., (2002) kritična vrijednost je ona sa 99%-tnom vjerojatnošću opstanka kroz 40 generacija. Međutim, analiza nije općenito primjenjiva jer njena šabloniziranost nije realna u primjeni na stvarnim populacijama (Flather i sur., 2011).

d) Vremenski interval

Zajednička komponenta koju zahtijevaju obje metode je vremenski period, antropogeno određeno vrijeme na koje se odnosi vjerojatnost izumiranja (White, 2000). Duljina trajanja vremenskog perioda je specifična i ovisi o biologiji i ekologiji vrste koja se istražuje. Mace i Sillero-Zubiri, (1997) su u modelu vijabilnosti populacija etiopskog vuka (*Canis simensis*) vremenski interval ograničili na 50 godina, uzimajući u obzir socijalne i

biološke karkteristike etiopskog vuka. Međutim, kada se modeliraju dugoživuće vrste niskih stopa razmnožavanja i vremenski intervali moraju biti u skladu s time. Tako su King i sur., (2014) procjenjujući uspjeh reintrodukcije zapadne nizinske gorile (*Gorilla gorilla gorilla*) odredili vremenski period u trajanju od 200 godina.

1.4. Opstojnost populacije

a) Definicija

Opstojnost populacije definira se kao sposobnost populacije u preživljavanju. Za populaciju kojoj se predviđa izumiranje vremenski period do predviđenog izumiranja zapravo je vrijeme u kojemu se očekuje da će populacija biti sposobna preživjeti (White, 2000).

b) Opstojnost i biološka sukcesija

Opstojnost populacije ovisi o stupnju biološke sukcesije kojemu ta populacija pripada, pri čemu dolazi do povećanja opstajnosti u kasnijim stadijima (White, 2000). Isto tako, biljne i životinjske populacije koje čine zajednicu imati će dulje vrijeme opstojnosti ako je zajednica ujedno i dugoživući seralni stadij (White, 2000).

c) Opstojnost i početna veličina populacije

Početna veličina populacije predstavlja brojčanu vrijednost populacije koja se uzima kao početna vrijednost prilikom izrade modela opstojnosti i procjene vjerojatnosti izumiranja (Hutchinson, 1978). Povećanjem početne veličine populacije smanjuje se vjerojatnost izumiranja (Shaffer, 1981; Shaffer i sur., 1985). Početna veličina populacije je važna odrednica opstojnosti (Reed i sur., 2002), ali treba naglasiti da opstojnost u pogledu početne veličine nije linearna iako su u proporcionalnom odnosu (White, 2000).

d) Opstojnost i stopa razmnožavanja

Populacije sa visokom stopom razmnožavanja pokazuju veću opstojnost naspram izumiranja (Foley, 1994). Međutim, sisavci većih tjelesnih veličina pokazuju veliku opstojnost pri niskim gustoćama, i tipično imaju niske stope razmnožavanja, gledajući proces razmnožavanja iz obje perspektive - godišnje na razini populacije i po jedinki populacije (Silva i Downing, 1994).

e) Opstojnost i okolišni uvjeti

Povećanje varijacija, odnosno promjena u jedinici vremena vodi ka smanjenju opstojnosti (Lande, 1988; Lande, 1993). Prvenstveno zbog toga što se prirodne katastrofe, npr. uragani, požari ili poplave, češće događaju u sustavima s visokim vrijednostima vremenskih varijacija, tako da se populacije iz tropskih područja mogu održati na razinama gustoća mnogo nižim od populacija koje naseljavaju područja umjerene klime, vjerojatno zbog nižih stopa okolišnih promjena (White, 2000). Nadalje, čak i prognozirani i predviđeni učinci mogu imati utjecaja zato što bez obzira što se pojedini faktori mogu prognozirati njihov opseg i jačinu nije moguće predvidjeti (White, 2000).

Naposljetku može se reći da okolišni uvjeti koji smanjuju nivo zasićenosti ili uvećavaju varijacije u stopama rasta populacije umanjuju opstojnost (Lande, 1988; Lande, 1993).

1.5. Osnovni populacijski model

a) Leslie matrični model

Leslie matrični modeli (Leslie, 1945) obično se koriste kao okviri za modeliranje modela vijabilnosti populacije (White, 2000). Model je diskretan, znači da vrijeme teče u koracima nasuprot kontinuiranosti, i dobno ovisan, što znači da izgradnja modela uzima u obzir dobnu strukturu (Montshiwa, 2007). Pryde i sur., (2005) su koristili dobno-strukturirani matrični model kako bi procijenili stopu rasta populacije dugorepog šišmiša (*Chalinolobus tuberculatus*) na Novom Zelandu tako da su u model uključili prosječnu stopu opstanka juvenilnih jedinki i ženki dobivenu iz prosječnog modela opstanka, zajedno s prosječnim udjelom ženki koje se pare svake godine, unoseći podatke dobivene kroz desetogodišnju terensku studiju.

Svako ponavljanje izračuna zahtijeva vremensku varijaciju, a preinaka Leslie matričnih parametara u nasumične varijable je standardni pristup tome postupku (Burgman i sur., 1993), čime se unosi stohastičnost u model (Montshiwa, 2007).

Međutim, korištenje Leslie matričnog okvira zanemaruje individualnu heterogenost, stoga je vjerojatno da podcjenjuje opstojnost (White, 2000). Uključivanje individualne heterogenosti zahtijeva individualno usmjereni model (DeAngelis i sur., 2005; Grimm i sur., 2004) i stoga se konceptualno razlikuje od osnovnog Leslie matričnog pristupa (White, 2000).

b) Ovisnost gustoće

Važna je komponenta procjene opstojnosti populacije (Boyce, 1992; Stacey i Taper, 1992). Može se reći da više stope gustoće pridonose povećanju opstajnosti osim kada vrijednost gustoće premašuje kapacitet okoliša, međutim, Mace i Sillero-Zubiri, (1997) su radom na etiopskom vuku pokazali da je udio ženki koje se pare u obrnuto proporcionalnom odnosu s razinom gustoće.

Lande (1993) je demonstrirao da važnost okolišne stohastičnosti i nasumičnih katastrofa ovisi o mehanizmu ovisnosti gustoće u populaciji temeljenoj na vrijednosti *K* nivoa zasićenosti. Modele ovisnosti gustoće, vjerojatnosti izražene kroz različite jednadžbe pružili su mnogi autori (Hassell, 1975; Hassell i sur., 1976; May i Oster, 1976; Moran, 1950; Ricker, 1975). Međutim, način na koji je ovisnost gustoće uključena u model značajno utječe na procjene opstojnosti (Pascual i sur., 1997).

c) Allee efekt

Stopa rodnosti po glavi (jedinici) opada pri niskim gustoćama, zato što na primjer, dolazi do povećanja teškoća i prepreka u pronalasku partnera za parenje (Yodzis, 1989). Ovo ponašanje je poznato kao ponašanje Allee-tipa i utječe na per capita stopu rasta populacije i naziva se Allee efekt (Allee, 1931). U teoriji, ravnoteža niske gustoće će se održati samo u determinističkoj ravnoteži, gdje su stope rodnosti jednake stopama smrtnosti. Međutim, s obzirom na stohastičnost, populacija može krenuti silaznom putanjom ispod ravnoteže niske gustoće i tako biti gurnuta u izumiranje (White, 2000).

1.6. Modeli rasta populacije

Opstojnost populacije prije svega ovisi o stohastičnosti, odnosno varijaciji (Dennis i sur., 1991). Izvori promjena i njihov doseg određuju vjerojatnost izumiranja, uzimajući u obzir da su mehanizmi rasta populacije specifični za svaku pojedinu vrstu (White, 2000). Proces promjene rezultat je demografskih, okolišnih i individualnih varijacija. Iako je očekivani ishod za određeni model opstanak populacije, nasumične varijacije, odnosno stohastičnost, sprječavaju da se ovakav ishod uvijek ostvari (White, 2000).

a) Deterministički model rasta populacije

Osnovna karakteristika determinističkog modela je nedostatak slučajnosti, odnosno fluktuacija u modelu. Posljedica takvog pristupa je predvidljivost u stopi rasta populacije - ona raste eksponencijalno, što nije slučaj u stvarnim populacijama (White, 2000).

Uzmimo u obzir populaciju bez varijacija (promjena), populaciju koja se kvalificira za jedan jednostavan, o gustoći neovisan, model rasta $N_{t+1} = N_t(1+R)$ (Holsinger, 2013; White, 2000) gdje je N_t -veličina populacije u vremenu *t*, a R-konačna stopa promjene unutar populacije kao funkcija stopi rođenih i umrlih pa je: $R = b - d(birth - death)$ (White, 2000). Model je deterministički, stoga je i populacija deterministička. Vrijednost $R \geq 0$ znači da će populacija opstati, $R < 0$ znači da će populacija izumrijeti. Kada stopa rođenih prelazi ili je jednaka stopi umrlih populacija će opstati s vjerojatnošću 1 u ovom determinističkom modelu (White 2000).

b) Stohastički model rasta populacije

U stvarnim, realnim populacijama nije zastupljen deterministički model rasta. Slučajne, tj. nasumične varijacije koje čine stohastičnost, osiguravaju promjenjljivost rasta populacije u antropološki određenom vremenskom periodu (White, 2000).

Deterministički model rasta možemo učiniti stohastičkim promjenom R varijable uvodeći vrijednosti parametara za *b* i *d* koji su nasumično primjenjeni na populaciju tako da je R funkcija dvije nasumične varijable (White, 2000).

Za svako vrijeme *t* odredimo, stohastički, broj jedinki koji će biti dodan populaciji preko rođenja, i broj jedinki koji će biti oduzet smrću. Pretpostavimo da je stopa rodnosti jednaka stopi smrtnosti: *b=d=0,5*. To znači da, u prosjeku, 50 % jedinki iz N_t populacije će roditi jednu novu jedinku, i osigurati dopunu populaciji, i 50 % jedinki, u prosjeku, N_t populacije će umrijeti i biti odstranjeno iz populacije. Zbog toga za očekivati je da će veličina populacije ostati stalna, zato što je broj rođenih jednak broju umrlih (White, 2000).

Najprikladniji stohastički model za ovaj proces bio bi binomna ili dvočlana distribucija (White, 2000). Binomni model može se opisati bacanjem novčića dva puta za svaku pojedinu jedinku. Prvo bacanje određuje da li će jedinka dati potomstvo u obliku jedne nove jedinke kao dodatku za populaciju N_{t+1}, a drugo bacanje određuje da li jedinka koja je član populacije N_t ostaje živa kako bi bila dio populacije N_{t+1}, ili jedinka umire i odstranjuje

se iz populacije N_t (White, 2000). Binomni model se koristi za izražavanje demografske varijacije (White, 2000).

1.7. Izvori varijacija koji utječu na opstojnost

a) Varijacija procesa i varijacija uzorkovanja

Kombinirani i udruženi efekti, odnosno djelovanja, demografskih, vremenskih, prostornih i individualnih varijacija nazivaju se zajedničkim imenom varijacija procesa (White, 2000). To znači da svaki od ovih izvora varijacija utječe na procese unutar populacije. Varijacija procesa se koristi kao opći pojam za svojstvenu stohastičnost promjena na razini populacije (White, 2000).

Varijacija uzorkovanja posljedica je uzorkovanja populacija u različito vrijeme svake godine, ili za vrijeme različitih sezonskih ciklusa populacija, a može se umanjiti skraćivanjem intervala uzorkovanja i usklađivanjem sa sezonskim ciklusima populacije (Larsen i sur., 2001). Nemoguće je mjeriti stvarnu stopu opstanka populacije. Promatra se realizacija procesa, ali ne točna vrijednost, odnosno promatra se posljedica stohastičnog procesa a nemogu se mjeriti konkretne vrijednosti parametara (White, 2000).

b) Demografska varijacija

Demografska varijacija je parametar koji se očituje bez obzira da li će se jedinka razmnožavati ili ne, da li će opstati ili neće (White 2000). Ako pretpostavimo da vjerojatnosti opstanka svake jedinke u populaciji iznosi 0,8, to znači da će u prosjeku 80 % populacije opstati svaki puta kada se ova vrijednost primjeni (White, 2000). Međutim, populacije s puno nižim rasponom veličine mogu preživjeti duži niz godina, naposljetku s izumiranjem kao krajnim rezultatom (White, 2000). Zbog toga je ovaj izvor varijacije osobito važan za male populacije i naziva se demografska varijacija. Drugim riječima, kako se veličina populacije povećava relativna promjena se smanjuje prema 0. Odnosno, promjena N_{t+1} / N_t smanjuje se prema 0 kako N_t ide prema beskonačno. Zbog toga demografska varijacija općenito ne predstavlja problem za opstanak većih populacija (White, 2000).

c) Okolišna varijacija

Okolišna varijacija je važna komponenta dinamike rasta populacije (Lögdberg, 2011) koja obuhvaća vremensku i prostornu varijaciju, pri čemu obje varijacije diktiraju okoliš populacije, jedna u vremenu a druga u prostoru (White, 2000).

Okolišna stohastičnost se može uključiti u model tako da se vrijednosti parametara prostorne i temporalne varijacije odabiru kao nasumične varijable koje se mijenjaju svake godine (White, 2000). Okolišnu varijaciju obradili su mnogi autori (Lewis Jr., 1978; Hanski, 1982; Stewart-Oaten i Bence, 2001; Bruce, 2002; Bailey i sur., 2004; Augustine, 2010; Belisle i sur., 2014).

Vremenska varijacija

Temporalna varijacija predstavlja promjenu kroz vrijeme (White, 2000), a čine ju dvije komponente: varijacija kroz godinu i varijacija tijekom godina (Larsen i sur., 2001). Njihovo razlikovanje važno je za procjenu uočavanja smjera promjene, odnosno stanja indikatora za pojedinu godinu (Larsen i sur., 2001). Beissinger (1995) je dokazao proporcionalnu korelaciju između opstojnosti u obliku reproduktivnog uspjeha i brojnosti u odnosu na varijaciju, u ovom slučaju vodni režim za pojedinu godinu.

Prostorna varijacija

Prostorna varijacija je tip promjene preko krajolika, tj. predjela kojeg naseljava populacija (White, 2000). U prostorno podjeljenim populacijama niz lokalnih subpopulacija može biti u spacijalnoj korelaciji (Lögdberg, 2011) tako da prostorne promjene uzrokuju sinkronizaciju dinamike rasta subpopulacija (Lögdberg, 2011). Ako su stope imigracije i emigracije visoke preko cijelog staništa, visoka prostorna varijacija može dovesti i do visoke opstojnosti (White, 2000), zbog toga što je vjerojatnost da će sve subpopulacije biti pogođene istodobno od strane neke katastrofe izrazito niska (White, 2000).

Prema tome, u suprotnosti sa temporalnom varijacijom, gdje povećanje varijacije vodi ka manjoj opstojnosti, veće stope prostorne varijacije vode ka povećanju opstojnosti, s obzirom da imigracija i emigracija učinkovito miješaju subpopulacije (White, 2000).

Ako su stope imigracije i emigracije niske, tada prostorna varijacija dijeli populaciju na manje subpopulacije koje će najvjerojatnije pretrpjeti izumiranja zbog djelovanja demografske varijacije na male populacije (White, 2000).

d) Individualna varijacija

Svi dosada opisani modeli pretpostavljaju da sve jedinke u populaciji imaju jednake izglede za opstanak i reprodukciju, iako se ove stope mijenjaju u vremenu (White, 2000). Ali postavlja se pitanje što se događa ako svaka jedinka u populaciji ima različite stope opstanka i razmnožavanja. Razlike između jedinki unutar populacije čine individualnu heterogenost i predstavljaju individualnu varijaciju (White, 2000).

Mnoge studije i projekti su pokazali individualnu heterogenost na stopama opstanka i razmnožavanja jedinke, npr. Clutton-Brock i sur., (1982) demonstrirali su cijeloživotni reproduktivni uspjeh ženki običnog jelena (*Cervus elaphus*). Razlike u učestalosti smrtnosti teladi između majki čine veći dio varijance u uspijeh nego razlike u plodnosti.

Bartman i sur., (1992) su pokazali da je prezimljavanje lanadi crnorepog jelena (*Odocoileus hemionus*) zapravo funkcija tjelesne mase laneta na početku zime, pri čemu treba naglasiti da lanad veće tjelesne mase na početku zime ima veću vjerojatnost prezimljavanja. Pojedinačna heterogenost je jako važan element u održavanju vijabilnosti i pozitivno utječe na opstojnost (White, 2000).

Za simulaciju individualne varijacije stope rodnosti i smrtnosti svake jedinke izvučene su iz beta distribucije, pri čemu dobivene vrijednosti vrijede za čitav životni vijek jedinke i ne mijenjaju se kroz vrijeme. Rezultat je individualno bazirani model (White, 2000).

Genetska varijacija

Individualna varijacija najčešće je uzrokovana genetskom varijacijom, razlike između jedinki rezultat su razlika u njihovim genomima, odnosno genetskim sadržajima (White, 2000). Dešifriranje obrazaca genetske varijacije unutar vrste je esencijalno za shvaćanje dinamike populacije, prilagodba na lokalne uvjete i različitosti među populacijama (Marsden i sur., 2012). Prirodna selekcija igra važnu ulogu u genetskoj varijaciji prisutnoj u populaciji koja je u opadanju. Velika većina vrsta kojima se pridodaju visoke procjene vjerojatnosti izumiranja pretrpjele su ozbiljan pad ukupne brojnosti (Keller i sur., 1994). Preostali genotipovi u populaciji vjerojatno nisu nasumični uzorci prvotne populacije (Keller i sur., 1994), odnosno genotipovi koji su preostali nakon pada brojnosti su "preživjeli" i imaju veću vjerojatnost opstojnosti nego što bi imao nasumičan uzorak prije pada brojnosti (Keller i sur., 1994). Genetska varijacija je važan čimbenik opstanka malih populacija, međutim, u malim populacijama može doći do pada genetske varijacije zbog smanjene zalihe gena, zbog genetskog drifta (Marsden i sur., 2012), pri čemu su udjeli mutacija zanemarivi (Mace i

Sillero-Zubiri, 1997) i kada su i međuodnosi jedinki s okolnim populacijama niske, stope emigracije i imigracije, tj. protok gena, mala je vjerojatnost pozitivnog pomaka genetske varijacije u populaciji (Mace i Sillero-Zubiri, 1997; Marsden i sur., 2012).

Fenotipska varijacija

Treba naglasiti da je i fenotipska varijacija isto moguća, odnosno da može uzrokovati individualnu heterogenost (White, 2000). Jedinke koje imaju pristup boljim, kvalitetnijim resursima kao i količinski široj paleti resursa imaju više stope reprodukcije i veću opstojnost iako su genetski potpuno identične (White, 2000).

e) Beta distribucija

Jedan od načina za generiranje nasumičnih stopa opstanka svakako je beta distribucija koja je opisana s dva parametra, α i β, pri čemu vrijedi; $\alpha > 0$ i $\beta > 0$. Prednosti beta distribucije leže u činjenici da se nasumične vrijednosti mogu ograničiti na određeni interval, recimo na interval 0-1 (White, 2000). Za srednju vrijednost od 0,5 raspodjela je simetrična oko srednje vrijednosti, ali opseg varijacije može se mijenjati ovisno o tome koliko je šiljasta distribucija, odnosno, koliko je šiljast grafički prikaz (White, 2000).

Za beta distribuciju potrebno je odrediti vrijednosti za α i β. Za danu srednju vrijednost (μ), varijaciju (σ^2) ili standardnu devijaciju (σ) (White, 2000):

$$\alpha = \frac{\mu^2(1-\mu)}{\sigma^2} \quad \beta = \frac{\left[\sigma^2 + \mu(\mu-1)\right](\mu-1)}{\sigma^2}$$

Srednju vrijedost distribucije daje $\alpha/(\alpha+\beta)$, a varijaciju $\alpha\beta/\left[(\alpha+\beta)^2(\alpha+\beta+1)\right]$.

Standardne devijacije stopa rodnosti i smrtnost utječu na opstojnost zbog toga što ove vrijednosti određuju standardnu devijaciju od R (White, 2000). Što je manja standardna devijacija, model se sve više približava slučaju demografske varijacije, a isto tako, kako N_t ide u beskonačno, determinističkom modelu (White, 2000). Povećanjem standardne devijacije, povećavaju se varijacije u N_t populaciji, i bez obzira na veličinu populacije, smanjuje se opstojnost (White, 2000).

1.8. Procjena varijacije

a) Direktna procjena varijacije

Komponente PVA zahtijevaju da su parametri populacije ili njihove distribucije poznati bez greške, tj. točne vrijednosti parametara su promatrane, a ne procijenjene. Međutim, svaka procjena uključuje varijaciju uzorkovanja, odnosno, mi samo imamo procjenu stvarnog parametra, a ne njegovu točnu vrijednost. Za ispravnu procjenu temporalne varijacije niza, varijacija uzorkovanja procjena mora biti uklonjena (White, 2000).

Razmotrimo sljedeći primjer: situaciju procjene stopi opstanka prezimljavanja svake godine u vremenskom periodu od 10 godina. Svake godine stopa opstanka se razlikuje od ukupnog prosjeka, zbog različitih uvjeta svake godine. Ako je ukupni stvarni prosjek S, tada, stopu opstanka za svaku godinu možemo smatrati kao S plus devijacija koju pripisujemo vremenskoj varijaciji e_i i devijacija koju pripisujemo varijaciji uzorkovanja f_i odnosno: $S + e_i + f_i$ (White, 2000).

U stvarnosti, mi nikada nismo u mogućnosti promatrati godišnje stope zbog varijacije uzorkovanja ili demografske varijacije (White, 2000). Na primjer, uzmimo u obzir bacanje u zrak 10 novčića. Znamo da je točna vjerojatnost glave ili pisma 0,5 odnosno 50 %, ali mi nećemo uvijek promatrati točno tu vrijednost. Iako je stvarna vjerojatnost opstanka 0,5 mi ne bi nužno vidjeli stvarni S opstanka populacije za svaku godinu (White, 2000).

b) Indirektna procjena varijacije

Individualna heterogenost se očituje u oba parametra, reprodukciji i u opstanku. Bartman i sur., (1992) su pokazali da je prezimljavanje lanadi cnorepog jelena (*O. hemionus*) povezano s masom lanadi na početku zime. Prema tome, jedan od pristupa za modeliranje individualne heterogenosti je pronaći korelata opstanku, a koji se može mjeriti, i zatim razviti statistički model distribucije ovog korelata. Tada se distribucija korelata može uzorkovati za dobivanje procjene opstanka individue, to jest pojedine jedinke. Jedan od primjera za korelat je svakako masa jedinke kao jedna lako mjerljiva varijabla koja se odnosi na fizičku spremnost jedinke.

Ukratko, izražava se modelom logističke regresije:

$$\log\left(\frac{S}{1-S}\right) = \beta_0 + \beta_1$$

Gdje je opstanak (S) predviđen kao funkcija mase. Za simulaciju individualne heterogenosti u opstanku lanadi tijekom zime mogu se izvući vrijednosti iz normalne distribucije naposlijetku za dobivanje procjene opstanka. Naposlijetku, možemo zaključiti da je masa lanadi uzorkovana za procjenu njihove distribucije, zatim je ta distribucija uzorkovana da pokaže, iliti inducira, varijaciju u stopama opstanka.

Drugi način procjene preko modeliranja vremenskih prilika može se vidjeti u radu Cézilly i sur., (1996) na karipskom plamencu (*Phoenicopterus ruber roseus*). Ovaj pristup sugerira modeliranje jačine zime kao nasumične varijable i procjenu opstanka kao funkciju ove nasumične varijable.

Najveći nedostatak indirektnog pristupa je ignoriranje varijacije uzorkovanja u modelu. Odnosno, model logističke regresije već sadrži varijaciju uzorkovanja jer su njegovi parametri procijenjeni iz promatranih podataka, međutim mi ne znamo kolika je greška procjene. Prema tome, potreban je i model koji povezuje kovarijantni proces s biološkim (White, 2000).

Obje metode pružaju mehanizme unosa varijacije u model vijabilnosti populacije, pri čemu treba naglasiti da prednost korištenja podataka vremenkih uvjeta za unos vremenske varijacije u model leži u činjenici da je dostupna znatno veća količina vremenskih i klimatskih podataka za razliku od bioloških podataka koji se odnose na stope opstanka i razmnožavanja (White, 2000).

2. CILJ RADA

Cilj ovog diplomskog rada je procjeniti opstojnost populacije *A. kitaibelii* s vrhova Turjak i Pliš na Papuku u današnjim uvijetima, te procijeniti vjerojatnost izumiranja populacije u narednih 100 godina. Nadalje, obavit će se procjena opstojnosti populacije *A. kitaibelii* na Papuku u scenariju s povećanjem veličine staništa uklanjanjem nasada crnog bora (*P. nigra*). Procjeniti će se i opstojnost populacije *A. kitaibelii* na Papuku u scenariju s introdukcijom ivanjskog rovaša na dva nova vrha Lapjak i Topličke glava, te će se istražiti glavni čimbenici i uzroci trenda dinamike rasta populacije.

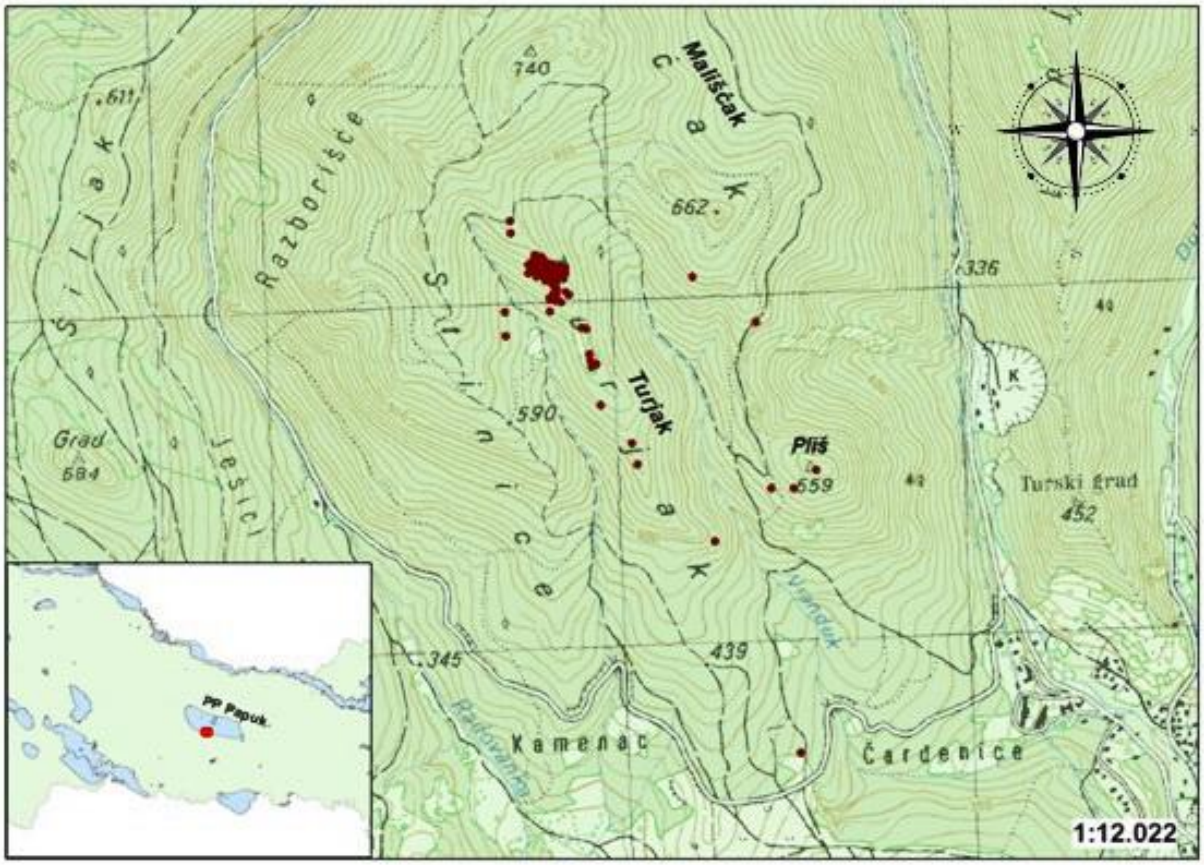
3. PODRUČJE ISTRAŽIVANJA

3.1. Papuk

Papuk je dio zapadnoslavonskog gorja koje okružuje Požešku kotlinu. Nalazi se na njezinoj sjeverozapadnoj strani. Pruža se u smjeru sjeverozapad-jugoistok te je najvećim dijelom unutar granica istoimenog Parka prirode (Slika 3).

Jedna od osobitosti Papuka je izuzetna geološka i litološka raznolikost koja podrazumijeva razne tipove stijena i formacije iz svih razdoblja geološke prošlosti. Također, u središnjem i sjeveroistočnom dijelu te okolici naselja Velika prisutan je krški reljef (trijasne vapnenačke i dolomitne naslage) što je netipično i rijetko za istočnu Hrvatsku (Topić i Vuković, 2010; JU PP Papuk, 2010).

Većinu vegetacije Papuka čine šume i to prvenstveno zajednice bukve koja dominira u višem pojasu. Najzastupljenija je šuma obične bukve s lazarkinjom (*Galio odorati-Fagetum sylvaticae* Sougnez et Thill 1959). U nižem pojasu prevladavaju hrastove šume, pretežno hrasta kitnjaka (*Festuco-Quercetum petraeae* – šuma hrasta kitnjaka s brdskom vlasuljom, *Epimedio-Carpinetum* – šuma hrasta kitnjaka i običnog graba, *Quercetum frainetto-cerris* – šuma sladuna i cera i dr.). Mjestimično su prisutne azonalne zajednice i kulture crnogorice (šumskog i crnog bora, smreke i ariša) (Topić i Vuković, 2010).



Slika 3. Nalazi *A. kitaibelii* na području Papuka u razdoblju od 2008. do 2012. (Arhiva HHD HYLA) (Web 2)

3.2. Vrh Turjak

Ivanjski rovaš pronađen je na južnim obroncima Papuka u blizini naselja Velika, na području predloženog posebnog botaničkog rezervata "Turjak – Mališćak – Lapjak – Pliš" nazvanog po 4 susjedna brda koje obuhvaća (JU PP Papuk, 2010). Na području Pliša nađen je manji broj jedinki, dok se u vršnoj zoni Turjaka nalazi stabilna populacija te je na ovom lokalitetu proveden najveći dio terenskih istraživanja (Slika 4). Lokalitet se nalazi na oko 600-685 m nadmorske visine. Na nižim nadmorskim visinama Turjaka ivanjski rovaš je sporadično zabilježen. Ukupna površina pogodnih staništa Turjaka i Pliša iznosi svega 26, 9845 hektara.

Vegetacijom na lokalitetu Turjak (Papuk) dominiraju šume hrasta medunca *Quercus pubescens* sa grmovima crnog jasena *Fraxinus ornus* i smreke *Juniperus communis,* i otvorena područja kamenitog šumskog tla prekrivenog prostranim i razvijenim travnatim slojem (*Chrysopogon gryllus, Festuca* sp., *Carex* sp.) (Szövényi i Jelić, 2011). Prema

Nacionalnoj klasifikaciji staništa (NKS), ovo stanište pripada *Orno-Quercetum pubescentis* Klika 1938 tipu. Ovakav tip staništa uglavnom dolazi na strmim, vlažnim i izrazito toplim južnim padinama planina sjeverne Hrvatske (Szövényi i Jelić, 2011). Na Papuku ovaj tip staništa je ograničen na svega nekoliko manjih područja s dolomitnim stijenama kao supstratom u samoj blizini naselja Velika (vrhovi Turjak, Pliš i Mališćak) (Szövényi i Jelić, 2011).



Slika 4. Stanište *A. kitaibelii* na vrhu Turjak (Papuk) (Fotografirao Ivan Damjanović)

4. MATERIJALI I METODE

4.1. Terenski rad

Terenska istraživanja i prikupljanje podataka provodila su se nekoliko puta godišnje po tri do četiri dana, u razdoblju od prve polovice lipnja do sredine listopada. Gledano po mjesecima i po godinama, podaci nisu prikupljani jednakim intenzitetom.

Istraživanje je rađeno na lokalitetu Turjak. Jedinke su lovljene rukama u različito doba dana sustavnim pretraživanjem terena (šumskog tla, ispod žbunja i otvorenih travnatih područja). Uslijedilo je prikupljanje morfometrijskih podataka i fotografiranje. Nakon mjerenja, jedinke su odmah vraćene na mjesto pronalaska.

Vanjski okolišni faktori kao nadmorska visina, temperatura zraka, temperatura tla, strujanje zraka, naoblaka i geografske koordinate također su mjereni prilikom ispitivanja svake istraživane jedinke.

4.2. Sastavnice PVA

a) Osnovni populacijski model

Osnovni populacijski model je nužan. Mehanizam regulacije populacije i ovisnosti gustoće, svakako treba biti uključen zbog toga što ni jedna populacija ne može i ne smije rasti beskonačno zbog toga što opstojnost postaje precijenjena. Ovisnost gustoće ne smije biti zanemarena prilikom modeliranja velikih populacija, a ujedno može pružiti stabilizirajući utjecaj koji povećava opstojnost u malim populacijama (White, 2000).

b) Demografska varijacija

Demografska varijacija mora biti uključena u ovaj temeljni model, jer inače, procjene opstojnosti će biti previsoke zbog toga što utjecaj demografske varijacije za male populacije nije uključen u model (White, 2000).

c) Temporalna varijacija

Temporalna varijacija također mora biti uključena za pojedine parametre modela, uključujući i vjerojatnosti prirodne katastrofe. Katastrofe moraju biti rijetke, jer inače, varijacija će se smatrati dijelom normalnog vremenskog odstupanja. Suodstupanje (kovarijacija) parametara je također važno. Dobre godine za opstanak su vjerojatno i dobre

godine za reprodukciju, i obrnuto. Ako je pozitivna korelacija stopa opstanka i reprodukcije uključena u model, opstojnost je poboljšana (White, 2000).

d) Spacijalna varijacija

Prostorno odstupanje u parametrima modela mora biti uključeno ako je populacija prostorno odvojena. Ako će se prostorni atributi (karakteristike) modelirati, tada parametri imigracije i emigracije moraju biti procijenjeni kao i udaljenosti raspršenih subpopulacija. Poteškoća procjene spacijalne varijacije leži u tome da kovarijacija parametara mora biti procijenjena kao funkcija udaljenosti. Odnosno, postavljamo pitanje koja je kovarijacija opstanka odraslih jedinki dviju subpopulacija kao funkcija udaljenosti (White, 2000).

e) Individualna heterogenost

Ignoriranjem individualne heterogenosti procjene opstojnosti bivaju preniske. Ona zahtjeva da temeljni model bude proširen na individualno-usmjereni model. Dok se varijacija individualnih parametara povećava u temeljnom modelu, povećava se vrijeme opstojnosti. Zbog toga, umjesto da samo znamo procjene parametara osnovnog modela, također moramo znati statističku distribuciju ovih parametara po jedinkama (White, 2000).

f) Genetska varijacija

Za kratkoročne projekte koji obuhvaćaju kraći vremenski period dosadašnji izvori varijacija mogu biti adekvatni i zadovoljavajući. Međutim, ako se projektiraju modeli koji obuhvaćaju više generacija unutar populacije, tada se genetička varijacija mora uzeti u obzir (White, 2000). Treba očekivati da će se populacija mijenjati kada prirodna selekcija zauzme svoje mjesto (White, 2000). Međutim, važnost genetskog utjecaja još uvijek je predmet koji traži i zahtjeva odgovore (White, 2000).

g) Stabilnost sustava

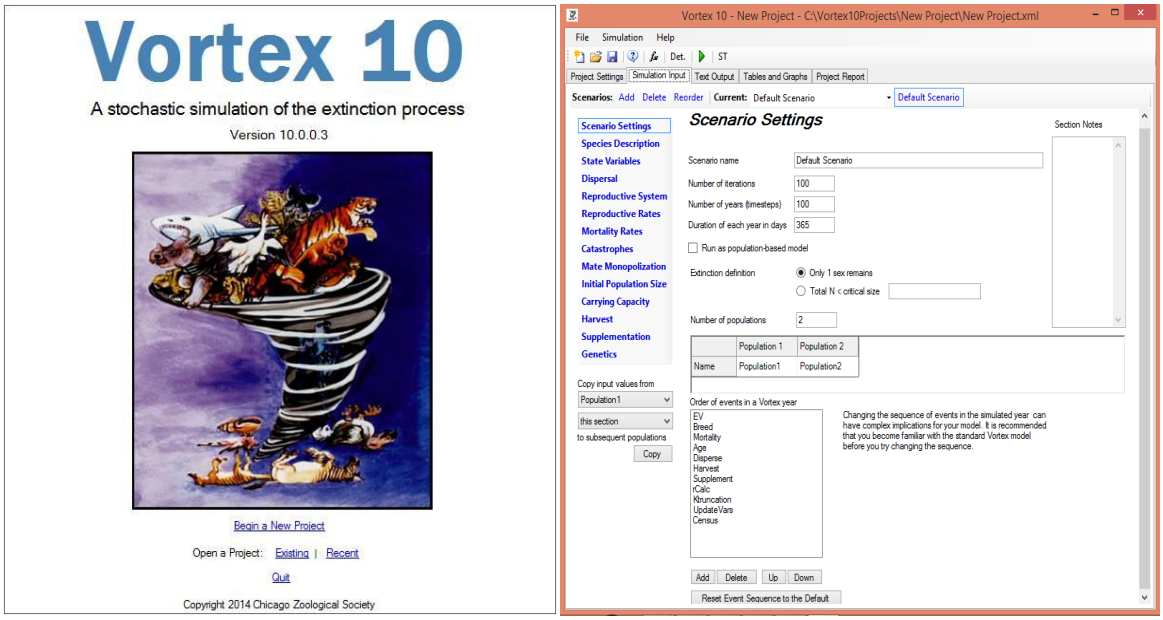
Za dugoročne projekte, moramo pretpostaviti da se sustav neće promijeniti, da se nivoi i razine stohastičnosti neće mijenjati tijekom vremena, da vrste neće evoluirati kroz selekciju, i da će potporni kapacitet okoliša ostati statičan(White 2000). Također, moramo pretpostaviti da prirodni procesi kao npr. dugoročne sukcesije i klimatske promjene neće utjecati na

opstojnost populacije. Da bi vjerovali rezultatima moramo pretpostaviti da će model i svi njegovi parametri ostati isti kroz pretjerano duge vremenske periode (White, 2000).

4.3. Statistička obrada podataka

a) VORTEX – simulator procesa izumiranja

Obrada podataka rađena je u računalnom programu VORTEX (Slika 5). VORTEX je individualno – bazirani simulacijski model koji se koristi za analizu vijabilnosti populacije (Miller i Lacy, 2005). Računalni program čiji modeli predstavljaju simulaciju učinaka determinističkih sila i stohastičkih zbivanja na vijabilnost populacija (Lacy, 1993; Lacy i sur., 2014). Njegovi modeli najbolje odgovaraju i najprimjenljiviji su na vrstama koje karakteriziraju niske stope plodnosti i dugi život, poput gmazova, ptica i sisavaca (Lacy, 1993), tako da je VORTEX vjerojatno i najčešće korišteni program za analizu vijabilnosti (Lacy, 1993).



Slika 5. VORTEX simulacijski program

b) Microsoft Office paket

Pri izradi rada korišten je Microsoft Office 2007 paket. Obrada podaka i izrada tablica rađeni su u Microsoft Office Excel 2007.

4.4. Populacijski modeli sa različitim scenarijima

a) Osnovni populacijski model

Osnovni populacijski model predstavlja scenarij idealnih uvjeta za rast i razvoj populacije. Rađen je kao osnovni model na temelju podataka pojedinih ekoloških parametara dobivenih prethodnim istraživanjima (Kolarić, 2013). Parametri za koje nedostaju podaci su zadržane programski predložene vrijednosti (Tablica 1).

Tablica 1. Vrijednosti pojedinih parametara modela

Varijabla		Varijabla	
Broj ponavljanja	10000	1 mladunac	0,00%
Broj godina	100	2 mladunca	33,33%
Trajanje godine u danima	365	3 mladunca	55,56%
Definicija izumiranja	Ostaje 1 spol	4 mladunca	11,11%
Broj populacija	1	Varijable stanja populacije	-
Populacijsko-usmjereni model	+	Smrtnost jedinki mlađih od godinu dana	50,00%
Depresija parenja bliskih rođaka	+	SD u smrtnosti mlađih od 1 godine	10,00%
Letalni ekvivalenti	6,29	Smrtnost jedinki starijih od 1 godinu	10,00%
Recesivni letalni aleli	0,5	SD u smrtnosti jedinki starijih od 1 godine	3,00%
EV podudarnost reprodukcije i opstanka	+	Lokalna katastrofa	+
Reproduktivni sistem	Poligamni	Učestalost %	1
Spolna zrelost ženki	1	Reprodukcija %	1
Spolna zrelost mužjaka	1	Opstanak %	1
Maksimalni životni vijek	4	% mužjaka aktivnih u rasplodnom ciklusu	100,00%
Maksimalan broj legla u godini	1	Korištena stabilna dobna distribucija	Da
Maksimalan broj mladunaca po leglu	4	Početna veličina populacije	10000
Odnos udjela mužjaka u leglu	50,00%	Kapacitet zasićenosti (*K*)	15000
Maksimalan vijek reprodukcije za ženke	4	SD u *K* s obzirom na EV	0
Maksimalan vijek reprodukcije za mužjake	4	Buduće promjene *K*	-
Reprodukcija ovisna o gustoći	-	Predacija	-
% odraslih ženki koje se pare	42,85%	Dopuna	-
SD u % ženki s obzirom na EV	10,00%	Genetika	-
1 leglo po godini	1	Broj neutralnih lokia	1

b) Populacijski model sa simulacijama mortaliteta juvenilnih jedinki

Modeliranje je rađeno u dva scenarija koji su se međusobno razlikovali prema stupnju smrtnosti juvenilnih jedinki. Vrijednosti smrtnosti su procjenjeni na temelju prethodnih saznanja o ekologiji vrste.

Simulacija umjerenog mortaliteta

Scenarij umjerenog mortaliteta predstavlja simulaciju pri kojoj vrijednost smrtnosti jedinki do jedne godine starosti iznosi 50 %. Zajedno sa smrtnošću odraslih jedinki od 10 % predstavlja ukupnu smrtnost od 60 % na razini cjelokupne populacije (Tablica 2). Vrijednosti ostalih parametara modela istovjetne su osnovnom modelu.

Simulacija povišenog mortaliteta

Predstavlja scenarij pri kojemu vrijednost smrtnosti jedinki do jedne godine starosti iznosi 60 %. U kombinaciji sa smrtnošću odraslih jedinki od 10 % predstavlja ukupnu smrtnost od 70 % na razini populacije (Tablica 2). Vrijednosti ostalih parametara modela istovjetne su osnovnom modelu.

Tablica 2. Vrijednosti parametara mortaliteta jedinki dvaju scenarija u modelu mortaliteta juvenilnih jedinki

Varijabla	Umjereni mortalitet	Povišeni mortalitet
Smrtnost ženki		
Smrtnost do 1. godine starosti	50	60
SD u 0-1 smrtnosti s obzirom na EV	10	10
Godišnja smrtnost nakon 1 godine starosti	10	10
SD u smrtnosti nakon 1 godine starosti	3	3
Smrtnost mužjaka		
Smrtnost do 1. godine starosti	50	60
SD u 0-1 smrtnosti s obzirom na EV	10	10
Godišnja smrtnost nakon 1 godine starosti	10	10
SD u smrtnosti nakon 1 godine starosti	3	3

c) Populacijski model sa simulacijama katastrofa

S obzirom na tip staništa prisutnom na lokalitetu kao primjer vanjskog čimbenika koji može negativno utjecati na dinamiku rasta populacije izabran je šumski požar. Modeliranje je rađeno u dva scenarija. Scenariji se međusobno razlikuju prema intenzitetu i jačini požara. Vrijednosti ekoloških parametara su istovjetne onima osnovnog modela osim onih koji se odnose na primjer simulacije.

Simulacija snažnog požara

Prvi scenarij čini simulacija snažnog požara koji zahvaća 70 % staništa i pojavljuje se 4 puta u 100 godina. Zahvaćenost 70 % staništa katastrofom znači da je 30 % jedinki preživjelo katastrofu. Vrijednost reprodukcije u ovome slučaju dobiva se umnoškom reprodukcije u normalnim uvjetima i udjelom jedinki koje su preživjele katastrofu, odnosno (42,85 %)(0,3)=12,86 % (Tablica 3).

Simulacija ekstremnog požara

Drugi scenarij predstavlja simulaciju ekstremnog požara koji zahvaća 90 % staništa i pojavljuje se 2 puta u 100 godina. Obujam od 90 % staništa znači da je 90 % populacije zahvaćeno katastrofom i da svega 10 % jedinki preživi. Vrijednost reprodukcije računa se na isti način kao i prethodno dobivena i iznosi (42,85 %)(0,1)=4,285 % (Tablica 3).

Tablica 3. Vrijednosti parametara reprodukcije i opstanka jedinki dvaju scenarija u modelu prirodne katastrofe

Varijabla	Snažni požar	Ekstremni požar
Lokalna aktivnost	+	+
Učestalost	4	2
Reprodukcija	12,86	4,285
Opstanak (0-1)	0,3	0,1

d) Populacijski model sa simulacijama degradacije staništa

Scenarij degradacije staništa opisuje se možebitnom sječom šume ili zakorovljenošću i obrastanjem staništa. Degradacijom staništa dolazi do promjena u vrijednosti *K* (kapacitet okoliša) pri čemu se on smanjuje. Smanjenje *K* vrijednosti uvjetuje brojčanu vrijednost jedinki koji može opstati na sada prostorno smanjenom staništu. Modeliranje je rađeno u dva scenarija koji se međusobno razlikuju prema intenzitetu degradacije. Za oba modela vremenski okvir promjene obuhvaćao je razdoblje od 50 godina.

Scenarij umjerene degradacije

Model minimalne degradacije staništa opisan je kao promjena koja se odvija kroz 50 g. i uvjetuje degradaciju od 50 %. Odnosno, vrijednost *K* se smanjuje za 50 % kroz 50 g. ili 1 % godišnje (Tablica 4).

Scenarij povišene degradacije

Scenarij maksimalne degradacije predstavlja degradaciju staništa od 70 % kroz vremenski period od 50 g. Odnosno, vrijednost parametra *K* se smanjuje za 70 % kroz 50 g. ili 1,4 % svake godine (Tablica 4).

Tablica 4. Vrijednosti parametara promjene kapaciteta zasićenosti okoliša (K) dvaju scenarija u modelu degradacije staništa

Varijabla	Umjerena degradacija	Povišena degradacija
Kapacitet zasičenosti okoliša (K)	15000	15000
SD u *K* s ozirom na EV	0	0
Buduće promjene K vrijednosti	+	+
Tijekom koliko godina	50	50
% Godišnje povećanje ili smanjenje	-1	-1,4

e) Populacijski model sa scenarijem povečanja staništa

Scenarij povečanja staništa ostvaruje se uklanjanjem nasada crnog bora (*P. nigra*). Vrijednosti ekoloških parametara su istovjetne onima osnovnog modela osim onih koji se odnose na primjer simulacije (Tablica 5). Prema procjenama dolazi do povečanja staništa od 15 % kroz vremenski period od 5 g. Svake godine povečava se populacija u vrijednosti od 3 %, odnosno 15 % kroz 5 g. Povečanjem staništa dolazi do promjena u vrijednosti *K*, odnosno varijable su u pozitivnoj korelaciji.

Tablica 5. Vrijednosti parametara promjene kapaciteta okolišne zasićenosti (K) dvaju scenarija u modelu povečanja staništa

Varijabla	Vrijednost
Kapacitet zasičenosti okoliša (*K*)	15000
SD u K s ozirom na EV	0
Buduće promjene *K* vrijednosti	+
Tijekom koliko godina	5
% Godišnje povećanje ili smanjenje	3

f) Populacijski model sa scenarijem introdukcije vrste

Introdukcija vrste na dva nova lokaliteta radi se s ciljem povečanja staništa za 100 % tako da svaki od dva lokaliteta pridonosi povečanju staništa za 50 %. Kroz vremenski period od 2 godine na oba lokaliteta je translocirano po 100 odraslih jedinki. Omjer mužjaka i ženki na oba lokaliteta je 50/50 (Tablica 6.). Vrijednosti ostalih parametara modela temelje se na osnovnom modelu.

Tablica 6. Vrijednosti parametara introdukcije vrste za temeljnu i dvije nove populacije u istovjetnom modelu

Varijabla	Populacija Lapjak	Populacija Toplička glava	Temeljna populacija
Početna veličina populacije (*N0*)	100	100	10000
Kapacitet zasičenosti (*K*)	7500	7500	15000
SD u *K* s ozirom na EV	0	0	0
Buduće promjene *K* vrijednosti	-	-	-
Provedena translokacija	+	+	-
Populacija dodana	+	+	-
1. godina dopune	1	1	0
Zadnja godina dopune	2	2	0
Interval između dopuna	1	1	0
Osnovni kriteriji za dopune	1	1	1
Broj translociranih odraslih ženki u jednoj godini dopune	25	25	0
Broj translociranih odraslih mužjaka u jednoj godini dopune	25	25	0

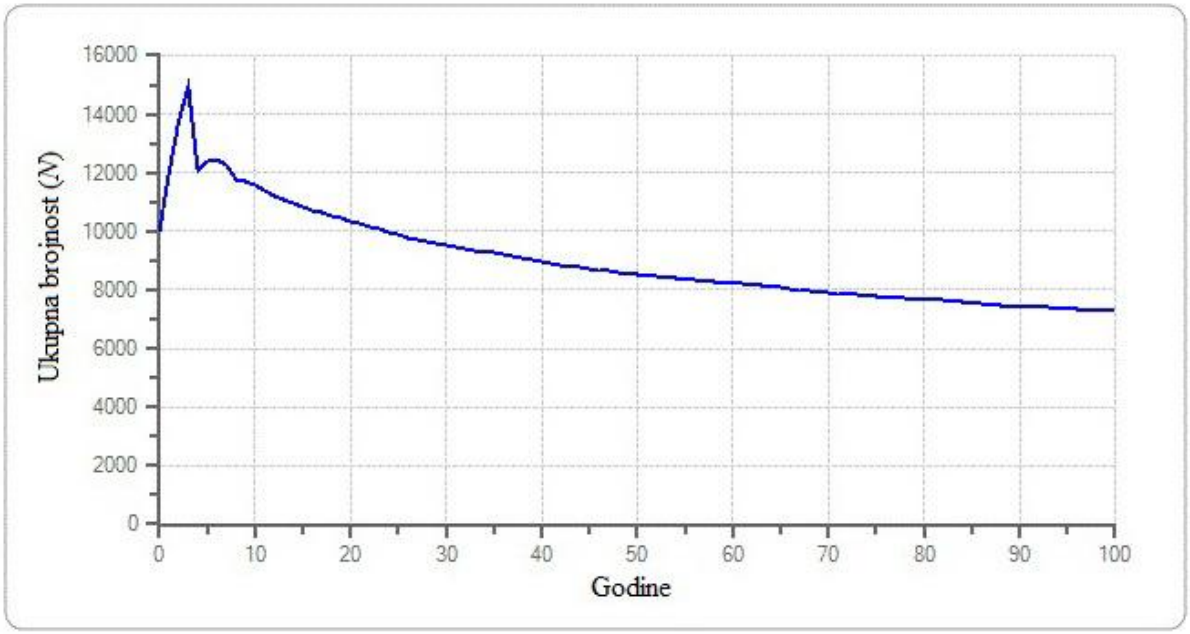
5. REZULTATI

5.1. Procjena opstajnosti populacije *A. kitaibelii* s vrhova Turjak i Pliš na Papuku u sadašnjim uvijetima

Simulaciju procjene opstajnosti populacije predstavlja osnovni populacijski model. Prema dobivenim rezultatima opstajnost populacije u 100 - godišnjem vremenskom periodu iznosi 100 %, odnosno vjerojatnost izumiranja populacije procjenjena je na 0. Znači da ni u jednom od 10 000 simuliranih scenarija nije došlo do izumiranja populacije niti u jednoj godini.

Početna populacija (N_0) od 10 000 jedinki postigla je vrijednost kapaciteta okoliša u 3. simulacijskoj godini kada je brojnost iznosila 14953,04 jedinki sa standardnom pogreškom (SE) od 15,51 i standardnom devijacijom (SD) od 1550,78. Dinamika rasta populacije u vremenskom periodu prikazana je na slici 6.

Postizanje okolišnog kapaciteta (K) uvjetuje pad brojnosti koji se očituje u 4. simulacijskoj godini pa nadalje. Veličina populacije (N) u prvoj četvrtini vremenskog perioda iznosi 9886,39 ± 40,57 jedinki. Nakon 50 godina vrijednost iznosi 8523,65 ± 45,01 jedinki. U trečoj četvrtini, nakon 75 godina iznosi 7765,34 ± 47,18 jedinki. Na kraju simulacije vrijednost veličine populacije (N) iznosi 7260,31 ± 48,31 jedinki (Tablica 7).



Slika 6. Dinamika promjene brojnosti populacije kroz vrijeme u slučaju osnovnog populacijskog modela vrste *A. kitaibelii*

Tablica 7. Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za osnovni populacijski model

	0 godina	25 godina	50 godina	75 godina	100 godina
Veličina populacije (*N*)	10000	9886,39	8523,65	7765,34	7260,31
Standardna pogreška (SE)	0	40,57	45,01	47,18	48,31
Standardna devijacija (SD)	0	4056,66	4500,86	4717,73	4831,11

Srednja stopa rasta populacije (*r*) kroz sve godine s obzirom na kapacitet okoliša (*K*) iznosi 0,0070 ± 0,0002 ili 0,7 % godišnje.

Odnos udjela mužjaka i ženki je 1:1 i iznosi 3630,16 mužjaka i 3630,15 ženki.

5.2. Procijena vjerojatnosti izumiranja populacije u narednih 100 godina

Za dobivanje procjene vjerojatnosti izumiranja unutar 100-godišnjeg vremenskog perioda korištena su dva različita modela. Modeli se međusobno razlikuju prema tipu okolišnog parametra koji uvjetuje promjenu dinamike rasta populacije. Tako da prvi model predstavlja promjenu koju uvjetuje parametar unutar populacije, odnosno svojstven populaciji, dok drugi model predstavlja promjenu dinamike rasta na koju utječe vanjski okolišni čimbenik.

a) Model dinamike rasta populacije s obzirom na stopu smrtnosti juvenilnih jedinki

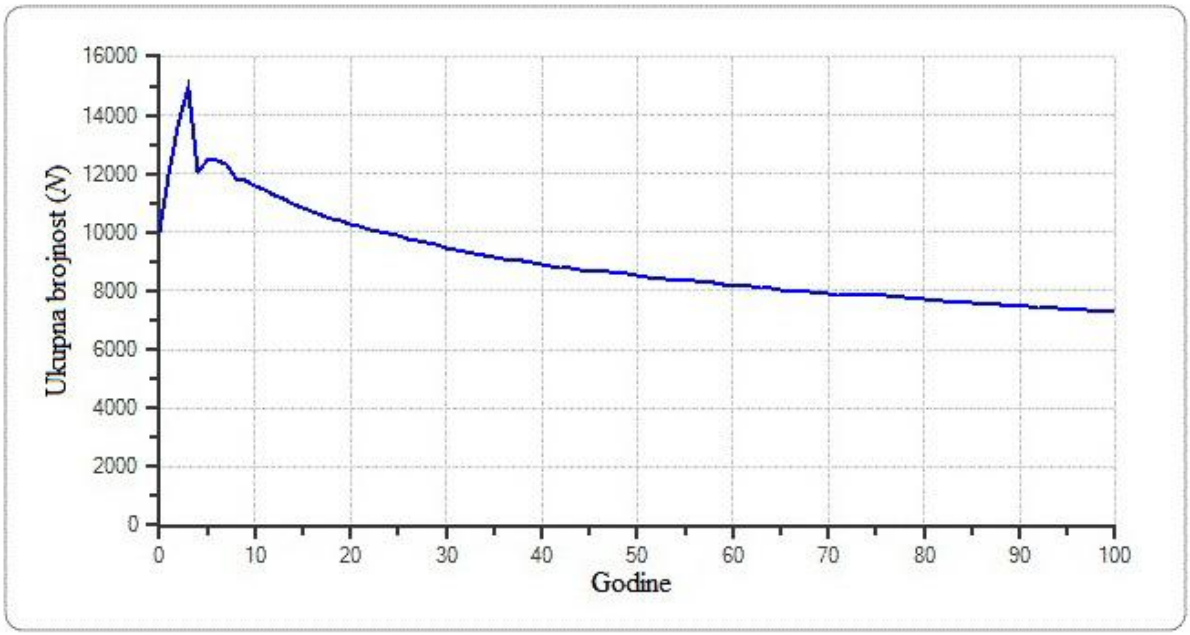
Rađena su dva različita scenarija koji se međusobno razlikuju u stopi smrtnosti juvenilnih jedinki.

Model umjerenog mortaliteta

Prema dobivenim rezultatima vjerojatnost opstanka populacije iznosi 0,9999, odnosno 99,99 %. Sukladno stopi opstanka vjerojatnost izumiranja iznosi 0,0001, odnosno 0,01 %. Prema tome, samo u jednom scenariju provedene simulacije dolazi do izumiranja populacije.

Nivo zasićenosti okoliša (*K*) postignut je u 3. simulacijskoj godini. Vrijednost veličine populacije (*N*) pri dostizanju *K* iznosi 14959,22 ± 15,56 jedinke. Dinamika rasta populacije prikazana je na slici 7.

Vrijednosti veličine populacije (*N*), standardne pogreške (SE) i standardne devijacije (SD) za svaku pojedinu četvrtinu vremenskog perioda prikazane su u tablici 8. Svi navedeni podaci predstavljaju vrijednosti dobivene od populacija koje su opstale, dok vrijednosti ukupnog broja populacija zajedno sa scenarijima izumrlih populacija nisu uzete u obzir.

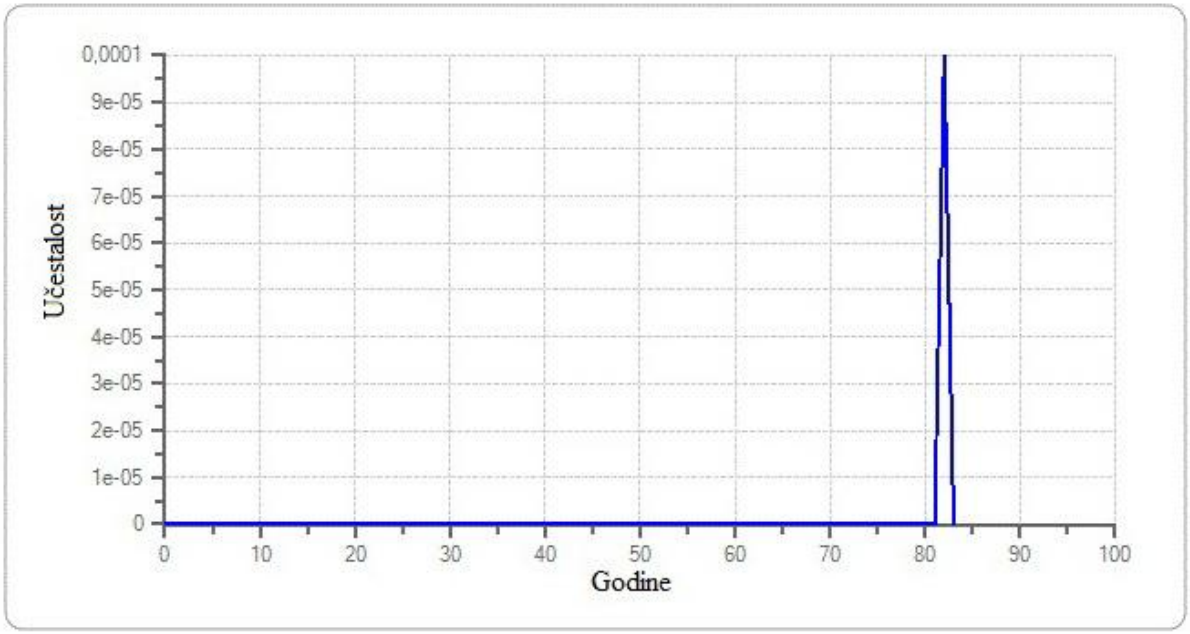


Slika 7. Dinamika promjene brojnosti populacije kroz vrijeme u modelu umjerenog mortaliteta juvenilnih jedinki vrste *A. kitaibelii*

Tablica 8. Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za model minimalnog mortaliteta juvenilnih jedinki

	0 godina	25 godina	50 godina	75 godina	100 godina
Veličina populacije (*N*)	10000	9869,01	8538	7832,29	7257,43
Standardna pogreška (SE)	0	40,7	45,5	47,56	47,69
Standardna devijacija (SD)	0	4070,21	4549,76	4755,7	4769

Srednja vrijednost prvog izumiranja populacije iznosi 82,00 godine. Budući da je riječ o samo jednom slučaju izumiranja srednja vrijednost ujedno predstavlja i konkretnu procjenjenu vjerojatnost izumiranja populacije u 82. godini (Slika 8).



Slika 8. Opseg ponavljanja scenarija izumiranja za svaku pojedinu godinu u modelu umjerenog mortaliteta juvenilnih jedinki vrste *A. kitaibelii*

Srednja stopa rasta populacije (*r*) s obzirom na nivo okolišne zasićenosti (*K*) iznosi 0,0072 ± 0,0002 ili 0,72 % godišnje.

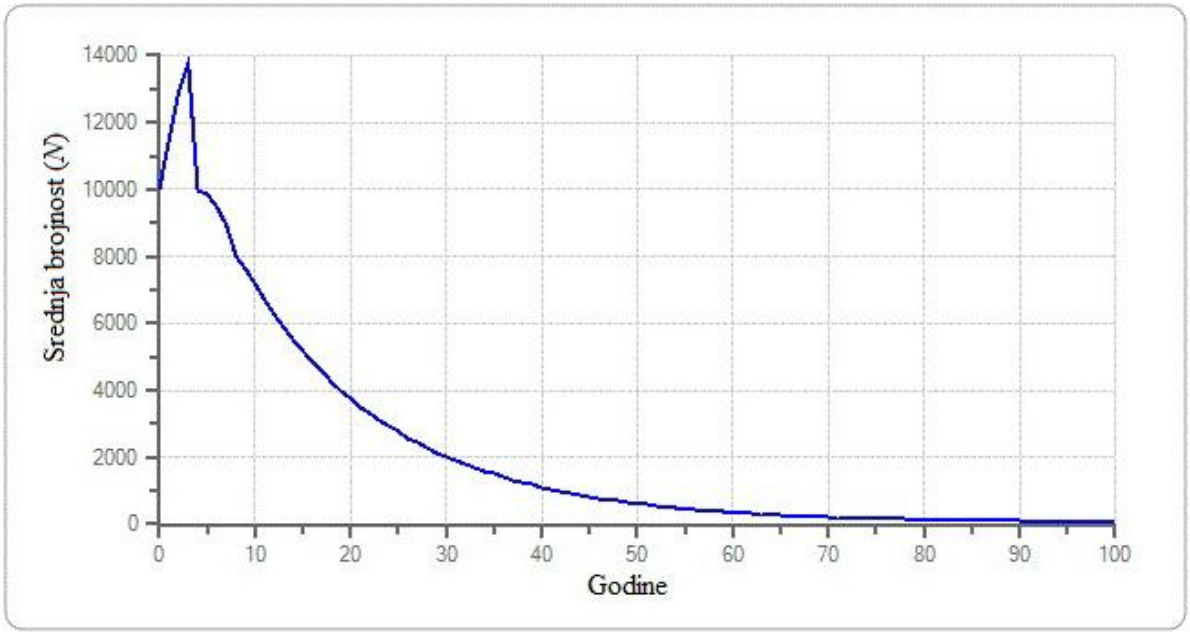
Odnos udjela mužjaka i ženki je 1:1 i iznosi 3628,71 mužjak i 3628,72 ženke.

Model povišenog mortaliteta

Prema dobivenim rezultatima vjerojatnost opstanka populacije iznosi 0,5168 ± 0,0050 ili 51,68 %. Tako da vjerojatnost izumiranja populacije iznosi 0,4832 ± 0,0050 ili 48,32 %.

Kapacitet okoliša (*K*) postignut je u 3. simulacijskoj godini. Vrijednost veličine populacije (*N*) pri dostizanju *K* iznosi 14959,22 ± 15,56 jedinke. Dinamika rasta populacije prikazana je na slici 9.

Vrijednosti veličine populacije (*N*), standardne pogreške (SE) i standardne devijacije (SD) za svaku pojedinu četvrtinu vremenskog perioda prikazane su u tablici 9. Svi navedeni podaci predstavljaju vrijednosti dobivene od populacija koje su opstale, dok vrijednosti ukupnog broja populacija zajedno sa scenarijima izumrlih populacija nisu uzete u obzir.



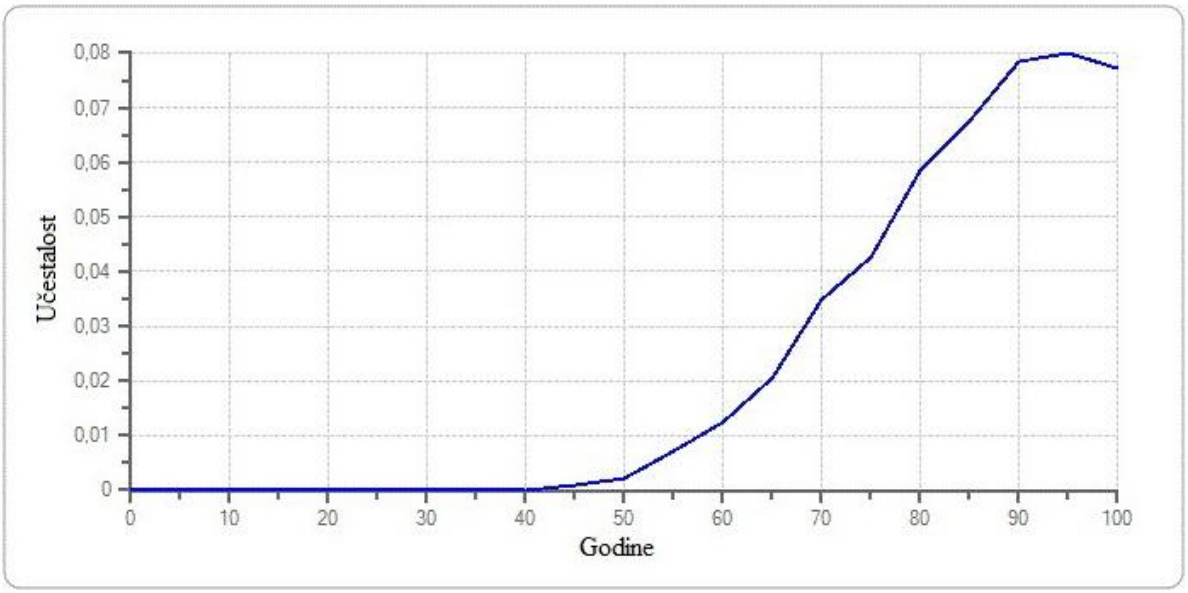
Slika 9. Dinamika promjene brojnosti populacije kroz vrijeme u modelu povišenog mortaliteta juvenilnih jedinki vrste *A. kitaibelii*

Tablica 9. Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za model povišenog mortaliteta juvenilnih jedinki

	0 godina	25 godina	50 godina	75 godina	100 godina
Veličina populacije (*N*)	10000	2753,8	611,75	158,75	59,99
Standardna pogreška (SE)	0	25,72	10,76	4,77	2,35
Standardna devijacija (SD)	0	2572,16	1074,03	447,47	168,6

Srednja vrijednost prvog izumiranja populacije iznosi 83,16 ± 0,17 godina. Raspon ponavljanja scenarija u kojima populacija izumire kreće se u intervalu od 41. godine do isteka uspostavljenog vremenskog perioda od 100 godina. Tako da, počevši od 41. godine dolazi do eksponencijalnog rasta broja scenarija u kojima populacija izumire. Odnosno, vjerojatnost izumiranja populacije eksponencijalno se povečava.

Od ukupnog broja ponavljanja scenarija izumiranja populacije najveća vrijednost izumiranja zabilježena je za vremenski interval od 90-e do 95-e godine pri čemu iznosi 0,0799 ili 7,99 % (Slika 10).

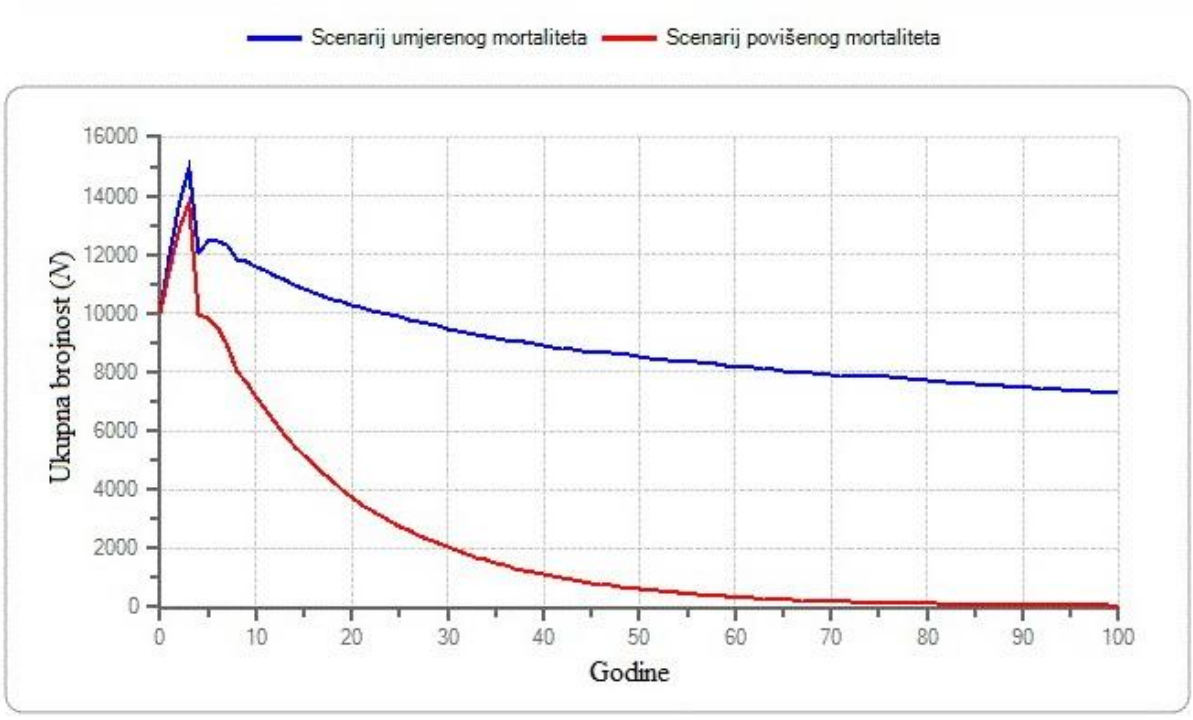


Slika 10. Opseg ponavljanja scenarija izumiranja juvenilnih jedinki vrste *A. kitaibelii* za svaku pojedinu godinu u modelu povišenog mortaliteta pri čemu su podaci prezentirani u 5-ogodišnjim vremenskim intervalima

Srednja stopa rasta populacije (*r*) s obzirom na nivo zasićenosti okoliša iznosi -0,0764 ± 0,0002 ili -7,64 % godišnje.

Odnos udjela mužjaka i ženki je 1:1 i iznosi 30,02 mužjaka i 30,04 ženki.

Usporedbom dobivenih rezultata procjene brojnosti populacije za oba scenarija vidljiva je razlika u visini brojčane vrijednosti populacija, odnosno u broju jedinki (Slika 11).



Slika 11. Prikaz dobivenih rezultata procjene brojnosti populacije za oba scenarija u modelu mortaliteta juvenilnih jedinki vrste *A. kitaibelii*

b) Model dinamike rasta populacije s obzirom na učestalost požara kao primjer vanjskog okolišnog parametra koji utječe na dinamiku rasta populacije

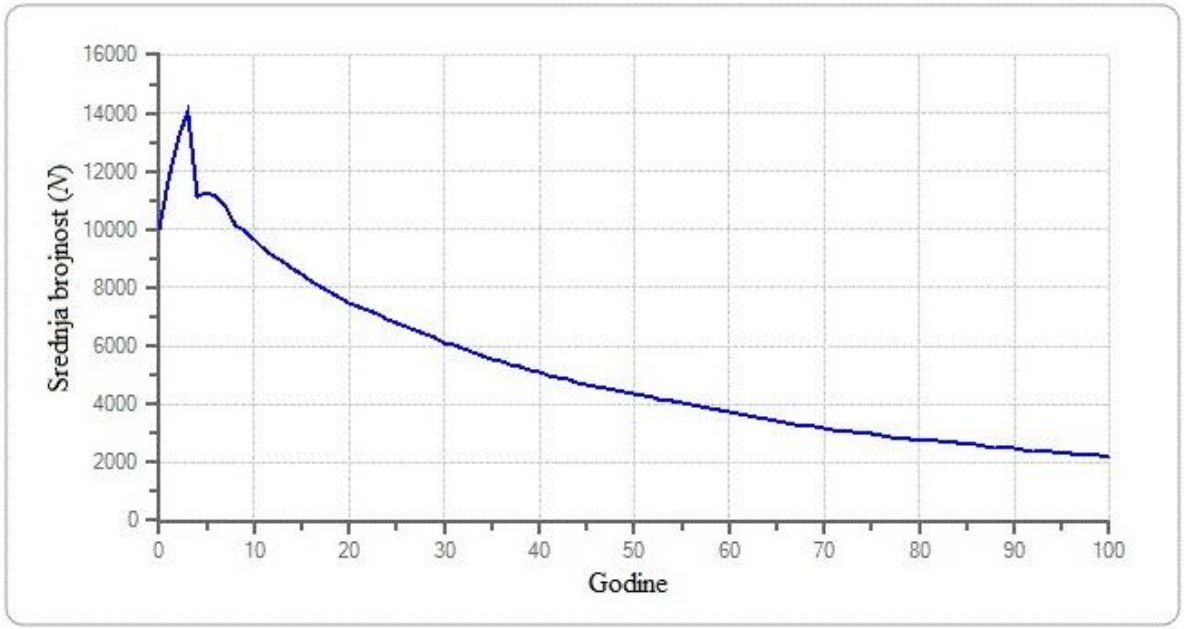
Rađena su dva scenarija koji se međusobno razlikuju u intenzitetu i učestalosti požara na lokalitetu.

Model snažnog požara

Dobiveni rezultati provedenog modela procjenjuju vjerojatnost opstanka populacije u vrijednosti od 0,9760 ± 0,0015 ili 97,60 %. Tako da procjenjena vjerojatnost izumiranja iznosi 0,0240 ± 0,0015 odnosno 2,40 %.

Nivo zasićenosti okoliša (*K*) postignut je u 3. simulacijskoj godini. Veličina populacije (*N*) pri postizanju *K* vrijednosti iznosi 14076,94 ± 31,26 jedinke. Dinamika rasta populacije prikazana je na slici 12.

Vrijednosti veličine populacije (*N*), standardne pogreške (SE) i standardne devijacije (SD) za svaku pojedinu četvrtinu vremenskog perioda prikazane su u tablici 10. Svi navedeni podaci predstavljaju vrijednosti dobivene od populacija koje su opstale, dok vrijednosti ukupnog broja populacija zajedno sa scenarijima izumrlih populacija nisu uzete u obzir.



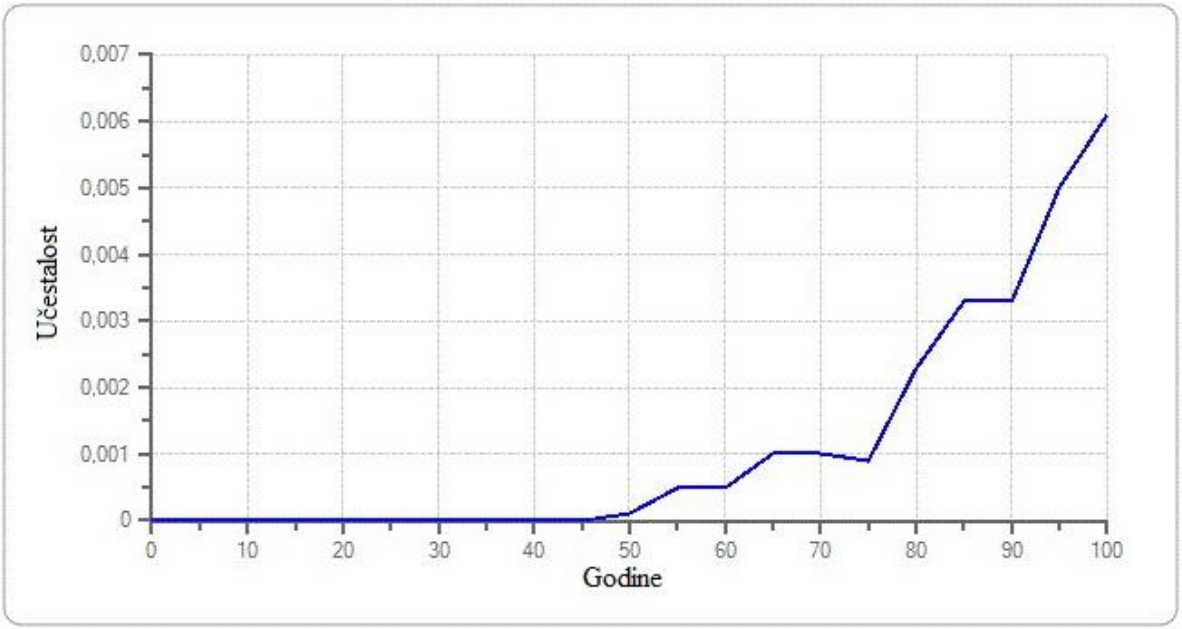
Slika 12. Dinamika promjene brojnosti populacije vrste *A. kitaibelii* kroz vrijeme u modelu snažnog požara

Tablica 10. Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za model snažnog požara

	0 godina	25 godina	50 godina	75 godina	100 godina
Veličina populacije (*N*)	10000	6787,66	4330,04	2975,62	2181,17
Standardna pogreška (SE)	0	46,03	42,95	37,87	33,62
Standardna devijacija (SD)	0	4602,65	4294,99	3779,92	3321,35

U pogledu scenarija izumiranja populacije kroz godine srednja vrijednost izumiranja iznosi 86,23 ± 0,77 godine. Raspon ponavljanja scenarija u kojima populacija izumire kreće se u intervalu od 50. godine do isteka uspostavljenog vremenskog perioda od 100 godina. Tako da, počevši od 50. godine dolazi do eksponencijalnog rasta broja scenarija u kojima populacija izumire. Odnosno, vjerojatnost izumiranja populacije eksponencijalno se povečava.

Od ukupnog broja ponavljanja scenarija izumiranja populacije najveća vrijednost izumiranja zabilježena je za vremenski interval od 95-e do 100-e godine pri čemu iznosi 0,0061 ili 0,61 % (Slika 13).



Slika 13. Opseg ponavljanja scenarija izumiranja vrste *A. kitaibelii* za svaku pojedinu godinu u modelu snažnog požara pri čemu su podaci prezentirani u 5-ogodišnjim vremenskim intervalima

Srednja stopa rasta populacije (r) s obzirom na nivo zasićenosti okoliša iznosi -0,0228 ± 0,0002 ili -2,28 % godišnje.

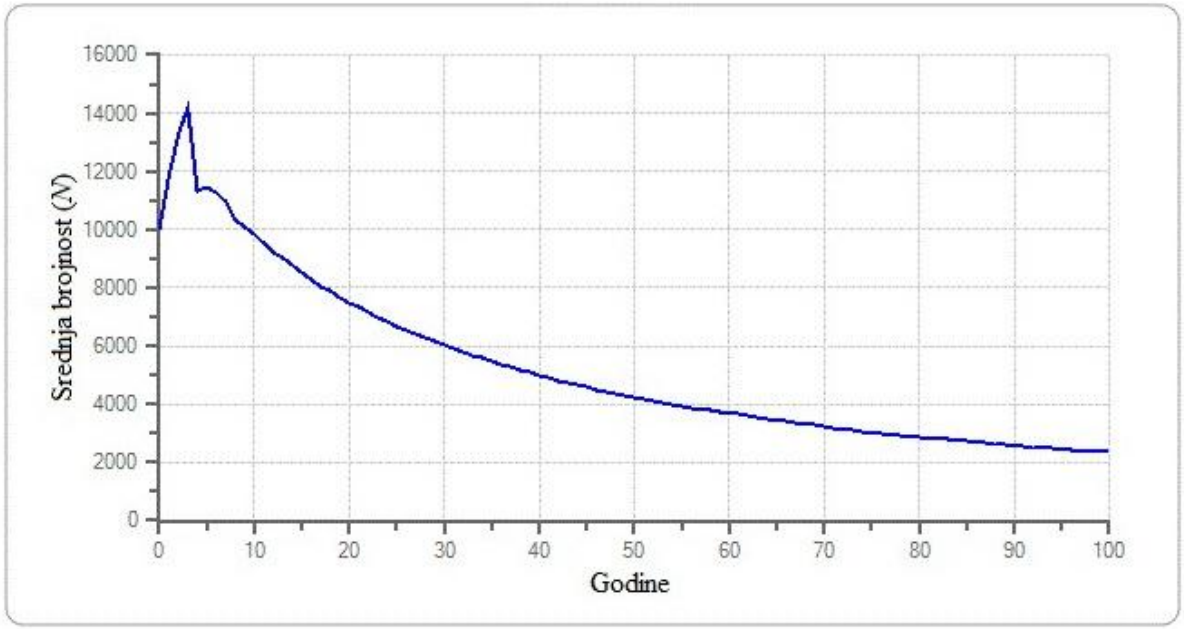
Odnos udjela mužjaka i ženki je 1:1 i iznosi 1090,58 mužjaka i 1090,59 ženki.

Model ekstremnog požara

Prema dobivenim rezultatima provedene simulacije vjerojatnost opstanka popualcije procjenjuje se na vrijednost 0,8903 ± 0,0031 odnosno 89,03 %. Tako da, procjenjena vjerojatnost izumiranja populacije iznosi 0,1097 ± 0,0031 odnosno 10,97 %. Prema tome, 1097 simulacija je rezultiralo izumiranjem minimalno jednom.

Kapacitet okoliša postignut je u 3. simulacijskoj godini. Veličina populacije (N) pri postizanju vrijednosti K iznosi 14217,73 ± 34,46 jedinke. Dinamika rasta populacije prikazana je na slici 14.

Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za svaku pojedinu četvrtinu vremenskog perioda prikazane su u tablici 11. Svi navedeni podaci predstavljaju vrijednosti dobivene od populacija koje su opstale, dok vrijednosti ukupnog broja populacija zajedno sa scenarijima izumrlih populacija nisu uzete u obzir.



Slika 14. Dinamika promjene brojnosti populacije vrste *A. kitaibelii* kroz vrijeme u modelu ekstremnog požara

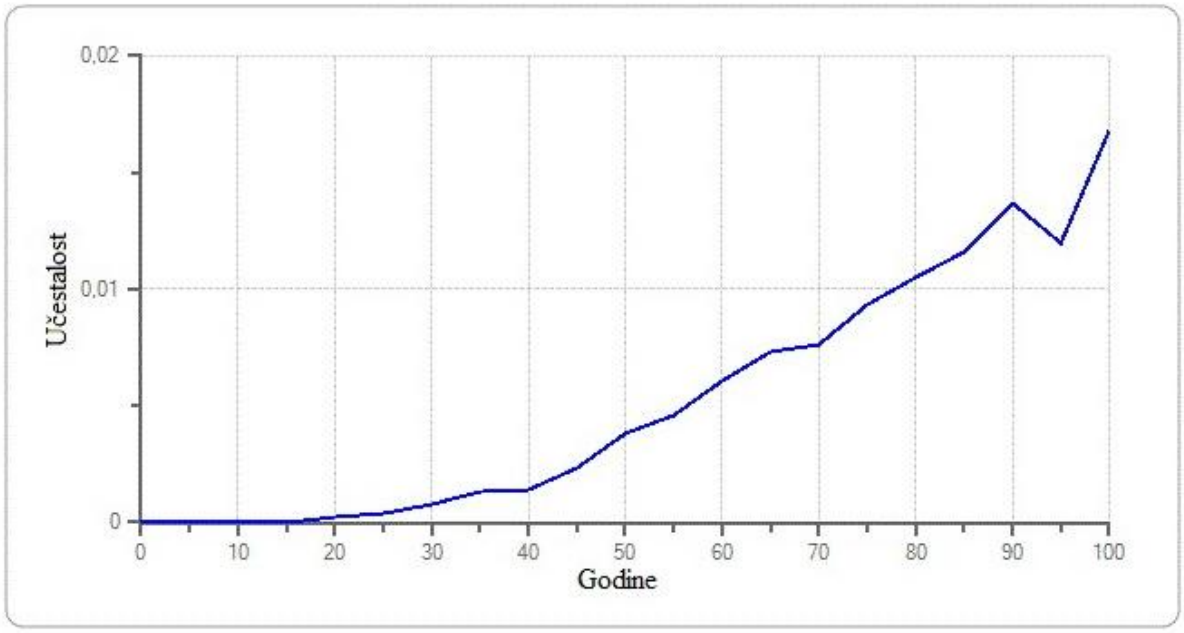
Tablica 11. Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za model ekstremnog požara

	0 godina	25 godina	50 godina	75 godina	100 godina
Veličina populacije (*N*)	10000	6678,22	4240,66	3014,67	2351,69
Standardna pogreška (SE)	0	51,36	47,23	42,72	40,21
Standardna devijacija (SD)	0	5134,87	4698,43	4174,72	3794

Gledajući brojnost scenarija izumiranja populacije kroz godine proizlazi procjena srednje vrijednosti izumiranja u iznosu od 76,88 ± 0,53 godina. Raspon ponavljanja scenarija u kojima populacija izumire kreće se u intervalu od 19. godine do isteka uspostavljenog vremenskog perioda od 100 godina. Tako da, počevši od 19. godine dolazi do eksponencijalnog rasta broja scenarija u kojima populacija izumire. Odnosno, vjerojatnost izumiranja populacije eksponencijalno se povečava.

Od ukupnog broja ponavljanja scenarija izumiranja populacije najveća vrijednost izumiranja zabilježena je za vremenski interval od 95-e do 100-e godine pri čemu iznosi

0,0168 ili 1,68 % sa postizanjem maksimuma u 100-oj godini. Visoke vrijednosti vjerojatnosti izumiranja zabilježene su i za interval od 85-e do 90-e godine (Slika 15).

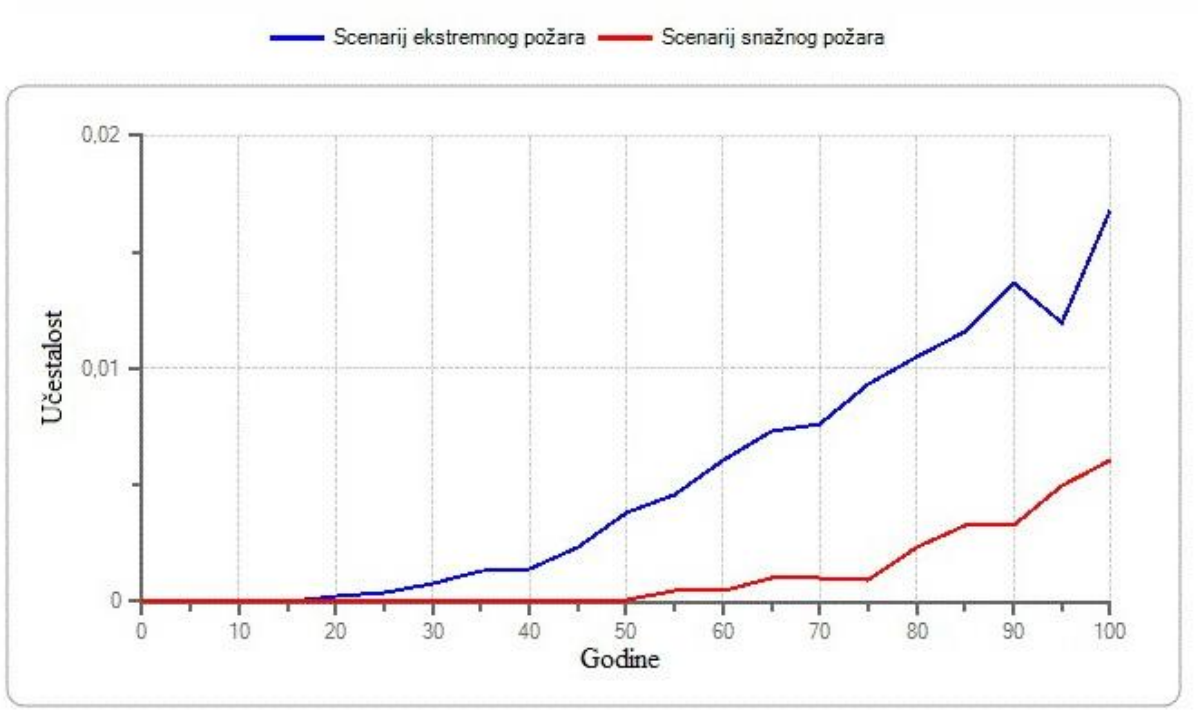


Slika 15. Opseg ponavljanja scenarija izumiranja vrste *A. kitaibelii* za svaku pojedinu godinu u modelu ekstremnog požara pri čemu su podaci prezentirani u 5-ogodišnjim vremenskim intervalima

Srednja stopa rasta populacije (r) s obzirom na nivo zasićenosti okoliša iznosi -0,0285 ± 0,0003 ili -2,85 % godišnje.

Odnos udjela mužjaka i ženki je 1:1 i iznosi 1175,87 mužjaka i 1175,83 ženke.

Usporedbom dobivenih rezultata procjene vjerojatnosti izumiranja za oba scenarija vidljiva je razlika u procjeni vjerojatnosti izumiranja, odnosno broju ponavljanja slučajeva u kojima populacija izumire prije isteka istraživanog vremenskog perioda (Slika 16).



Slika 16. Opseg ponavljanja scenarija izumiranja vrste *A. kitaibelii* za svaku pojedinu godinu za oba scenarija u modelu katastrofe pri čemu su podaci prezentirani u 5-ogodišnjim vremenskim intervalima

c) Model dinamike rasta populacije s obzirom na degradaciju staništa (negativna promjena *K* vrijednosti)

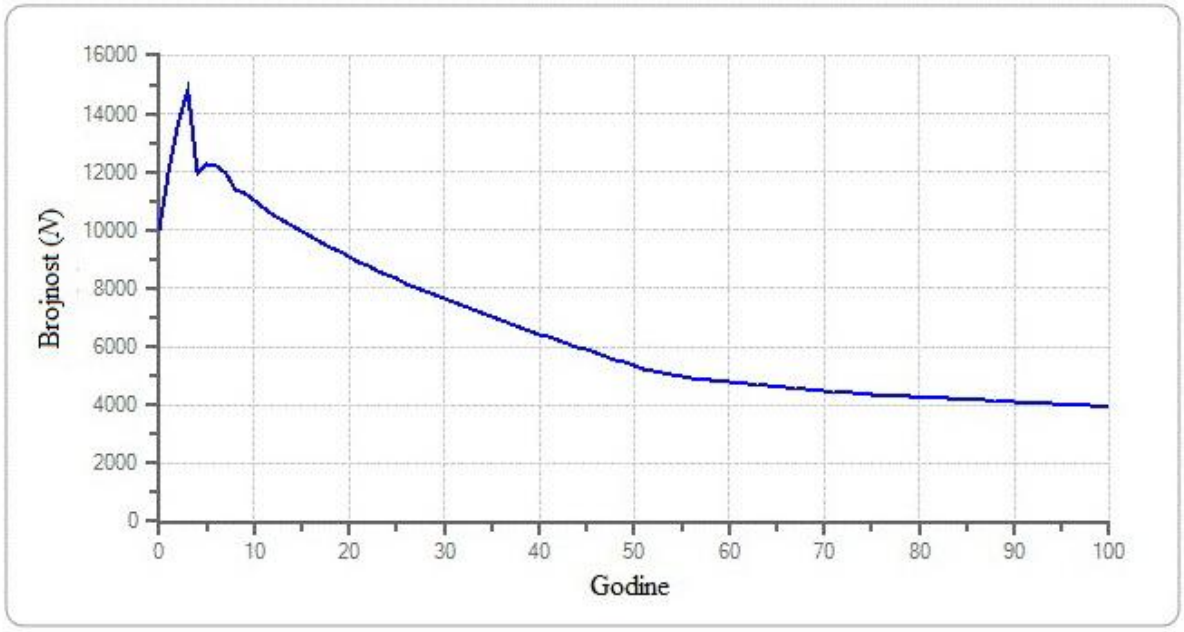
Model umjerene degradacije

Dobiveni rezultati procjenjuju 100 %-tnu vjerojatnost opstanka populacije u uvjetima umjerene degradacije staništa. Prema tome, niti u jednom provedenom scenariju nije došlo do izumiranja populacije.

Početna populacija (N_0) postigla je vrijednost *K* u 3. simulacijskoj godini. Veličina populacije (*N*) pri dostizanju *K* iznosila je 14834,77 ± 14,68 jedinki. Degradacijom staništa smanjuje se *K*, i procjenjena dinamika promjene rasta populacije dobivena provedenim modelom potkrepljuje tu tezu. Tako da, počevši od 4. simulacijske godine dolazi do eksponencijalnog pada brojnosti populacije koja postupno ulazi u dinamičku ravnotežu u intervalu od 50-e do 60-e simulacijske godine (Slika 17).

Vrijednosti veličine populacije (*N*), standardne pogreške (SE) i standardne devijacije (SD) za svaku pojedinu četvrtinu vremenskog perioda prikazane su u tablici 12.

Usporedbom vremenskog perioda aktivnosti degradacije staništa sa vremenom nakon degradacije evidentna je razlika u padu brojnosti populacije (Tablica 13).



Slika 17. Dinamika promjene brojnosti populacije vrste *A. kitaibelii* kroz vrijeme u modelu umjerene degradacije staništa

Tablica 12. Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za model umjerene degradacije staništa

	0 godina	25 godina	50 godina	75 godina	100 godina
Veličina populacije (*N*)	10000	8313,84	5343,38	4348,67	3936,71
Standardna pogreška (SE)	0	29,18	21,56	22,39	23,61
Standardna devijacija (SD)	0	2917,9	2155,61	2239,4	2361,26

Tablica 13. Razlike u padu brojnosti populacije promatrajući interval koji obuhvaća degradacija staništa sa vremenskim periodom nakon degradacije zaključno sa istekom zadnje simulacijske godine modela u scenariju umjerene degradacije

Vremenski period	0.-50. godine (degradacija)	51.-100. godine (nakon degradacije)
Razlika u brojnosti	4656,62	1310,78

Srednja stopa rasta populacije (r) iznosi 0,0067 ± 0,0002 ili 0,67 % godišnje.

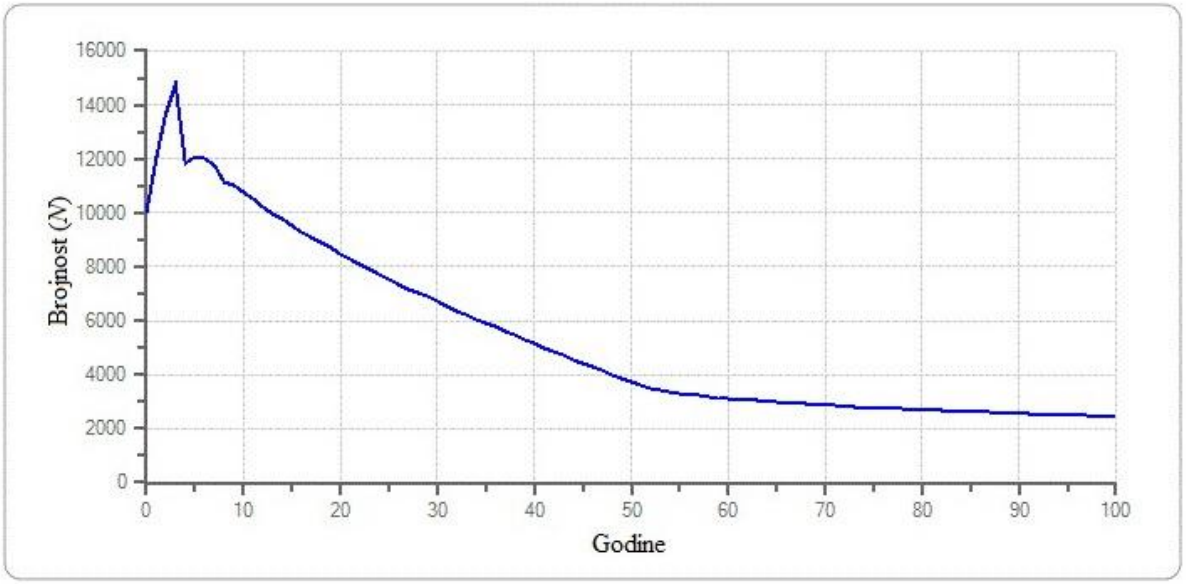
Odnos udjela mužjaka i ženki je 1:1 i iznosi 1968,36 mužjaka i 1968,35 ženki.

Model povišene degradacije

Prema dobivenim rezultatima procjenjuje se 100 %-tna vjerojatnost opstanka populacije.

Početna populacija (N_0) postigla je nivo zasićenosti okoliša (K) u 3. simulacijskoj godini. Veličina populacije (N) pri dostizanju K iznosila je 14765,36 ± 14,28 jedinki. Međutim, počevši od 4. simulacijske godine dolazi do eksponencijalnog pada brojnosti populacije koja postupno ulazi u dinamičku ravnotežu u intervalu od 50-e do 60-e simulacijske godine (Slika 18).

Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za svaku pojedinu četvrtinu vremenskog perioda prikazane su u tablici 14.



Slika 18. Dinamika promjene brojnosti populacije vrste *A.kitaibelii* kroz vrijeme u modelu povišene degradacije staništa

Tablica 14. Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za model povišene degradacije staništa

	0 godina	25 godina	50 godina	75 godina	100 godina
Veličina populacije (*N*)	10000	7533,43	3731,23	2753,48	2444,8
Standardna pogreška (SE)	0	24,62	11,97	13	13,88
Standardna devijacija (SD)	0	2461,91	1196,91	1300,23	1387,76

Usporedbom vremenskog perioda aktivnosti degradacije staništa sa vremenom nakon degradacije evidentna je razlika u padu brojnosti populacije (Tablica 15).

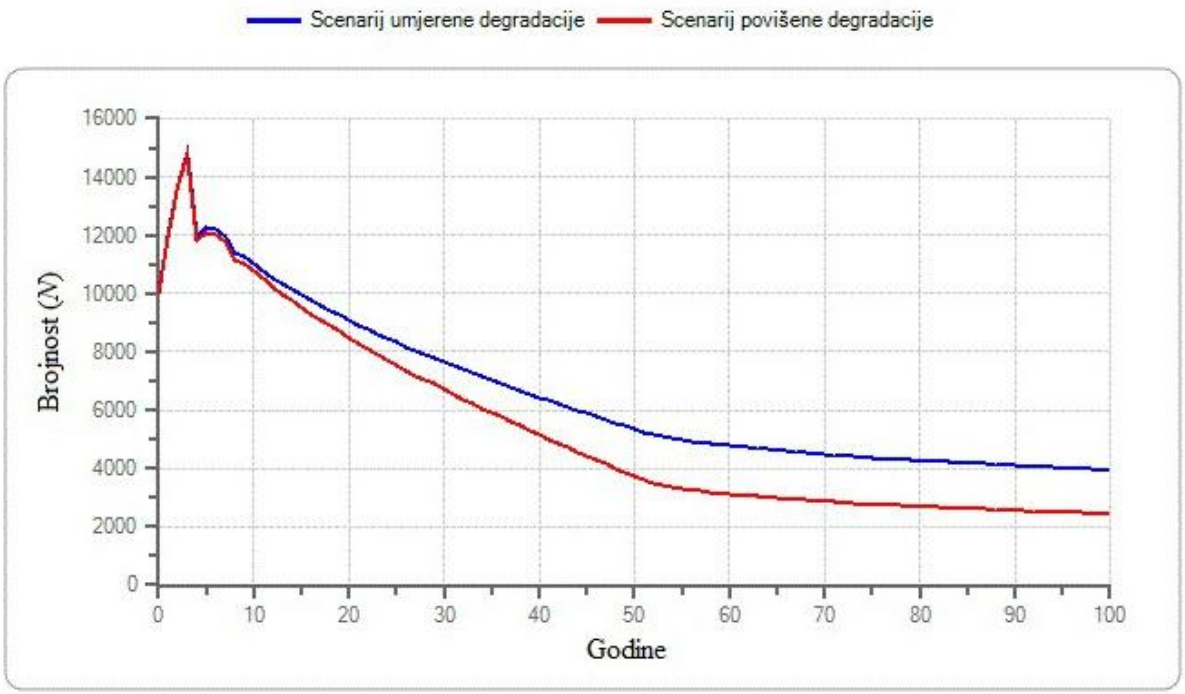
Tablica 15. Razlike u padu brojnosti populacije promatrajući interval koji obuhvaća degradacija staništa sa vremenskim periodom nakon degradacije zaključno sa istekom zadnje simulacijske godine modela u scenariju povišene degradacije

Vremenski period	0.- 50. godine (degradacija)	51.-100. godine (nakon degradacije)
Razlika u brojnosti	6268,77	1140,05

Srednja stopa rasta populacije (*r*) iznosi 0,0058 ± 0,0002 ili 0,58 % godišnje.

Odnos udjela mužjaka i ženki je 1:1 i iznosi 1222,41 mužjaka i 1222,38 ženki.

Usporedbom dobivenih rezultata promjene dinamike rasta populacije za oba scenarija degradacije staništa vidljiva je razlika u ukupnom padu brojnosti kao i u intenzitetu opadanja broja jedinki. Pri isteku stogodišnjeg vremenskog perioda razlika u brojčanom stanju populacije iznosi 1491,91 jedinka u korist scenarija umjerene degradacije staništa (Slika 19).

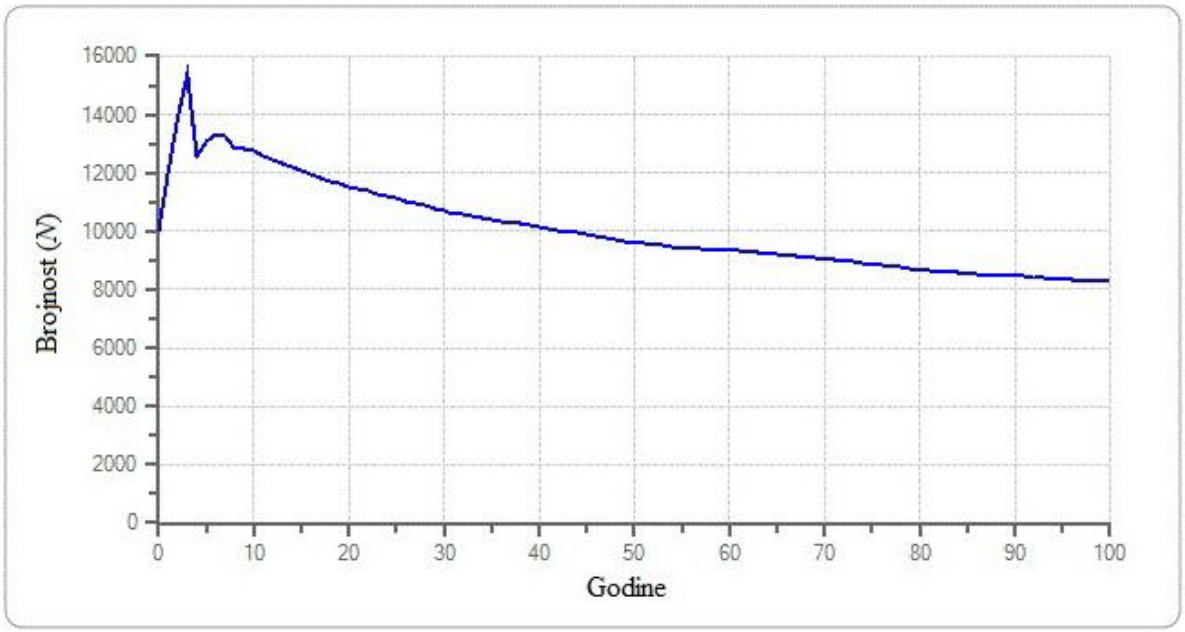


Slika 19. Prikaz dobivenih rezultata promjene dinamike rasta populacije vrste *A.kitaibelii* za oba scenarija u modelu degradacije staništa

5.3. Procjena opstajnosti populacije *A. kitaibelii* na Papuku u scenariju povećanja veličine staništa uklanjanjem nasada crnog bora (*Pinus nigra*)

Rezultati provedene simulacije su pokazali 100 % - tnu uspješnost opstanka populacije u istraživanom vremenskom periodu, odnosno ni u jednom scenariju provedene simulacije nije došlo do izumiranja populacije.

Zasićenost okoliša (*K*) postignuta je u 3. Simulacijskoj godini pri čemu je brojnost iznosila 15362,84 ± 18,37 jedinke. Dinamika rasta populacije prikazana je na slici 20. Vrijednosti veličine populacije (*N*), standardne pogreške (SE) i standardne devijacije (SD) za svaku pojedinu četvrtinu vremenskog perioda prikazane su u tablici 16.



Slika 20. Dinamika promjene brojnosti populacije vrste *A.kitaibelii* kroz vrijeme u modelu povečanja staništa uklanjanjem nasada crnog bora (*Pinus nigra*)

Tablica 16. Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za model povečanja staništa uklanjanjem nasada crnog bora (*Pinus nigra*)

	0 godina	25 godina	50 godina	75 godina	100 godina
Veličina populacije (*N*)	10000	11114,96	9604,6	8867,71	8255,4
Standardna pogreška (SE)	0	47,42	52,46	54,61	55,65
Standardna devijacija (SD)	0	4741,68	5245,68	5461,07	5565,25

Srednja stopa rasta populacije (*r*) iznosi 0,0071 ± 0,0002 ili 0,7 % godišnje.

Odnos udjela mužjaka i ženki je 1:1 i iznosi 4127,70 mužjaka i 4127,70 ženki.

Usporedbom dobivenih rezultata procjene brojnosti populacije modela povečanja kapaciteta staništa sa rezultatima temeljnog modela očigledna je pozitivna razlika u brojnost u korist modela povečanja kapaciteta staništa (Tablica 17).

Tablica 17. Usporedba brojnosti populacije modela povečanja kapaciteta staništa sa temeljnim modelom

Model povečanja kapaciteta staništa	0 godina	25 godina	50 godina	75 godina	100 godina
Veličina populacije (*N*)	10000	11114,96	9604,6	8867,71	8255,4
Standardna pogreška (SE)	0	47,42	52,46	54,61	55,65
Standardna devijacija (SD)	0	4741,68	5245,68	5461,07	5565,25
Temeljni model	**0 godina**	**25 godina**	**50 godina**	**75 godina**	**100 godina**
Veličina populacije (*N*)	10000	9886,39	8523,65	7765,34	7260,31
Standardna pogreška (SE)	0	40,57	45,01	47,18	48,31
Standardna devijacija (SD)	0	4056,66	4500,86	4717,73	4831,11

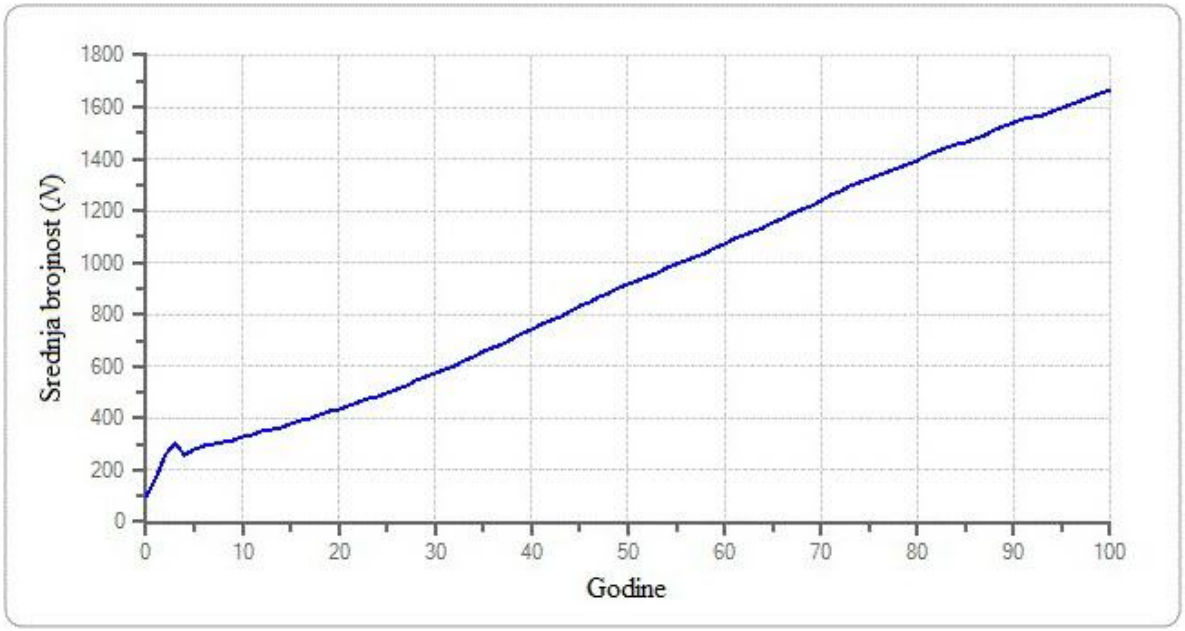
5.4. Procjena opstajnosti populacije *A. kitaibelii* na Papuku u scenariju s introdukcijom vrste na dva nova vrha Lapjak i Topličke glava (100 %-tno povečanje staništa)

Model povečanja staništa osim osnovne i dvaju novih populacija obuhvaća i metapopulaciju, odnosno ukupnu vjerojatnost opstanka na razini svih populacija zajedno. Modeli su rađeni sa optimalnim vrijednostima okolišnih parametara.

a) Populacija Lapjak

Simulacija introdukcije na vrh Lapjak od 10 000 ponavljanja scenarija u 309 slučajeva populacija izumire, a u 9691 scenariju opstaje. Prema tome, dobiveni rezultati simulacije su pokazali da vjerojatnost opstanka populacije iznosi 0,9691 ± 0,0017 odnosno 96,91 %. Sukladno stopi opstanka, vjerojatnost izumiranja populacije iznosi 0,0309 ± 0,0017 odnosno 3,09 %. Dinamika rasta populacije prikazana je na slici 21.

Vrijednosti veličine populacije (*N*), standardne pogreške (SE) i standardne devijacije (SD) za svaku pojedinu četvrtinu vremenskog perioda prikazane su u tablici 18. Svi navedeni podaci predstavljaju vrijednosti dobivene od populacija koje su opstale, dok vrijednosti ukupnog broja populacija zajedno sa scenarijima izumrlih populacija nisu uzete u obzir.



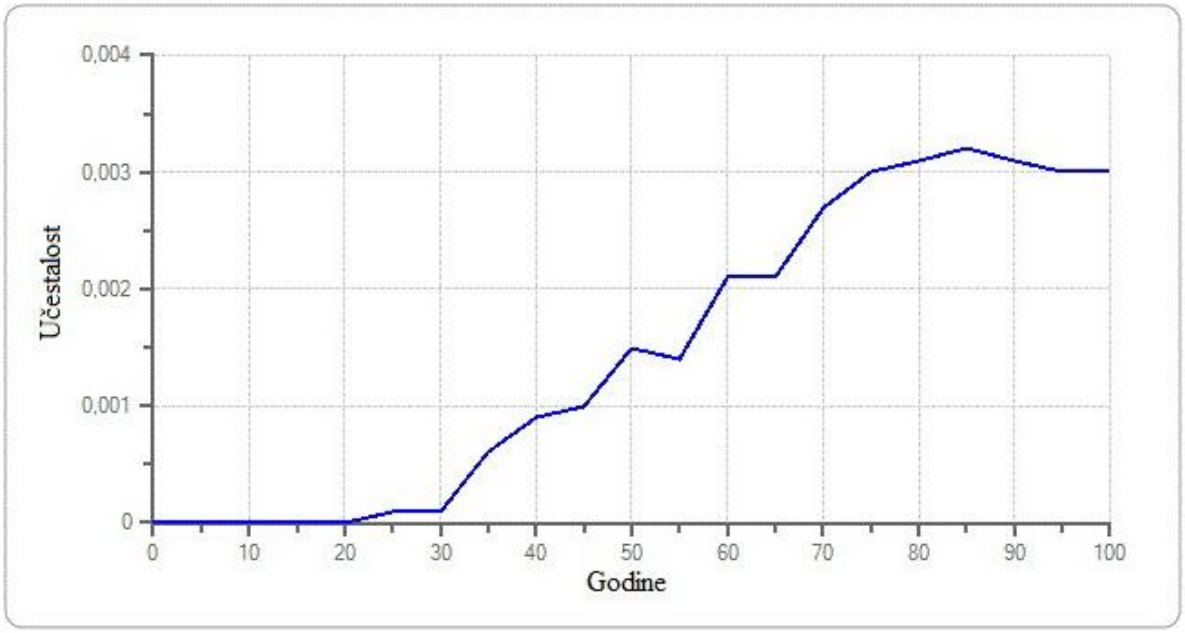
Slika 21. Dinamika promjene brojnosti populacije vrste *A.kitaibelii* kroz vrijeme za populaciju Lapjak u modelu introdukcije vrste na dva nova lokaliteta

Tablica 18. Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za populaciju Lapjak u modelu introdukcije vrste na nove lokalitete

	0 godina	25 godina	50 godina	75 godina	100 godina
Veličina populacije (N)	100	498,58	916,87	1324,61	1669,69
Standardna pogreška (SE)	0	5,81	13,64	18,53	21,51
Standardna devijacija (SD)	0	580,52	1360,97	1838,63	2117,64

Srednja vrijednost vremena prvog izumiranja populacije unutar vremenskog intervala iznosi 73,06 ± 1,01 godina pri čemu je raspon ponavljanja scenarija u kojemu populacija izumre u intervalu od 23. godine do kraja određenog vremenskog perioda, zaljučno sa 100-tom godinom.

Od ukupnog broja ponavljanja scenarija izumiranja populacije najveća vrijednost izumiranja zabilježena je za vremenski interval od 80-e do 85-e godine pri čemu iznosi 0,0032 ili 0,32 %. (Slika 22).



Slika 22. Opseg ponavljanja scenarija izumiranja vrste *A.kitaibelii* za svaku pojedinu godinu pri čemu su podaci prezentirani u 5-ogodišnjim vremenskim intervalima za populaciju Lapjak u modelu introdukcije vrste na dva nova lokaliteta

Srednja stopa rasta populacije (r) s obzirom na nivo okolišne zasićenosti iznosi 0,0179 ± 0,0002 ili 1,79 % godišnje.

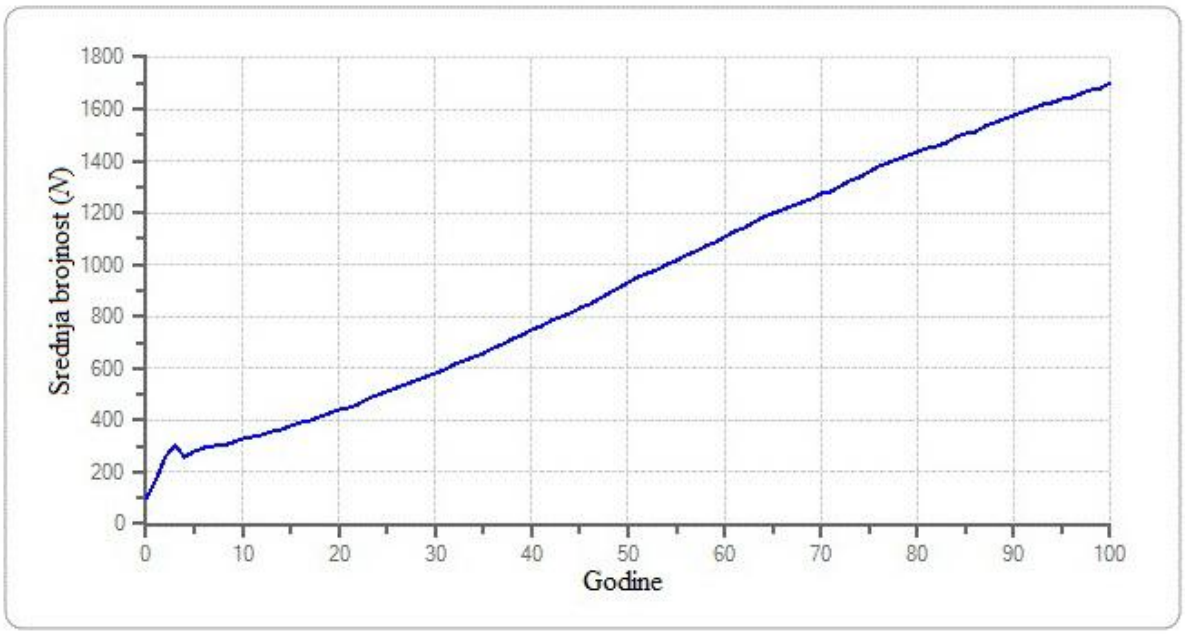
Odnos udjela mužjaka i ženki je 1:1 i iznosi 834,85 mužjaka i 834,84 ženki.

b) Populacija Toplička glava

Model introdukcije populacije na lokalitet Toplička glava od 10 000 ponavljanja scenarija u 302 slučaja populacija je izumrla a u 9698 scenarija je opstala. Iz dobivenih rezultata je vidljivo da vjerojatnost opstanka populacije iznosi 0,9698 ± 0,0017 ili 96,98 %. Sukladno stopi opstanka, vjerojatnost izumiranja procjenjuje se na 0,0302 ± 0,0017 ili 3,02 %. Dinamika promjene rasta populacije prikazana je na slici 23.

Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za svaku pojedinu četvrtinu vremenskog perioda prikazane su u tablici 19. Svi navedeni podaci predstavljaju vrijednosti dobivene od populacija koje su opstale, dok vrijednosti

ukupnog broja populacija zajedno sa vrijednostima scenarija izumrlih populacija nisu uzete u obzir.



Slika 23. Dinamika promjene brojnosti populacije vrste *A.kitaibelii* kroz vrijeme za populaciju Toplička glava u modelu introdukcije vrste na dva nova lokaliteta

Tablica 19. Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za populaciju Toplička glava u modelu introdukcije vrste na nove lokalitete

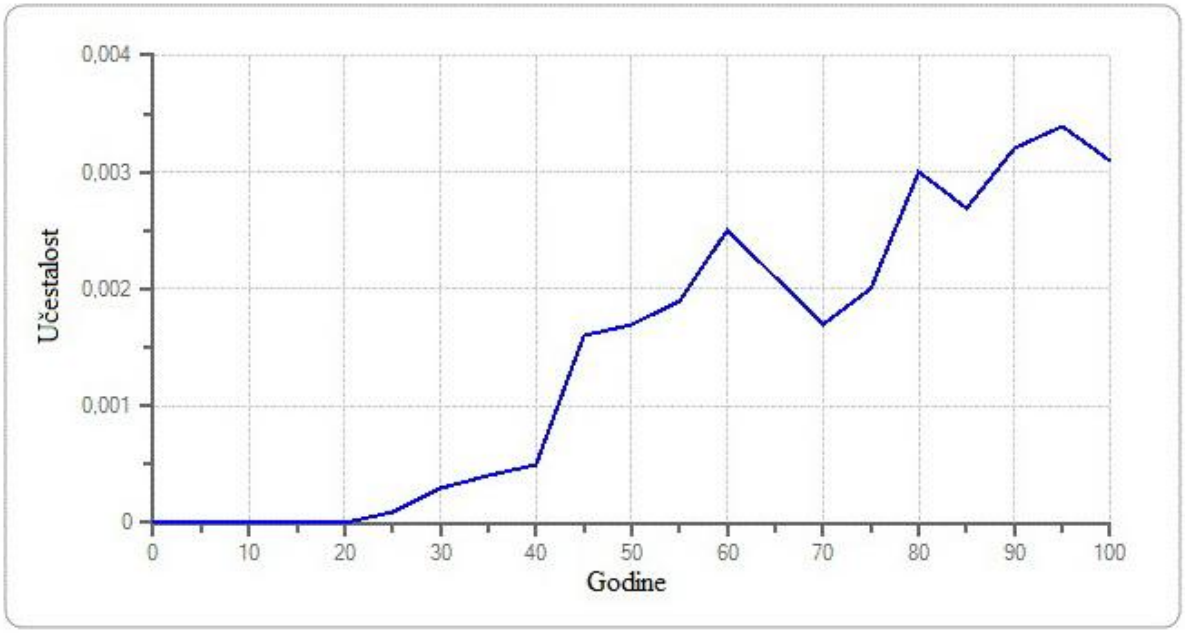
	0 godina	25 godina	50 godina	75 godina	100 godina
Veličina populacije (N)	100	509,34	930,67	1358,1	1701,81
Standardna pogreška (SE)	0	5,99	13,97	18,88	21,76
Standardna devijacija (SD)	0	599,41	1393,92	1873,79	2143,34

Prema dobivenim podacima vremena izumiranja srednja vrijednost vremena prvog izumiranja populacije iznosi 72,60 ± 1,07 godina.

Raspon ponavljanja scenarija u kojemu populacija izumre minimalno u jednom slučaju je u intervalu od 25. godine do isteka vremenskog perioda od 100 godina.

Od ukupnog broja ponavljanja scenarija izumiranja populacije najveća vrijednost izumiranja zabilježena je za vremenski interval od 90-e do 95-e godine sa postizanjem

maksimuma u 95-oj godini. Visoke vrijednosti vjerojatnosti izumiranja zabilježene su i za interval od 60-e do 65-e godine kao i nagli rast unutar intervala od 75-e do 80-e godine (Slika 24).

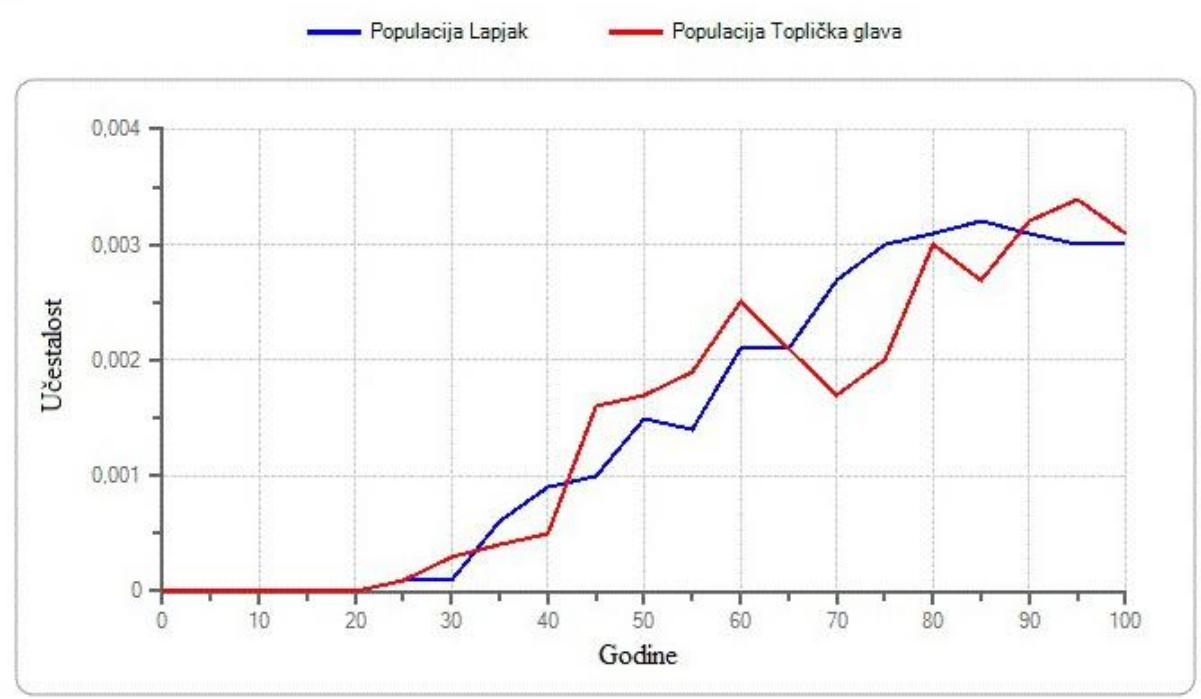


Slika 24. Opseg ponavljanja scenarija izumiranja vrste *A.kitaibelii* za svaku pojedinu godinu pri čemu su podaci prezentirani u 5-ogodišnjim vremenskim intervalima za populaciju Toplička glava u modelu introdukcije vrste na dva nova lokaliteta

Srednja stopa rasta populacije (*r*) s obzirom na nivo okolišne zasićenosti iznosi 0,0180 ± 0,0002 ili 1,8 % godišnje.

Udio mužjaka i ženki je 1:1 i iznosi 850,90 mužjaka i 850,91 ženki.

Usporedba dobivenih procjena opsega ponavljanja scenarija izumiranja za svaku pojedinu godinu istraživanog vremenskog intervala za oba scenarija introdukcije vrste na dva nova lokaliteta prikazana je na slici 25.



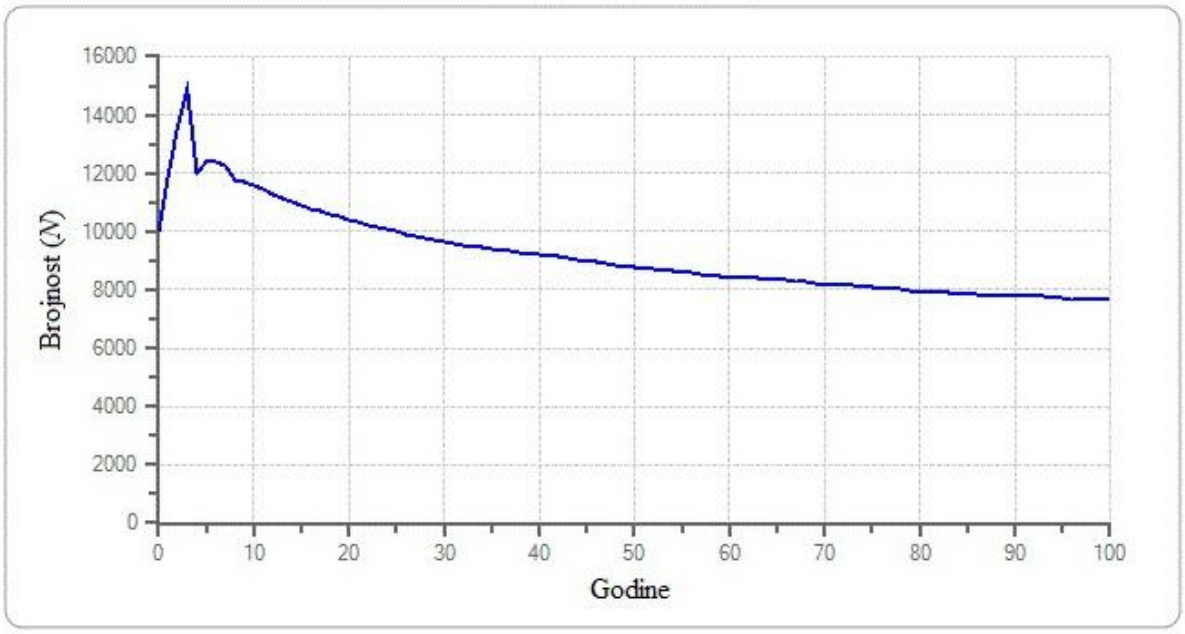
Slika 25. Opseg ponavljanja scenarija izumiranja vrste *A. kitaibelii* za svaku pojedinu godinu pri čemu su podaci prezentirani u 5-ogodišnjim vremenskim intervalima za obje introducirane populacije u modelu introdukcije vrste na nove lokalitete

c) Temeljna populacija

Predstavlja osnovu na temelju koje se vršila translokacija na nove lokalitete. Dobiveni rezultati modela procjenjuju vjerojatnost opstanka populacije u vrijednosi 1,00 odnosno 100 %. Prema tome, ni u jednom od 10 000 simuliranih scenarija nije došlo do izumiranja populacije niti u jednoj godini istraživanog vremenskog perioda.

Početna populacija (N_0) od 10 000 jedinki postigla je nivo zasićenosti okoliša u 3. Simulacijskog godini u vrijednosti od 14854,58 ± 16,89 jedinki. Dinamika rasta populacije prikazana je na slici 26.

Vrijednosti veličine populacije (*N*), standardne pogreške (SE) i standardne devijacije (SD) za svaku pojedinu četvrtinu vremenskog perioda prikazane su u tablici 20.



Slika 26. Dinamika promjene brojnosti populacije vrste *A. kitaibelii* kroz vrijeme za temeljnu populaciju u modelu introdukcije vrste na dva nova lokaliteta

Tablica 20. Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za temeljnu populaciju u modelu introdukcije vrste na nove lokalitete

	0 godina	25 godina	50 godina	75 godina	100 godina
Veličina populacije (N)	10000	9996,83	8759,52	8077,92	7627,28
Standardna pogreška (SE)	0	42,03	46,41	48,38	49
Standardna devijacija (SD)	0	4231,87	4640,79	4838,37	4899,69

Srednja stopa rasta populacije (*r*) s obzirom na nivo zasićenosti okoliša iznosi 0,0106 ± 0,0002 ili 1,06 % godišnje.

Udio mužjaka i ženki je 50/50 % i iznosi 3813,65 mužjaka i 3813,63 ženke.

Usporedba rezultata modela temeljne populacije sa osnovnim populacijskim modelom i modelom minimalnog mortaliteta potvrđuje korelaciju brojnosti jedinki između različitih modela koji se temelje na istim i sličnim vrijednostima okolišnih parametara (Tablica 21).

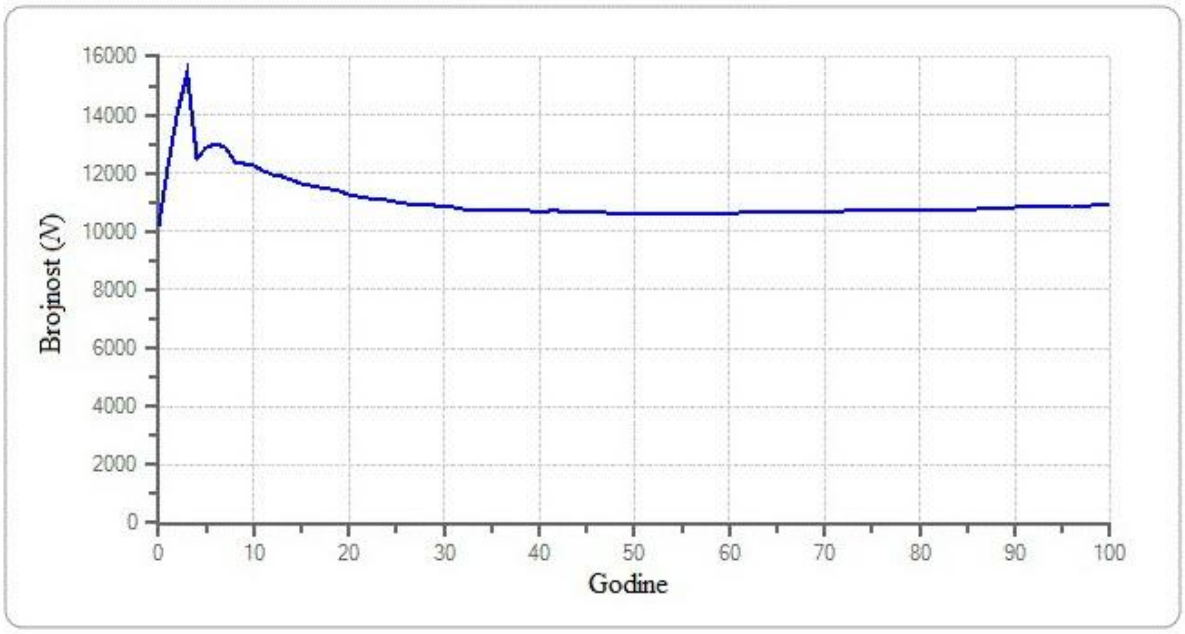
Tablica 21. Usporedba brojnosti populacije triju scenarija unutar različitih modela procjene vijabilnosti populacije

	Osnovni model	Model umjerene smrtnosti	Model introdukcije
Veličina populacije (N)	7260,31	7257,43	7627,28
Standardna pogreška (SE)	48,31	47,69	49
Standardna devijacija (SD)	4831,11	4769	4899,69

d) Metapopulacija

Metapopulacija predstavlja ukupnu vrijednost temeljne i dvaju introduciranih populacija zajedno. Prema dobivenim rezultatima vjerojatnost opstanka na razini metapopulacije iznosi 1,00 odnosno 100 %. Drugim riječima ni u jednom od 10 000 simuliranih scenarija nije došlo do izumiranja populacije niti u jednoj godini istraživanog vremenskog perioda.

Početna veličina populacije (N_0) od 10 200 jedinki dostigla je nivo okolišne zasićenosti (K) u 3. simulacijskoj godini kada je veličina populacije (N) iznosila 15458,42 ± 17,17 jedinke. Najniža brojčana vrijednost veličine populacije (N) izuzev N_0, zabilježena je u 58. simulacijskoj godini u iznosu od 10563,31 ± 56,64 jedinke. Dinamika rasta populacije prikazana je na slici 27. Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za svaku pojedinu četvrtinu vremenskog perioda prikazane su u tablici 22.



Slika 27. Dinamika promjene brojnosti populacije vrste *A. kitaibelii* kroz vrijeme za metapopulaciju u modelu introdukcije vrste na dva nova lokaliteta

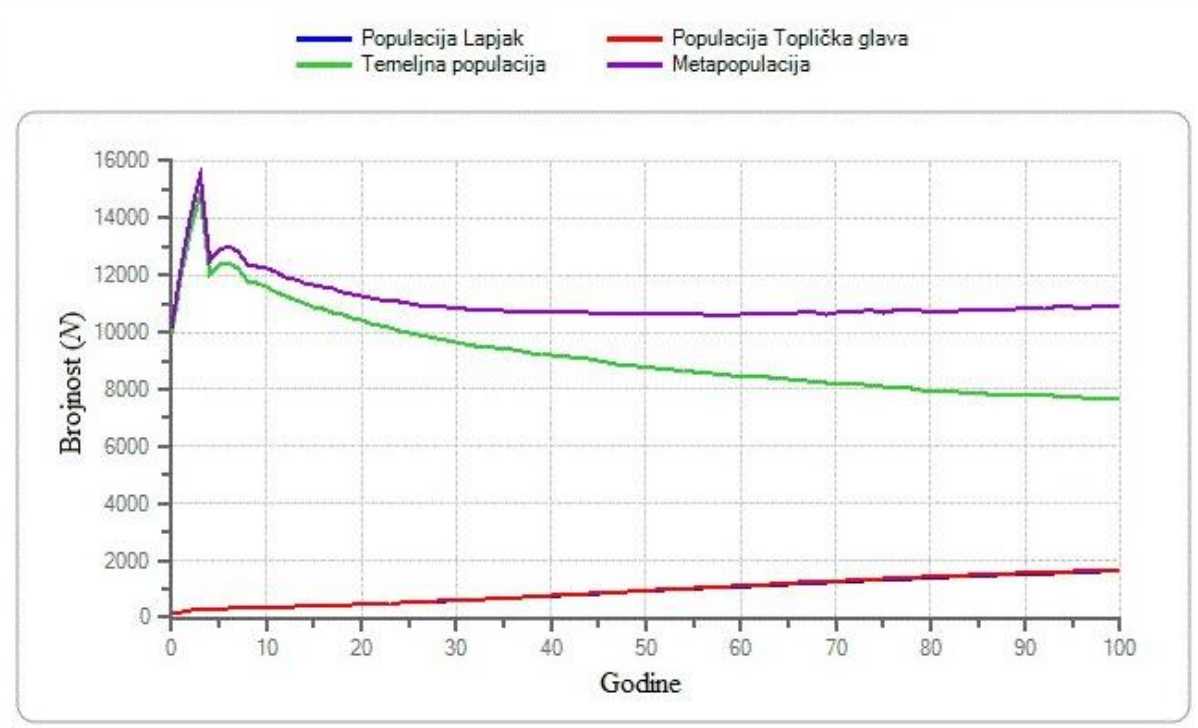
Tablica 22. Vrijednosti veličine populacije (N), standardne pogreške (SE) i standardne devijacije (SD) za metapopulaciju u modelu introdukcije vrste na nove lokalitete

	0 godina	25 godina	50 godina	75 godina	100 godina
Veličina populacije (*N*)	10200	11004,64	10598,93	10720	10895,79
Standardna pogreška (SE)	0	44,94	54,52	60,96	64,56
Standardna devijacija (SD)	0	4494,1	5451,91	6096,25	6455,93

S obzirom na nivo zasićenosti okoliša (*K*) srednja vrijednost stope rasta populacije (*r*) iznosi 0,0144 ± 0,0001 ili 1,44 %.

Udio mužjaka i ženki je 1:1 i iznosi 5447,91 mužjak i 5447,89 ženki.

Usporedbom dobivenih rezultata metapopulacije sa rezultatima temeljne poppulacije i dvaju introduciranih populacija vidljiva je promjena trenda dinamike rasta na razini metapopulacije koja se očituje u povečanju brojnosti počevši od 58. simulacijske godine pa nadalje, sve do isteka stogodišnjeg vremenskog perioda (Slika 28).



Slika 28. Dinamika promjene brojnosti populacije vrste *A. kitaibelii* kroz vrijeme za model introdukcije vrste na dva nova lokaliteta za sve tri populacije uključujući i metapopulaciju

6. RASPRAVA

Ivanjski rovaš (*A. kitaibelii*) prvi put je zabilježen u Hrvtaskoj godine 2008. na lokalitetu Turjak na Papuku (Szövényi i Jelić, 2011), i tada postaje predmetom različitih ekoloških istraživanja (Szövényi i Jelić, 2011). Poznavanje biologije vrste *A. kitaibelii* osnovni je preduvjet za daljnja biološka istraživanja (Arnold, 2002; Gruber, 1981). Za procjenu vijabilnosti i opstojnosti populacija različitih vrsta kralježnjaka u novije vrijeme intenzivno se koristi program Vortex (Miller i Lacy, 2005; Lacy, 1993; Lacy i sur., 2014). S obzirom na premali broj radova iz kvantitativne biologije obavljenih na vrsti *A. kitaibelii* obavio sam procjenu vijabilnosti i opstojnosti populacije *A. kitaibelii*. Prema dobivenim rezultatima procjene opstojnosti populacije u sadašnjim uvjetima, iako je 100 %-tna vjerojatnost preživljanja, ukupna dinamika rasta populacije ima negativan predznak (Slika 6). Negativni trend promjene očituje se u padu brojnosti kroz istraživani vremenski period (Tablica 7). Prema dobivenim rezultatima procjene opstanka i negativnom trendu dinamike rasta populacije može se zaključiti da će istraživana populacija izumrijeti u nekom periodu nakon isteka istraživanog vremenskog intervala od 100 godina. Budući da temeljni model predstavlja simulaciju idealnih uvijeta za normalan rast i razvoj populacije s obzirom na stohastičnost sustava može se zaključiti da bi pojava i aktiviranje pojedinih negativnih čimbenika ubrzala negativan trend dinamike rasta i pogurnula populaciju u prijevremeno izumiranje. Prema dobivenim rezultatima scenarija minimalnog mortaliteta model je rubno prolazan (Slika 7). Budući da je trend rasta populacije negativan, odnosno brojnost opada, prisutnost dodatnog negativnog činioca može pogurnuti populaciju u izumiranje i prije isteka 100-godišnjeg vremenskog perioda. Rezultati scenarija povišenog mortaliteta su pokazali da povečanjem smrtnosti juvenilnih jedinki za 10 % dolazi do drastičnog pada procjene vjerojatnosti opstanka populacije (Slika 9). Drugim riječima, naglo se povečava vjerojatnost izumiranja populacije. Iako scenarij procjenjuje prisutnost malog broja jedinki na kraju isteka 100-godišnjeg vremenskog perioda, s obzirom na stohastičnost, može se zaključiti da će populacija vrlo brzo izumrijeti. Rezultati modela mortaliteta juvenilnih jedinki pokazuju da vrijednost stope smrtnosti juvenilnih jedinki uvelike utječe na opstojnost i vijabilnost populacije. Manja promjena u vrijednosti stope smrtnosti uvelike povečava vjerojatnost izumiranja (Slika 11). Rezultati oba scenarija modela požara kao primjer vanjskog okolišnog parametra koji utječe na dinamiku rasta populacije pokazuju negativan trend rasta, odnosno pad brojnosti populacije koji se očituje kao posljedica požara u staništu. Dobiveni rezultati

pokazuju da će populacija, iako opstaje istraživani vremenski period, izumrijeti u određenom intervalu nakon isteka 100-godišnjeg vremenskog perioda (Slika 12, 14). Prema dobivenim rezultatima procjene i usporedbom rezultata dvaju scenarija vjerojatnost izumiranja približno je 4 puta veća u scenariju ekstremnog požara (Slika 16). Rezultatima provedenog modela može se zaključiti da su intenzitet i učestalost požara u korelaciji sa vjerojatnošću izumiranja. Rezultati modela degradacije staništa potvrdili su negativne učinke obraštanja staništa (Slika 16, 17). Eksponencijalni pad brojnosti u vremenu degradacije posljedica je gubitka staništa, odnosno smanjenja kapaciteta okoliša. Raspoloživi resursi neophodni za normalan rast i razvoj dijele se na veći broj jedinki. Vrijednost omjera resursa s jedne strane i broja jedinki sa druge direktno utječe na vijabilnost populacije. Za vrijednost ≥ 1 očekuje se da će broj jedinki rasti ili biti ravnoteži. Vrijednost omjera < 1 uvjetuje pad brojnosti populacije dok se ponovno ne uspostavi ravnoteža. Razlika u padu brojnosti u vremenu degradacije između dva scenarija posljedica je intenziteta i opsega degradacije. Odnosno, eksponencijalni pad brojnosti u korelaciji je sa intenzitetom degradacije (Slika 18). Prema dobivenim podacima modela uklanjanja nasada crnog bora vijabilnost populacije se povečava antropološkim aktivnostima koje pozitivno utječu na dinamiku rasta populacije. Iako je trend rasta negativan, usporedbom sa rezultatima temeljnog modela, prisutan je pozitivan trend koji se očituje u većem broju jedinki prisutnom kroz cijeli istraživani vremenski period (Tablica 17). Podaci dobiveni provedenim simulacijama procjene vijabilnosti dvaju novih introduciranih populacija pokazuju pozitivan trend u dinamici rasta. Prema modelu, introducirane populacije rastu eksponencijalno (Slika 21, 23). Rezultati provedene simulacije su i očekivani budući da jedinke nisu ograničene resursima i imaju sve preduvijete koji omogučavaju nesmetani rast i razvoj. Usporedbom dobivenih rezultata procjene vjerojatnosti izumiranja za oba scenarija može se zaključiti da je vjerojatnost izumiranja izrazito niska i približno jednaka za oba modela (Slika 25). Međutim, s obzirom na nisku brojčanu vrijednost populacija, prisutnost pojedinog vanjskog ili unutarnjeg čimbenika koji bi potencijalno mogao biti poguban za jedinke mogao bi pogurnuti populacije u prijevremeno izumiranje. Može se reći da su populacije s obzirom na brojčano stanje kritički prolazne. Dobiveni rezultati scenarija temeljne populacije procjenjuju visoku opstojnost populacije kroz istraživani vremenski period iako je dinamika rasta populacije u opadanju, odnosno očituje se blagi negativni trend rasta (Slika 26). S obzirom na stohastičnost za očekivati je da će negativan trend rasta biti veći nego što model procjenjuje, tako da je opstojnost precjenjena. Međutim, podaci dobiveni provedenom simulacijom potvrđuju vjerodostojnost rezultata. Odnosno u tri različita modela (osnovni populacijski model, model dinamike rasta populacije s obzirom na stopu smrtnosti

juvenilnih jedinki i model introdukcije vrste na dva nova lokaliteta) scenariji koji predstavljaju optimalne uvjete za rast i razvoj jedinki daju približno iste rezultate u procjeni vjerojatnosti opstanka i brojčanoj vrijednosti populacije (Tablica 21). Budući da dobiveni podaci procjene vijabilnosti populacije procjenjuju pozitivnu dinamiku rasta populacije na razini metapopulacije (Slika 27) za očekivati je da će se pozitivan trend rasta populacije nastaviti i nakon isteka istraživanog vremenskog perioda. Model introdukcije vrste sa dobivenim rezultatima brojnosti populacije uključujući sve tri populacije zajedno sa metapopulacijom prikazan je na slici 28.

7. ZAKLJUČAK

- Istraživanje je pokazalo da je i pri idealnim uvjetima dinamika rasta populacije negativna.
- Stohastičnost sustava i duljina trajanja istraživanog vremenskog perioda pokazuje da će populaciju u određenom trenutku pogoditi određeni negativni čimbenik i ubrzati proces izumiranja.
- Rezultati pokazuju da je u temeljnom modelu opstojnost populacije precijenjena.
- Unutarnji čimbenici, kao stopa smrtnosti juvenilnih jedinki, imaju drastično veći utjecaj na vijabilnost i opstojnost populacije od vanjskih okolišnih čimbenika
- Vrijednosti ekoloških parametara svojstvenih populaciji nepromjenjivi su na vremenskim skalama i očituju se redovito neovisno o stohastičnosti sustava.
- Vrijednosti okolišnih čimbenika promjenjive su kroz vrijeme, odnosno čine stohastičnost sustava, pri čemu su njihove vrijednosti, intervali aktivnosti i jačina nepredvidivi
- Različite antropogene aktivnosti u staništu kojima se poboljšavaju životni uvjeti za vrstu pospješuju vijabilnost i opstojnost populacije.
- Model introdukcije vrste pokazuje da se stvaranjem subpopulacija, odnosno povečanjem stope prostorne varijacije, povečava vijabilnost i opstojnost populacije.
- Introdukciju vrste i mješanje subpopulacija potrebno je nastaviti, jer su introducirane populacije prostorno odjeljene, odnosno stopa imigracije i emigracije nije prisutna, jer će u protivnom novonastale populacije izumrijeti zbog djelovanja demografske varijacije na male populacije.
- Cjelokupna analiza rađena je kao populacijsko-usmjereni model koji pokazuje da sve jedinke u populaciji imaju jednake izglede za opstanak i reprodukciju, iako se ove stope mijenjaju u vremenu.
- Zbog nedostatka podataka ignorirana je individualna heterogenost ali i stopa predacije.
- Ignoriranjem individualne heterogenosti umanjuje se opstojnost populacije *A. kitaibelii*
- Proširenjem modela na individualno-usmjereni model osigurava se kvalitetnija i vjerodostojnija procjena vrijednosti vijabilnosti i opstojnosti populacije.

8. LITERATURA

Allee, WC., (1931): Animal Aggregations: A Study in General Sociology. University of Chicago Press, Chicago

Akçakaya, HR., Sjögren-Gulve P., (2000): Population viability analysis in conservation planning: an overview. Ecological Bulletins 48:9-21.

Arnold, EN. (2002): A field guide to the reptiles and amphibians of Britain and Europe. Second edition. Harper Collins Publishers, London 185-191str.

Augustine, DJ. (2010): Spatial versus temporal variation in precipitation in a semiarid ecosystem. Landscape ecology.

Bailey, LL., Simons, TR., Pollock, KH., (2004): Spatial and temporal variation in detection probability of plethod salamanders usin the robust capture-recapture design. Jurnal of wildlife management 68(1): 14-24.

Beissinger, SR., (1995): Modeling extinction in periodic environments: Everglades water levels and snail kite population viability. Ecological aplications vol.5, no.3: 618-631.

Belisle, M., Mendenhall, CD., Oviedo Brenes, F., Fukami, T., (2014): Temporal variation in fungal communities associated with tropical hummingbirds and nectarivorous bats. (u tisku).

Böhme, W., Lymberakis, P., Ajtic, R., Tok, V., Ugurtas, IH., Sevinç, M., Crochet, PA., Haxhiu, I., Sterijovski, B., Krecsák, L., Crnobrnja Isailovic, J., Kaska, J., Kumlutaş, Y., Avci, A., Jelić, D., (2009): *Ablepharus kitaibelii*. In: IUCN 2012. IUCN Red List of Threatened Species. Version 2012.2. <www.iucnredlist.org>; pristupljeno 26.11.2012.

Boitani, L., Fuller, TK., (2000): Research Techniques in Animal Ecology: Controversies and Consequences. Columbia University Press. 442 pp.

Boyce, MS., (1992): Population viability analysis. Annual Review of Ecology and Systematics 23: 481–506.

Bruce, JF., (2002): Characterization and Analysis of Temporal and Spatial Variations in Habitat and Macroinvertebrate Community Structure, Fountain Creek Basin, Colorado Springs and Vicinity, Colorado, 1998–2001. US Geological Survey, Water-Resources Investigations Report 02–4093.

Burgman, MA., Ferson, S., Akçakaya, HR., (1993): Risk assessment in conservation biology. London: Chapman & Hall.

Covaciu-Marcov, SD., Cicort-Lucaciu, AŞ., Gaceu, O., Sas, I., Ferenti, S., Bogdan, HV., (2009): The herpetofauna of the south-western part of Mehedinţi County, Romania. North-Western Journal of Zoology 5: 142-164.

DeAngelis, DL., Mooij, WM., (2005): Individual-based modeling of ecological and evolutionary processes. Annu. Rev. Ecol. Evol. Syst. 2005. 36:147–68

Dennis, B., Munholland, PL., Scott, JM., (1991): Estimation of growth and extinction parameters for endangered species. Ecological Monographs 6: 115–143.

Foley, P., (1994): Predicting extinction times from environmental stochasticity and carrying capacity. Conservation Biology 8: 124–136.

Flather, CH., Hayward, GD., Beissinger, SR., Stephens, PA., (2011): Minimum viable populations: is there a 'magic number' for conservation practitioners? Trends in Ecology and Evolution, December 2011, Vol. 26, 307-316

Gilpin, ME., Soule, ME., (1986): Minimum viable populations: processes of species extinction. In Conservation Biology: The Science of Scarcity and Diversity (Soule, M.E., ed.), pp. 19–34, Sinauer Associates

Grimm, V., Railsback, SF., (2004): Individual-based Modeling and Ecology. Princeton University press.

Gruber, U., (1981): *Ablepharus kitaibelii* (Bibron und Bory 1833) – Johannisechse. U Böhme, W. (ur.): Handbuch der Reptilien und Amphibien Europas Vol.1. Akademische Verlagsgesellschaft, Wiesbaden. 297-302.

Hanski, I., (1982): On patterns of temporal and spatial variation in animal populations. Ann. Zool. Fennici 19: 21-37.

Hassell, MP., (1975): Density-dependence in single-species populations. Journal of Animal Ecology 44: 283–295.

Hassell, MP., Lawton, JH., May, RM., (1976): Patterns of dynamical behaviour in single-species populations. Journal of Animal Ecology 45: 471–486.

Herczeg, G., Tóth, T., Kovács, T., Korsós, Z., Török, J., (2004): Distribution of *Ablepharus kitaibelii fitzingeri* Mertens, 1952 (Squamata: Scincidae) in Hungary. Russian Journal of Herpetology 1: 99 – 105.

Herczeg, G., Kovács, T., Korsós, Z. Török, J., (2007): Microhabitat use, seasonal activity and diet of the snake-eyed skink (*Ablepharus kitaibelii fitzingeri*) in comparison with sympatric lacertids in Hungary. Biologia 62: 482—487.

Holsinger, KE., (2013): Demography of small populations

Hutchinson, GE., (1978): An Introduction to Population Ecology. Yale University Press, New Haven

Ioannidis, Y., Chiras, G., Kardakari, N., (2008): Comparison of reptile communities in three types of thermophilous Mediterranean forest in southern Greece. Journal of Natural History 42: 421-433.

Janev-Hutinec, B., Kletečki, E., Lazar, B., Podnar-Lešić, M., Skejić, J., Tadić, Z., Tvrtković N., (2006): Crvena knjiga vodozemaca i gmazova Hrvatske. Ministarstvo kulture, Državni zavod za zaštitu prirode , 62-63 str.

Javna ustanova Parka prirode Papuk, (2010): Plan upravljanja PP Papuk, http://www.pp-papuk.hr/o_parku/zakonodavstvo.htm; preuzeto 19.08.2014.

Uetz, P., Hošek, J., (eds.), The Reptile Database, http://www.reptile-database.org, accessed Dec 8, 2014

Keedwell, RJ., (2004): Use of population viability analysis in conservation management in New Zealand, Science for conservation 243.

King, T., Chamberlan, C., Courage, A., (2014): Assessing reintroduction success in long-lived primates through population viability analysis: western lowland gorillas (*Gorilla gorilla gorilla*) in Central Africa . Oryx, 48, pp 294-303.

Korsós, Z., Csekés, R., Takács, E., (2008): New locality records of *Ablepharus kitaibelii fitzingeri* Mertens, 1952 from the area surrounding the river Ipel', in Slovakia and adjacent Hungary. North-Western Journal of Zoology 4: 125-128.

Kumlutas, Y., Öz, M., Özdemir, A., Rizvan Tunc, M., Durmus, H., Düsen, S., (2005): On the Populations of *Ablepharus kitaibelii* (Bibron and Bory, 1833) (Sauria: Scincidae) from South-Western Anatolia. Pakistan Journal of Biological Sciences 8: 461-465.

Lacy, RC., (1993): VORTEX - a model for use in population viability analysis. Wildl. Res., 20: 45-65.

Lacy, RC., Miller, PS., Traylor-Holzer, K., (2015): Vortex 10 User's Manual. 19 January 2015 update. IUCN SSC Conservation Breeding Specialist Group, and Chicago Zoological Society, Apple Valley, Minnesota, USA.

Lacy, RC., Pollak, JP., (2014): Vortex: A stochastic simulation of the extinction process. Version 10.0. Chicago Zoological Society, Brookfield, Illinois, USA.

Lande, R., (1988): Genetics and demography in biological conservation. Science 241: 1455–1460.

Lande, R., (1993): Risks of population extinction from demographic and environmental stochasticity and random catastrophes. American Naturalist 142: 911–927.

Larsen, DP., Kincaid, TM., Jacobs, SE., Urquhart, NS., (2001): Designs for evaluating local and regional scale trends. BioScience 61:1069–1078.

Leslie, PH., (1945): On the use of matrices in certain population mathematics. Biometrika 33: 183–212.

Lögdberg, F., (2011): Population dynamics in variable environments-impacts of noise colour and synchrony. Linköping Studies in Science and Technology, Dissertation No. 1416

Lewis Jr., WM., (1978): Comparison of Temporal and Spatial Variation in the Zooplankton of a Lake by Means of Variance Components. Ecology 59(4): 666-671.

Ljubisavljević, K., Džukić, G., Kalezić, M., (2002): Morphological differentiation of the Snake-eyed Skink *Ablepharus kitaibelii* (Bibron & Bory, 1833) in the north-western part of the species' range: systematic implications. Herpetozoa 14: 107-121

Mace, G., Sillero-Zubiri, C., (1997): A preliminary population viability analysis for the Ethiopian wolf. The Ethiopian wolf - status survey and conservation action plan., 51-60

Marsden, CD., Woodroffe, R., Mills, MGL., McNutt, W., Creel, S., Groom, R., Emanuel, M., Cleveland, S., Kat, P., Rasmusen, GSA., Ginsberg, J., Lines, R., Andre, J-M., Begg, C., Wayne, RK., Mable, BK., (2012): Spatial and temporal patterns of neutral and adaptive genetic variation in the endangered Africanwild dog (*Lycaon pictus*). Molecular Ecology 21: 1379–1393.

May, RM, Oster, GF., (1976): Bifurcations and dynamic complexity in simple ecological Models: American Naturalist 110: 573–599.

Moran, PAP., (1950): Some remarks on animal population dynamics. *Biometrics* 6: 250–258.

Miller, PS., Lacy, RC., (2005): *VORTEX: A Stochastic Simulation of the Extinction Process. Version 9.50 User's Manual*. Apple Valley, MN: Conservation Breeding Specialist Group (SSC/IUCN).

Morris, W., Doak, D., Groom, M., Kareiva, P., Fieberg, J., Gerber, L., Murphy, P., Thomson, D., (1999): A Practical Handbook for Population Viability Analysis. The Nature Conservancy

Patterson, BR., Murray, DL., (2008): Flawed population viability analysis can result in misleading population assessment: A case study for wolves in Algonquin park, Canada, Biological conversation 141: 669-680

Pasuljević, G., (1965): Ritam dnevne i sezonske aktivnosti *Ablepharus kitaibelii* (Bibron et Bory) u Jugoslaviji, Glasnik Prirodnjačkog muzeja u Beogradu B 20: 311–314.

Pasuljević, G., (1966): Prilog poznavanju ekologije *Ablepharus kitaibelli* (Bibron et Bory). Zbornik Filozofskog fakulteta u Prištini 3: 459-463.

Pasuljević, G., (1976): Characteristics of habitat and factors determining distribution and activity of the species *Ablepharus kitaibelii* (Lacertilia, Scincidae), Acta. Biol. Med. Exp. 1-2: 57-63

Pravilnik o strogo zaštičenim vrstama, Narodne novine, 144/13

Puača B., Najvirt Ž., Miličević A., (2011):Neke pedološko-florističke i gospodarske značajke šumskih sastojina na lokalitetu Otmanov vis (Slavonija)

Rai, UK., (2003): Minimum Sizes for Viable Population and Conservation Biology. Our Nature 1:3-9

Reed, DH., O'Grady, JJ., Brook, BW., Ballou JD., Richard Frankham, R., (2002): Estimates of minimum viable population sizes for vertebrates and factors influencing those estimates. Biological Conservation 113: 23–34

Ricker, WE., (1975): Computation and interpretation of biological statistics of fish populations. Ottawa: Fisheries Research Board of Canada, bulletin 191.

Silva, M., Downing, JA., (1994): Allometric scaling of minimal mammal densities. Conservation Biology 8: 732–743.

Shaffer, ML., (1981): Minimum population sizes for species conservation. BioScience 31, 131–134.

Shaffer, ML., Samson, FR., (1985): Population size and extinction: A note on determining critical population sizes. American Naturalist, 125: 144-152.

Stewart-Oaten, A., Bence, JR., (2001): Temporal and spatial variation in enviromental impact assessment. Ecological monographs 71(2): 305-339.

Szövényi, G., Jelić, D., (2011): Distribution and conservation status of snake eyed skink (*Ablepharus kitaibelii* Bibron & Bory, 1833) in Croatia. North-western Journal of Zoology 7: 20-25.

Tomović, Lj., Ljubisavljević, K., Ajtić, R., Aleksić, I., Crnobrnja-Isailović, J., (2001): New records of the Snake-eyed Skink *Ablepharus kitaibelii* in Serbia. Biota 2: 115-117.

Topić, J., Vuković, N., (2010): Papuk. U Nikolić, T., Topić, J., Vuković, N. (ur.): Botanički važna područja Hrvatske. PMF, Školska knjiga, Zagreb, 324-330 str.

White, GC., (2000): Population Viability Analysis: Data Requirements and Essential Analyses. Research Techniques in Animal Ecology: Controversies and Consequences. Chapter 9: 288-331 pp.

Zakon o potvrđivanju konvencije o zaštiti europskih divljih vrsta i prirodnih staništa (Bernska konvencija), Narodne novine, 66/2000

Zakon o zaštiti prirode, Narodne novine, 70/05

Zakon o izmjenama i dopunama zakona o zaštiti prirode, Narodne novine, 139/08

Zakon o izmjenama i dopunama zakona o zaštiti prirode, Narodne novine, 57/11

Zhang, Y., Zheng, G., (2007): A population viability analysis (PVA) for Cabot's Tragopan (*Tragopan caboti*) in Wuyanling, south-east China. Bird Conservation International 17:151–161.

Vitt, L., (2012): Snake eyed skink. Encyclopædia Britannica Online, http://www.britannica.com/EBchecked/topic/550324/snake-eyed-skink; pristupljeno 6.12. 2014.
White, GC., Population viability analisis. Colorado State University. Preuzeto 23.08.2014

Web izvori

Web 1: http://www.iucn.org/; pristupljeno 6.12. 2014.
Web 2: http://www.hhdhyla.hr/; pristupljeno 14.08. 2014