

## Određivanje optimalne rute u mreži turističkih atrakcija grada Pule<sup>1</sup>

### Determining the optimal route in the network of tourist attractions of the City of Pula

KATARINA KOSTELIĆ

Fakultet ekonomije i turizma „Dr. Mijo Mirković“

Sveučilište Jurja Dobrile u Puli

Preradovićeva 1/1, 52100 Pula, Hrvatska

[katarina.kostelic@unipu.hr](mailto:katarina.kostelic@unipu.hr)

LORIS CVEK

Fakultet ekonomije i turizma „Dr. Mijo Mirković“

Sveučilište Jurja Dobrile u Puli

Preradovićeva 1/1, 52100 Pula, Hrvatska

MARJAN DRAŽENOVIC

Fakultet ekonomije i turizma „Dr. Mijo Mirković“

Sveučilište Jurja Dobrile u Puli

Preradovićeva 1/1, 52100 Pula, Hrvatska

LUKA DREZGA

Fakultet ekonomije i turizma „Dr. Mijo Mirković“

Sveučilište Jurja Dobrile u Puli

Preradovićeva 1/1, 52100 Pula, Hrvatska

AXEL GRBAC

Fakultet ekonomije i turizma „Dr. Mijo Mirković“

Sveučilište Jurja Dobrile u Puli

Preradovićeva 1/1, 52100 Pula, Hrvatska

MATEO PAJKOVIC

Fakultet ekonomije i turizma „Dr. Mijo Mirković“

Sveučilište Jurja Dobrile u Puli

Preradovićeva 1/1, 52100 Pula, Hrvatska

Prethodno priopćenje / *Preliminary communication*

UDK / UDC: 338.48(497.5 Pula)

Primljeno / Received: 15. svibnja 2021. / May 15<sup>th</sup>, 2021.

Prihvaćeno za objavu / Accepted for publishing: 21. lipnja 2021. / June 21<sup>st</sup>, 2021.

DOI: 10.15291/oec.3375

<sup>1</sup> Rad je izrađen u okviru znanstvenog projekta "Analiza društvenih mreža u hrvatskom turizmu" pri Fakultetu ekonomije i turizma "Dr. Mijo Mirković", Sveučilište Jurja Dobrile u Puli. Mišljenja, nalazi i zaključci ili preporuke navedene u ovom radu odnose se na autore i ne odražavaju nužno stajališta Fakulteta ekonomije i turizma "Dr. Mijo Mirković" Pula.

**Sažetak:** U radu se razmatra određivanje optimalne rute po turističkim atrakcijama. Na primjeru odabranih deset atrakcija u gradu Puli, dokazuje se da je problem optimalne rute rješiv modeliranjem po uzoru na model putujućega trgovackog predstavnika (TSP) te primjenom evolucijske metode. Postavljeni problem odnosi se na određivanje pješačke rute i modeliran je iz perspektiva minimizacije udaljenosti i minimizacije vremena potrebnog za obilazak. Prikaz rješavanja korištenjem MS Excela upućuje na mogućnost jednostavne i intuitivne pripreme podataka za analizu te relativno brzog utvrđivanja rješenja. Rezultati upućuju na mogućnosti upotrebe pri organizaciji obilaska u turističkoj destinaciji, prednosti i nedostatke primijenjene metode, ali i prednosti upotrebe kvantitativnih metoda u upravljanju turističkim atrakcijama. Uočena fleksibilnost primjene rezultata otvara mogućnosti daljnog obogaćivanja modela, ali i daljnji razvoj u obliku integracije u sustav potpore u upravljanju destinacijom kvantitativnim metodama, uz doprinos održivosti turizma destinacije.

**Ključne riječi:** optimalna ruta, kvantitativne metode, mrežni modeli, TSP, evolucijska metoda, Solver, turističke atrakcije, upravljanje turističkom destinacijom

**Abstract:** This paper evaluates the optimal route of tourist attractions in the City of Pula. By modelling the route over ten chosen tourist attractions in Pula and through application of evolutionary method as travelling salesman problem (TSP), it was proven that such approach can be used for determining optimal routes of tourist attractions. The problem was set as a walking route and modelled from the perspectives of tour distance minimization and tour time minimization. Model representation and solving using MS Excel points out to the possibility of simple and intuitive data preparation and analysis, as well as relatively quick solution output. The results indicate their possible use in tour organization within touristic destination, the pros and cons of the used method, but also point out to the advantages of using quantitative methods in tourist attraction management. The observed flexibility of the solution application revealed possibilities for further model development, as well as possible integration in the support system based on the quantitative methods for managing destinations with the aim of tourism destination sustainability.

**Key words:** optimal route, quantitative methods, network models, TSP, evolutionary method, Solver, tourism attractions, tourism destination management

## 1 Uvod

Problem određivanja optimalne rute dugo je prisutan u ekonomiji. Pritom se najčešće pojavljuje u operacijskim istraživanjima, osobito u logistici i distribuciji, a formaliziran je u obliku problema trgovackog putnika (engl. *Traveling Salesman Problem* – TSP) te pripada mrežnim modelima. Formalizacija problema trgovackog putnika odnosi se na tretiranje lokacija kao čvorova povezanih bridovima ili lukovima. Bridovima ili lukovima pripisane su težine koje mogu predstavljati udaljenost ili vrijeme. Cilj tako postavljenog modela je utvrđivanje puta obilaska danih lokacija minimizirajući potrebnu udaljenost ili vrijeme prolaska, pri čemu je pojedini čvor te pojedini brid ili luk dopušteno iskoristiti samo jedanput. Problemu se može pristupiti i iz perspektive maksimizacije profita trgovackog putnika.

Problem trgovackog putnika može se primijeniti i na probleme optimalnih ruta u drugim područjima, ako zadovoljavaju pretpostavke modela. U ovom će se radu preispitati mogućnost primjene TSP-a za određivanje optimalne rute turističkih atrakcija. Za potrebe prikaza modela odabранo je deset atrakcija

u gradu Puli. Turističke atrakcije predstavljaju turističke resurse koji sadrže privlačna obilježja i dostupni su za razgledavanje turistima, podižući pritom cjelokupnu atraktivnost turističke destinacije (Floričić i Tuličić, 2019). Unaprijed kreirane turističke rute olakšavaju turistima odabir te štede vrijeme potrebno za prikupljanje relevantnih podataka pri odabiru (Qian i Zhong, 2019).

Jedan od prvih heurističkih algoritama za utvrđivanje ruta primjenjuje *greedy* metodu uz višestruke obilaske i ograničeno trajanje (Butt i Cavalier, 1994). Napredak u modelima optimalne rute predstavlja utvrđivanje jedinstvenog rješenja, promatraljući TSP kao kombinatorijski problem optimizacije (Bérubé i dr., 2009). Vansteenwegen et al. (2009) postavljaju problem optimalne rute u okvir cjelobrojnog programiranja, pritom olakšavajući utvrđivanje rješenja. Do pojave softverskih rješenja, TSP je smatran jednim od zahtjevnijih kombinatorijskih problema optimizacije (Patterson i Harmel, 2003). Pri rješavanju TSP-a te određivanju ruta pomoću mrežnih modela, u novije vrijeme često se koriste heuristički i genetički algoritmi (Vasilev, 2016).

Kritika klasičnim modelima odnosi se na postavljanje cilja prema maksimizaciji prihoda ili minimizaciji troška/vremena, čime ne ostavljaju prostor za individualizaciju ruta na temelju osobnih preferencija putnika. Daljnji razvoj modela, osobito u području turizma, seže do kombinacija s neuralnim mrežama, geolociranjem, računalnom vizijom i big data (na primjer, Malik i Kim, 2019; Mor et al., 2021; Qian i Zhong, 2019). Pritom se najčešće koriste podaci prikupljeni putem objava na društvenim mrežama, uključujući komentare, ali i ekstrakciju koordinata iz objavljenih fotografija te analizu kuta fotografiranja atrakcija. Takvim se pristupom neizbjegno dotiče pitanje prava privatnosti, ali i generalizacije zaključaka zbog pregleda podataka samo onih korisnika koji koriste odabrane društvene mreže. Treba imati na umu da je takav smjer razvoja modela ponukan personalizacijom ruta, individualnim pristupom te ponudom zadovoljavajućih ruta iz perspektive korisnika. U turizmu se pritom često uzimaju u obzir preferencije turista, njihovi stavovi, sklonost riziku, ali i prometni kapaciteti (Prasetyowati et al., 2018; Zhou et al., 2019). Iako postoje brojni modeli, s različitim karakteristikama, vezanim postupcima i potrebnim podacima, zajedničku bazu većine modela predstavlja formulacija problema ili dijela problema u obliku TSP-a. Nadalje, često se koriste i sustavi preporuka temeljeni na recenzijama i preferencijama radi povećanja zadovoljstva turista (Yuan i Uehara, 2019; Wu et al., 2017).

Ipak, zbog rasta turizma i njegova aspekta masovnosti uočene su negativne posljedice u visoko atraktivnim destinacijama, uz prateće jačanje svijesti o jedinstvenosti prirodnih i ljudskih resursa, usmjeravajući razvoj turizma k održivom modelu (Križman Pavlović, 2019). U skladu s načelom održivosti, rute je potrebno planirati uključujući ograničenja koja smanjuju negativne učinke. Odabir ruta na temelju ograničenog broja turista po atrakcijama koristeći genetički algoritam i iterativnu lokalnu pretragu, stavljući problem optimalne rute u okvir TSP-a, sugeriraju Perera et al. (2018), s ciljem ekološke održivosti turističkih destinacija.

Pandemija i posljedični pad broja turističkih dolazaka preusmjerili su fokus na održivost turističke industrije. To je pitanje izrazito važno za države poput Hrvatske, u kojoj prihodi od turizma čine značajan udio u BDP-u, a zbog pandemije i osjetljivosti sektora na mjere fizičkog distanciranja za 2020. godinu mogli bi iznositi manje od polovice u odnosu na prethodnu godinu (HNB, 2020). Bašić i Skorić (2020) smatraju da jedno od mogućih rješenja leži u unaprjeđenju upravljanja turističkom destinacijom. Osim što optimalne turističke rute omogućuju bolje iskorištanje vremena turističkih vodiča i povećavaju zadovoljstvo turista, u trenutačnoj pandemijskoj situaciji mogu pridonijeti takvoj organizaciji obilaska kojom bi se umanjila ili potpuno uklonila mogućnost susretanja različitih turističkih grupa te posljedično umanjila mogućnost prijenosa COVID-19 među različitim grupama turista. Sprječavanje uspostavljanja interakcije važno je radi uklanjanja učinka premošćivanja (engl. *bridging effect*) prisutnog u turistički atraktivnim destinacijama, koje u pandemiskim uvjetima mogu

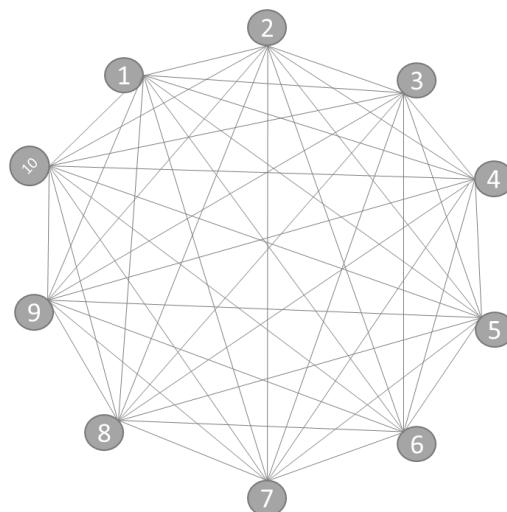
pospješiti širenje zaraze uslijed mogućnosti za interakciju turista iz inače nepovezanih zemalja (Kostelić i Turk, 2021). Sigurnost je i prije pandemije bila jedan od važnijih čimbenika pri odabiru turističke destinacije (Reisinger i Mavondo, 2005; Cui et al., 2016), a pažljiva organizacija može pomoći pri kreiranju sigurnijih uvjeta pri posjetu i time pogodovati učestalijem odabiru turističke destinacije. Iako organizirani pristup razgledavanju atrakcija kao segment upravljanja destinacijom nije jedini čimbenik, ne smije se zanemariti njegova uloga u potencijalnoj održivosti turizma u pandemijskim uvjetima.

Pri donošenju odluka, pa tako i rješavanju optimizacijskih problema, vrijeme i lakoća dolaženja do rezultata među ključnim su čimbenicima u praktičnoj upotrebi modela. Upotreba softvera postaje neizbjegljiva u poslovanju (Alt et al., 2020), pri čemu brojne organizacije koriste prilagođena softverska rješenja, ali još uvijek velik udio korisnika koristi jeftinija, univerzalna (neprilagođena) rješenja (Kordov i Eminov, 2018). Jedno od univerzalnih rješenja su proračunske tablice. U prilog takvom odabiru ide činjenica da proračunske tablice posjeduju integrirane alate operacijskih istraživanja, koji se upotrebljavaju u poslovanju, ali i obrazovanju u području poslovne ekonomije od devedesetih godina prošloga stoljeća (Baker i Camm, 2005). Prema Microsoftovom godišnjem izvješću iz 2016. godine, MS Office koristilo je više od 1,2 milijarde korisnika, a u izvješću iz 2019. godine navedeno je kako upotreba samo MS Office 365 paketa premašuje 180 milijuna korisnika. Excel, kao dio MS Office paketa odabran je zbog široke dostupnosti i upotrebe u poslovanju i obrazovanju. Osim toga, MS Office omogućuje i zahtjevnu analizu ekonomskih podataka kao što pokazuje primjer Yarmolenko et al. (2019), a moguće ga je koristiti i pri rješavanju problema optimalne rute (Baker i Camm, 2005; Jiang, 2010; Vasilev, 2015). Pretpostavlja se da je, zbog dostupnosti i česte upotrebe, veći udio korisnika upoznat s korištenjem Excela te će stoga biti spremniji iskušati već poznati alat pri kreiranju novih modela. Radi popularizacije upotrebe modela pri utvrđivanju optimalne rute u praksi te pružanja primjera s mogućnošću replikacije rezultata, ovdje se iscrpno prikazuje upotreba MS Excel alata i dodatka Rješavatelj pri utvrđivanju optimalne rute.

Dakle, svrha ovoga rada je trojaka: preispitati mogućnost upotrebe TSP-a pri određivanju rute po turističkim atrakcijama, ponuditi primjer rješavanja primjenom evolucijske metode u Excelu te kreirati podlogu za budući razvoj odlučivanja i organizacije kvantitativnim metodama u upravljanju turističkim atrakcijama. U nastavku rada opisan je problem određivanja rute na temelju kojeg je kreiran prikaz rješavanja problema. Rezultati nude moguća rješenja uz osvrt na prednosti i nedostatke primijenjene metode, dok zaključak upućuje na mogućnosti primjene, ograničenja te daljnji razvoj istraživanja.

## 2 Formulacija problema

Teorijski mrežni model kreiran na temelju deset međusobno povezanih lokacija prikazan je Slikom 1., a definiran je kako slijedi. Graf atrakcija A definiran je skupom čvorova  $V$  i skupom bridova  $E$ ,  $A = (V, E)$ . Svaki brid  $e \in E$  povezuje dva čvora. Ako brid  $e$  povezuje čvorove  $v_k$  i  $v_{k-1}$ , a ti su čvorovi različiti,  $v_k = u$ ,  $v_{k-1} = z$  i  $u, z \in V$ , tada vrijedi  $e = \langle u, z \rangle$ , pri čemu su  $u, z \in V$  krajnje točke (engl. *endpoints*) brida  $e$ . U pitanju je neusmjereni graf, pri čemu se ne čini razlika između  $\langle u, z \rangle$  i  $\langle z, u \rangle$ , te postoji simetrija veze. Ako su dva čvora  $u, z \in V$  povezana bridom  $e$ , tada su  $u, z \in V$  susjedni čvorovi.  $V(A)$  predstavlja skup čvorova grafa  $A$ , a  $E(A)$  predstavlja skup bridova grafa  $A$ . Graf A opisan Slikom 1. je konačan graf, jer su  $V(A)$  i  $E(A)$  konačni skupovi čvorova i bridova. Osim toga, graf A je potpun, jer su svaka dva čvora povezana jednim bridom.



**Slika 1.** Prikaz teorijskoga mrežnog modela kreiranog na temelju deset međupovezanih čvorova

Izvor: autori (2021)

Cilj modela je utvrditi optimalnu rutu po deset čvorova, to jest ciklus mreže. Ciklus je šetnja koja obuhvaća sekvencu bridova  $e_1, e_2, \dots, e_{n-1}, e_n$ , pri čemu je  $e_n \in E$  za svaki  $n \in \{1, \dots, N\}$  na takav način da je svaki čvor u sekvenci  $v_2, \dots, v_k$  različit, dok se početni čvor  $v_1$  pojavljuje i kao odredišni čvor  $v_{k+1}$ , to jest dva puta (van Steen, 2010). Duljina ciklusa je zbroj bridova na putu. Pod pojmom rute podrazumijeva se različit raspored čvorova u ciklusu te utvrđivanje jednog (jedinstvenog) ciklusa u ovom slučaju rezultira s dvadeset mogućih ruta, na temelju promjene početnog čvora te smjera kretanja. Teorijski model prikazan Slikom 1. predstavlja netežinski graf i potrebno ga je obogatiti težinama, to jest svakom bridu pripisati vrijednost vezanu uz postavljeni cilj.

Za potrebe određivanja pješačke rute po turističkim atrakcijama, odabранo je deset turističkih atrakcija Pule koristeći mrežne izvore na temu: službeni izvori (TZ Istra, TZ Pula), društvene mreže (TripAdvisor) te stranica specijaliziranih za putovanja (Putovnica.net, Topdestinacije.hr). Uvezši u obzir raznovrsnost atrakcija, odabранo je deset lokacija u gradu Puli: Aquarium, Arena, Arheološki muzej, Augustov Hram, Dvojna vrata, Herkulova vrata, Titov park, Tvrđava Kaštel, Zerostrasse i Zlatna Vrata (Slavoluk Sergijevaca).

Za rješavanje problema optimalne rute temeljene na udaljenostima i vremenu, potrebno je bridovima pripisati težine u jednakim mjernim jedinicama. Jiang (2010) sugerira utvrđivanje težina bridova na temelju udaljenosti ekstrakcijom zračnih udaljenosti na temelju koordinata lokacija, što može rezultirati odstupanjem od realnih udaljenosti koje je potrebno prijeći. U ovom slučaju, za problem utvrđivanja optimalne pješačke rute temeljene na udaljenostima, pripisane težine izražene su u metrima udaljenosti lokacija na temelju stvarnih udaljenosti koje osobe moraju pješaćenjem prijeći između lokacija. Koristeći jednak pristup, pri utvrđivanju optimalne pješačke rute temeljene na vremenu, težine na bridovima predstavljat će procijenjeno vrijeme hoda u minutama.

Navedeni su podaci prikupljeni i to je prikazano u Tablici 1. i Tablici 2. Tako obogaćen graf predstavlja težinski graf, pri čemu je svakom bridu  $e$  pripisana nenegativna vrijednost  $w(e)$ . Definiranje grafa kao težinskog omogućuje rješavanje problema i utvrđivanje najmanje udaljenosti ili vremena, pri čemu je svaki brid i svaki čvor, osim početnog, dopušteno iskoristiti samo jedanput.

**Tablica 1.** Udaljenosti između atrakcija izražene u metrima pješačenja

	Arena a (1)	Augus tov Hram (2)	Arheo loški muzej (3)	Zlatna Vrata (4)	Aqua rium (5)	Tvrđava Kaštel (6)	Herkulo va vrata (7)	Dvojn a vrata (8)	Titov park/ Riva (9)	Zeros trasse (10)
Arena (1)		714,59	374,5 7	576,5 2	4360	411,93	384,87	350	250	350
Augusto v Hram (2)	714, 59		505,7 5	463,2 3	3940	292,74	471,03	600	600	600
Arheolo ški Muzej (3)	374, 57	505,75		243,8 4	4060	149,8	34	53	230	44
Zlatna Vrata (4)	576, 52	463,23	243,8 4		3820	230,77	210,44	400	600	400
Aquariu m (5)	4360	3940	4060	3820		4010	4060	4600	4800	4600
Kaštel (6)	411, 93	292,74	149,8	230,7 7	4010		650	600	600	600
Herkulo va vrata (7)	384, 87	471,03	34	210,4 4	4060	650		87	260	78
Dvojna vrata (8)	350	600	53	400	4060	600	87		180	9
Titov park/ Riva (9)	250	600	230	600	4800	600	260	180		190
Zerostra sse (10)	350	600	44	400	4600	600	78	9	190	

Izvor: podaci prikupljeni koristeći Google maps.

Odabirom neusmjerenog grafa, predviđena je mogućnost kretanja između čvorova u bilo kojem smjeru (na primjer, od čvora 1 prema čvoru 2, ali i obrnuto). Graf sadrži  $K = 10$  čvorova i svaki čvor u mreži ima stupanj 9 (engl. *degree*) te postoji  $K! = 10! = 3\,628\,800$  različitih permutacija čvorova na putu i jednako toliko mogućih ruta.

Ako bi se problem rješavao ručno, bilo bi potrebno ispisati svaku rutu te izračunati udaljenost i/ili potrebno vrijeme za prelazak te rute, a nakon toga rezultate usporediti i utvrditi optimalnu vrijednost. S obzirom na količinu mogućnosti, može se uočiti da je u pitanju ekstenzivan posao na koji će se malo tko odvažiti. Štoviše, čak i adaptacija formalnih matematičkih modela u praktičnim slučajevima može biti zahtjevna (Vasilev, 2016).

**Tablica 2.** Udaljenosti između atrakcija izražene u minutama hoda

	Arena (1)	Augustov Hram (2)	Arheološki muzej (3)	Zlatna Vrata (4)	Aquarijum (5)	Tvrđava Kaštel (6)	Herkulova vrata (7)	Dvojna vrata (8)	Titov park/ Riva (9)	Zerostrasse (10)
Arena (1)		8	4	7	61	10	5	4	3	4
Augustov Hram (2)	8		7	5	58	8	9	8	7	8
Arheološki Muzej (3)	4	7		4	58	8	1	1	3	1
Zlatna Vrata (4)	7	5	4		55	10	4	5	7	5
Aquarium (5)	61	58	58	55		62	56	58	59	57
Kaštel (6)	10	8	8	10	62		8	7	7	7
Herkulova vrata (7)	5	9	1	4	56	8		1	3	1
Dvojna vrata (8)	4	8	1	5	58	7	1		2	1
Titov park/ Riva (9)	3	7	3	7	59	7	3	2		3
Zerostrasse (10)	4	8	1	5	57	7	1	1	3	

Izvor: podaci prikupljeni koristeći Google maps.

### 3 Rješavanje problema

Za rješavanje problema uporabom proračunskih tablica, potrebno je upoznati se s karakteristikama metoda i funkcija koje se može koristiti. Baker i Camm (2005) uspoređuju „tradicionalno“ cjelobrojno programiranje u proračunskim tablicama s heurističkom, evolucijskom metodom bez ograničenja. Koristeći cjelobrojno programiranje, postiže se sljedeća struktura problema:

Funkcija cilja:  $\text{Min } z = \sum_{ij} e_{ij} x_{ij}$

Ograničenja:

$\sum_i x_{ij} = 1$ , za sve atrakcije j

$\sum_i x_{ij} = 1$ , za sve atrakcije

$u_i - u_j + nx_{ij} \leq n - 1$ , za sve parove (i, j) ne uključujući lokaciju 1,

pri čemu su:

$x_{ij}$  varijable odluka i predstavljaju odabir brida koji povezuje lokaciju  $i$  s lokacijom  $j$ , te poprimaju vrijednost 1 ako je brid odabran, odnosno 0 ako brid nije odabran

$e_{ij}$  su težine pripisane bridovima i predstavljaju udaljenost ili vrijeme između dviju lokacija

$u_i, u_j$  predstavljaju relativni redoslijed pozicija lokacija (uz ograničenje cjelobrojnosti).

Primjenom evolucijske metode, problem je zadan kao:

Funkcija cilja:  $\text{Min } z = \sum_{ij} e_{p(j)i}$

Ograničenje:  $j = \text{AllDifferent}$ ,

pri čemu je rješenje sekvenca lokacija uz minimalni prijeđen put (prilagođeno iz Baker i Camm, 2005). Uz prepostavku da je cjelobrojnim programiranjem problem rješiv u razumnom roku, rješenje će predstavljati optimum, dok se primjenom evolucijske metode neće uvijek kao rješenje prikazati globalni optimum. U slučaju rješavanja TSP-a cjelobrojnim programiranjem, Baker i Camm (2005) su generirali rješenja u roku od 5 minuta uz postizanje optimuma, dok je u slučaju primjene evolucijske metode rezultat generiran u roku od 1 minute (zadano maksimalno vrijeme bez poboljšanja) i 83 % rješenja predstavljala su globalni optimum. Poteškoće nastupaju u traženju rješenja problema u velikim setovima podataka, to jest uz velik broj varijabli, pri čemu uspješnost utvrđivanja optimuma uz jednako zadano vrijeme rješavanja evolucijskom metodom opada na 16 %. Autori su proveli i naturalizirani eksperiment sa studentima, pri čemu su studenti koji su rješavali TSP u 86 % slučajeva odabrali cjelobrojno programiranje te u 93 % slučajeva utvrdili optimalno rješenje, dok je preostalih 14 % odabralo evolucijsku metodu uz postizanje optimuma u 60 % slučajeva. Prednost cjelobrojnog programiranja odnosi se na veću uspješnost utvrđivanja optimuma, dok je prednost evolucijske metode brže utvrđivanje rješenja. Evolucijska metoda prikladna je i za primjenu u situacijama u kojima postoji više različitih rješenja koja vode do globalnog optimuma. Osim toga, bilježeno je vrijeme vezano samo za generiranje rješenja, dok vrijeme potrebno za kreiranje modela nije uzeto u obzir. Ako bi se razmatralo i vrijeme potrebno za kreiranje modela, vremenska razlika u rješavanju primjenom tih dviju metoda dodatno bi se povećala.

Također, treba imati na umu da je dobivanje rješenja primjenom evolucijske metode uvjetovano zadanim vremenom rješavanja. Evolucijska je metoda heuristička te zadani problem dijeli na potprobleme (u ovom slučaju, moguće rute), pri čemu se uspoređuju vrijednosti funkcija cilja i zadržava se povoljnija vrijednost s kojom se uspoređuje dobivena vrijednost rješavanjem sljedećeg potproblema. Postupak je iterativni i prestaje istekom zadanog vremena. Na taj je način broj analiziranih potproblema uvjetovan ograničenjem vremena dostupnog za izračun. Drugim riječima, povećanjem vremena za izračun povećava se i preciznost metode, što je osobito značajno u situacijama s velikim brojem mogućih iteracija. Iako povećanje vremena može biti negativno percipirano, u ovom su slučaju u pitanju sekunde i minute. Vrijeme potrebno za dolaženje do rješenja čini evolucijsku metodu osobito privlačnom s obzirom na to da dinamika poslovnih promjena stvara sve veći vremenski pritisak pri donošenju odluka menadžera (Vasilev, 2016). U operacijskom menadžmentu, probleme nalik na TSP potrebno je iznova rješavati samo zbog promjena okolnosti i čimbenika koji utječu na utvrđeno rješenje, ali mogućnost jednostavnog postavljanja problema i kratkog vremena potrebnog za utvrđivanje ruta stvara preduvjete za brzu prilagodbu promjenama.

Pri rješavanju TSP-a proračunskim tablicama može se koristiti „Alldifferent“ ograničenje uz kombinaciju s INDEX funkcijom (Baker i Camm, 2005), „Alldifferent“ ograničenje uz kombinaciju s VLOOKUP i TRANSPOSE funkcijama (Jiang, 2010) ili „Alldifferent“ ograničenje uz kombinaciju s VLOOKUP funkcijom (Vasilev, 2016) uz primjenu evolucijske metode. INDEKS funkcija omogućuje utvrđivanje vrijednosti u popisu ili tablici podataka na temelju lokacije podatka u tablici ili popisu, a u kontekstu rješavanja TSP-a koristi se za ekstrakciju udaljenosti (ili vremena) između dviju lokacija. Na sličan način funkcioniра i VLOOKUP, pa je izbor između tih dviju funkcija pitanje preferencije prikaza rezultata.

	A	B	C	D	E	F	G	H	I	J	K	L	M
1			1	2	3	4	5	6	7	8	9	10	
2			Arena	Augustov Hram	Arh. Muzej	Zlatna Vrata	Aquarium	Tvrđava Kaštel	Herkulova vrata	Dvojna vrata	Titov park	Zerostrasse	
3	1	Arena		714,59	374,57	576,52	4360,00	411,93	384,87	350,00	250,00	350,00	
4	2	Augustov Hram	714,59		505,75	463,23	3940,00	292,74	471,03	600,00	600,00	600,00	
5	3	Arh. Muzej	374,57	505,75		243,84	4060,00	149,80	34,00	53,00	230,00	44,00	
6	4	Zlatna Vrata	576,52	463,23	243,84		3820,00	230,77	210,44	400,00	600,00	400,00	
7	5	Aquarium	4360,00	3940,00	4060,00	3820,00		4010,00	4060,00	4600,00	4800,00	4600,00	
8	6	Kaštel	411,93	292,74	149,80	230,77	4010,00		650,00	600,00	600,00	600,00	
9	7	Herkulova vrata	384,87	471,03	34,00	210,44	4060,00	650,00		87,00	260,00	78,00	
10	8	Dvojna vrata	350,00	600,00	53,00	400,00	4060,00	600,00	87,00		180,00	9,00	
11	9	Titov park	250,00	600,00	230,00	600,00	4800,00	600,00	260,00	180,00		190,00	
12	10	Zerostrasse	350,00	600,00	44,00	400,00	4600,00	600,00	78,00	9,00		190,00	
13													
14		Atrakcije:	=INDEX(\$B\$3:\$B\$12;C15;1)	=INDEX(\$B\$3:\$B\$12;D15;1)	=INDEX(\$B\$3:\$B\$12;E15;1)	=INDEX(\$B\$3:\$B\$12;F15;1)	=INDEX(\$B\$3:\$B\$12;G15;1)	=INDEX(\$B\$3:\$B\$12;H15;1)	=INDEX(\$B\$3:\$B\$12;I15;1)	=INDEX(\$B\$3:\$B\$12;K15;1)	=INDEX(\$B\$3:\$B\$12;L15;1)	=INDEX(\$B\$3:\$B\$12;M15;1)	=INDEX(\$B\$3:\$B\$12;N15;1)
15		Redoslijed:											=C15
16		Udaljenost do sljedeće atrakcije:	=@INDEX(\$C\$3:\$L\$12;C15;D15)	=@INDEX(\$C\$3:\$L\$12;D15;E15)	=@INDEX(\$C\$3:\$L\$12;E15)	=@INDEX(\$C\$3:\$L\$12;F15;15)	=@INDEX(\$C\$3:\$L\$12;G15;15)	=@INDEX(\$C\$3:\$L\$12;H15;15)	=@INDEX(\$C\$3:\$L\$12;I15;15)	=@INDEX(\$C\$3:\$L\$12;K15;5)	=@INDEX(\$C\$3:\$L\$12;L15;15)	=@INDEX(\$C\$3:\$L\$12;M15)	
17		Ukupna duljina puta:	=SUM(C16:L16)										
18													

Slika 2. Definiranje odnosa u modelu najkraće rute po atrakcijama

Izvor: autori (2021)

Pripremne radnje pri utvrđivanju najmanje udaljenosti u metrima primjenom evolucijske metode i INDEKS funkcije prikazane su Slikom 2. Varijable odluke nalaze se u retku *Redoslijed* i odnose se na ćelije C15:L15.

Uz *Redoslijed* vezan je popis atrakcija (*Atrakcije*: C14:M14), koji koristeći broj u redoslijedu varijabli odluka ekstrahira naziv atrakcije. Svrha toga popisa je preglednost pri iščitavanju rezultata i nije nužan za funkcioniranje modela.

Uz varijable odluke vezane su i vrijednosti u retku *Udaljenost do sljedeće atrakcije* (C16:L16), u kojem se pomoću INDEX funkcije ćeliji pridružuje vrijednost udaljenosti između dviju lokacija zapisane u gornjoj tablici u Slici 1. (redni broj trenutačne ili polazišne lokacije koristi se za pretragu po redcima, a redni broj sljedeće ili odredišne lokacije koristi se za pretragu po stupcima). Funkcija cilja je minimizacija ukupne duljine puta, a predstavlja sumu udaljenosti između atrakcija (C17).

S obzirom na to da je problem definiran kao ciklus, nužno je dodati ponavljanje prvog čvora (M15), ali se ta ćelija ne uključuje u varijable odluke. Postojanje tako definiranoga odredišnog čvora važno je i za ekstrakciju udaljenosti između prethodnog i odredišnog čvora (L16).

	A	B	C	D	E	F	G	H	I	J	K	L	M
1			1	2	3	4	5	6	7	8	9	10	
2			Arena	Augustov Hram	Arh. Muzej	Zlatna Vrata	Aquarium	Tvrđava Kaštel	Herkulova vrata	Dvojna vrata	Titov park	Zerostrasse	
3	1	Arena		714,59	374,57	576,52	4360,00	411,93	384,87	350,00	250,00	350,00	
4	2	Augustov Hram	714,59		505,75	463,23	3940,00	292,74	471,03	600,00	600,00	600,00	
5	3	Arh. Muzej	374,57	505,75		243,84	4060,00	149,80	34,00	53,00	230,00	44,00	
6	4	Zlatna Vrata	576,52	463,23	243,84		3820,00	230,77	210,44	400,00	600,00	400,00	
7	5	Aquarium	4360,00	3940,00	4060,00	3820,00		4010,00	4060,00	4600,00	4800,00	4600,00	
8	6	Kaštel	411,93	292,74	149,80	230,77	4010,00		650,00	600,00	600,00	600,00	
9	7	Herkulova vrata	384,87	471,03	34,00	210,44	4060,00	650,00		87,00	260,00	78,00	
10	8	Dvojna vrata	350,00	600,00	53,00	400,00	4060,00	600,00	87,00		180,00	9,00	
11	9	Titov park	250,00	600,00	230,00	600,00	4800,00	600,00	260,00	180,00		190,00	
12	10	Zerostrasse	350,00	600,00	44,00	400,00	4600,00	600,00	78,00	9,00		190,00	
13													
14		Atrakcije:											
15		Redoslijed:	1	2	3	4	5	6	7	8	9	10	1
16		Udaljenost do sljedeće atrakcije:	714,59	505,75	243,84	3820	4010	650	87	180	190	350	
17		Ukupna duljina puta:	10751,18										
18													

Slika 3. Model udaljenosti pješačenja s početnim redoslijedom atrakcija na ruti

Izvor: autori (2021)

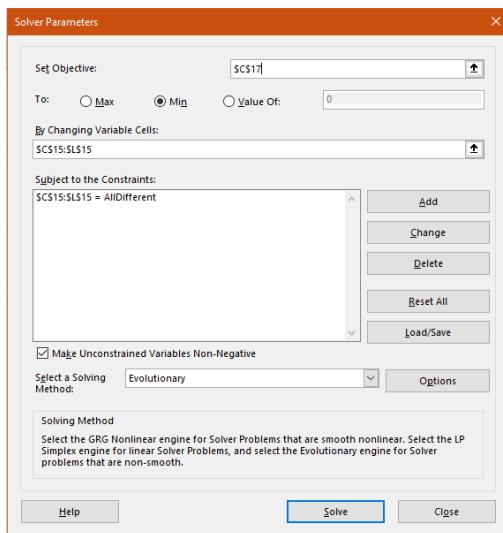
Slikom 3. prikazana je početna sekvenca atrakcija (1, 2, ..., 9, 10) koja rezultira duljinom puta od 10751,18 metara.

	A	B	C	D	E	F	G	H	I	J	K	L	M
1			1	2	3	4	5	6	7	8	9	10	
2			Arena	Augustov Hram	Arh. Muzej	Zlatna Vrata	Aquarium	Kaštel	Herkulova vrata	Dvojna vrata	Titov park	Zerostrasse	
3	1	Arena		8	4	7	61	10	5	4	3	4	
4	2	Augustov Hram	8		7	5	58	8	9	8	7	8	
5	3	Arh. Muzej	4	7		4	58	8	1	1	3	1	
6	4	Zlatna Vrata	7	5	4		55	10	4	5	7	5	
7	5	Aquarium	61	58	58	55		62	56	58	59	57	
8	6	Kaštel	10	8	8	10	62		8	7	7	7	
9	7	Herkulova vrata	5	9	1	4	56	8		1	3	1	
10	8	Dvojna vrata	4	8	1	5	58	7	1		2	1	
11	9	Titov park	3	7	3	7	59	7	3	2		3	
12	10	Zerostrasse	4	8	1	5	57	7	1	1	3		
13													
14		Atrakcije:											
15		Redoslijed:	1	2	3	4	5	6	7	8	9	10	1
16		Udaljenost do sljedeće atrakcije:	8	7	4	55	62	8	1	2	3	4	
17		Ukupna duljina puta:	154										

Slika 4. Model vremena pješačenja s početnim redoslijedom atrakcija na ruti

Izvor: autori (2021)

Jednakim pristupom kreiran je model rute uz najkraće ukupno vrijeme. Prikaz početnih postavki modela dan je Slikom 4., a takvim se rasporedom atrakcija postiže vrijeme potrebno za obilazak od 154 minute.

**Slika 5.** Postavke alata za rješavanje

Izvor: autori

U sljedećem koraku koristi se Alat za rješavanje (engl. *Solver*) (Slika 5.), pri čemu je potrebno odrediti minimizaciju funkcije cilja, definirati varijable odluke te postaviti ograničenje „*dif*“, to jest „*AllDifferent*“ za varijable odluke. Ovo ograničenje omogućuje provedbu kriterija različitosti čvorova, to jest uvjeta da se svaki čvor na putu smije pojaviti samo jedanput. Odabire se evolucijska metoda. Uz odabir metoda vezane su i mogućnosti (engl. *Options*), u kojima je poželjno namjestiti limit maksimalnog rješavanja na 60 sekundi (za sve metode), a s obzirom na prepoznate karakteristike evolucijske metode, poželjno je produljiti maksimalno vrijeme bez poboljšanja i postaviti na više od 60 sekundi (u ovom slučaju, maksimalno vrijeme bez poboljšanja postavljeno je na 120 sekundi).

#### 4 Rezultati

Jedno od rješenja modela minimizacije udaljenosti pješačenja prikazano je Slikom 6. i predstavlja takvu sekvencu atrakcija koja rezultira ukupno prijeđenom pješačkom udaljenosti od 9192,11 metara.

14	Atrakcije:	Titov park	Dvojna vrata	Zerostrasse	Arh. Muzej	Herkulova vrata	Zlatna Vrata	Aquarium	Augustov Hram	Kaštel	Arena	Titov park
15	Redoslijed:	9	8	10	3	7	4	5	2	6	1	9
16	Udaljenost do sljedeće atrakcije:	180	9	44	34	210,44	3820	3940	292,74	411,93	250	
17	Ukupna duljina puta:	9192,11										

**Slika 6.** Sekvenca atrakcija koja minimizira ukupnu duljinu puta

Izvor: autori (2021)

Jedno od rješenja modela minimizacije vremena pješačenja obilaženjem atrakcija prikazano je Slikom 7. Izlaznom sekvencom atrakcija postiže se najkraće trajanje pješačenja od 141 minute.

14	Atrakcije:	Zerostrasse	Dvojna vrata	Arh. Muzej	Herkulova vrata	Aquarium	Zlatna Vrata	Augustov Hram	Kaštel	Titov park	Arena	Zerostrasse
15	Redoslijed:	10	8	3	7	5	4	2	6	9	1	10
16	Udaljenost do sljedeće atrakcije:	1	1	1	56	55	5	8	7	3	4	
17	Ukupna duljina puta:	141										

**Slika 7.** Sekvenca atrakcija koja minimizira ukupno trajanje pješačenja

Izvor: autori (2021)

Također, rješavanje je provedeno i uz uobičajeno ograničenje vremena rješavanja (engl. *default*) od 20 sekundi, što je rezultiralo suboptimalnim rješenjima od 9550,95 m udaljenosti i 144 minute hoda. Iako ta rješenja nisu optimalna, upućuju na poboljšanje u odnosu na početnu sekvencu atrakcija (Slika 3. i Slika 4.), što je u skladu s pretpostavkom primjene kvantitativnih modela kao potpore odlučivanju: očekuje se da kvantitativni modeli pruže bolje rješenje u odnosu na rješenje bez primjene kvantitativnih metoda. Ipak, uz razumijevanje pretpostavki primijenjene metode i posljedične nužnosti povećanja vremenskog ograničenja, može se postići optimum (Slika 6. i Slika 7.). U odnosu na početno zadane sekvence atrakcija, rješenje prikazano Slikom 6. umanjuje duljinu puta za 1559,07 metara, a u slučaju trajanja pješačenja rješenje prikazano Slikom 7. upućuje na poboljšanje vremena za 13 minuta hoda.

Važno je imati na umu da iako rezultati prikazani Slikom 6. i Slikom 7. prikazuju optimalne rute s obzirom na minimizaciju puta i vremena, zapravo se radi o prikazu ciklusa i jednaku je vrijednost funkcije cilja moguće postići obrnutom sekvencom atrakcija te promjenom polazišta (poštujuci ostatak redoslijeda).

S obzirom na moguću permutaciju čvorova (osobito pri minimizaciji vremena pješačenja), metoda će se primijeniti više puta. Radi utvrđivanja mogućnosti i performansi korištenog alata i metode pri izračunu, postupak je ponovljen po deset puta za svaki problem. Nakon isteka zadanog vremena rješavanja (60 sekundi) u svakom je pokušaju odabran nastavak (osim u situacijama u kojima je rješenje uz zadanu razinu konvergencije postignuto prije isteka tog roka), a postupak je dovršen po isteku 120 sekundi bez poboljšanja vrijednosti funkcije cilja. Potrebno je napomenuti da su sve sekvence dobivene uz dulje vremensko ograničenje rezultirale minimalnom udaljenošću od 9192,11 metara i minimalnim trajanjem od 141 minute. Rezultati su prikazani Tablicom 3.

Uvidom u Tablicu 3. može se uočiti da iako postoji više mogućih rješenja problema, sva rješenja neće biti zastupljena s istom vjerojatnošću. Drugim riječima, pojedina moguća rješenja pojavljivat će se češće od drugih, dok neka uopće neće biti zastupljena u ovako malom broju pokušaja.

Pri utvrđivanju minimalne udaljenosti i pripadajućih ruta, tijekom pokušaja pojavile su se rute s početnim čvorovima 5 i 6 kao međurješenja po isteku zadanog vremena rješavanja od 60 sekundi, ali te sekvene nisu zadržane kao rješenje u idućim iteracijama. Rješenje {9, 8, 10, 3, 7, 4, 5, 2, 6, 1, 9} pojavljuje se šest puta, dok se rješenje {2, 5, 4, 7, 3, 10, 8, 9, 1, 6, 2} pojavljuje četiri puta.

Može se uočiti da drugo rješenje predstavlja obrnutu sekvencu atrakcija u odnosu na prvo rješenje, uz različit početni čvor. Važno je razumjeti da dobivena rješenja predstavljaju ciklus u kojem se svaki čvor osim početnog pojavljuje samo jedanput te promjena početnog čvora krećući se po sekvenci atrakcija u ciklusu neće dovesti do promjene ukupne udaljenosti. Na temelju utvrđenog ciklusa može se ispisati dvadeset ruta i to mijenjanjem polazišnog čvora i promjenom smjera kretanja.

Dakle, rješenje treba promatrati kao skup ruta koje stvaraju podlogu za donošenje odluke, a ne kao jedinstvenu mogućnost i nužan odabir.

**Tablica 3.** Rezultati na temelju deset pokušaja

	Minimalna udaljenost: 9192,11 metara			Minimalno trajanje: 141 minuta		
Po kuš aj	Ciklus	Trajanje rješavanja (u sekundam a)	Broj analiziran ih potproble ma	Ciklus	Trajanje rješavanja (u sekundama )	Broj analiziranih potproblema
1.	9-8-10-3-7-4-5-2-6-1	211,46	70912	10-8-3-7-5-4-2-6-9-1	9,63	3262
2.	2-5-4-7-3-10-8-9-1-6	230,14	78292	1-8-10-3-7-5-4-2-6-9	13,13	3667
3.	2-5-4-7-3-10-8-9-1-6	220,08	76197	8-3-7-5-4-2-6-9-1-10	201,89	68113
4.	9-8-10-3-7-4-5-2-6-1	241,06	77620	1-9-6-2-4-5-7-10-8-3	8,281	2868
5.	9-8-10-3-7-4-5-2-6-1	214,64	72044	1-10-3-8-7-5-4-2-6-9	17,172	5970
6.	9-8-10-3-7-4-5-2-6-1	208,17	73140	2-6-9-1-10-3-8-7-5-4	20,88	5800
7.	9-8-10-3-7-4-5-2-6-1	206,31	72489	9-1-10-3-8-7-5-4-2-6	9,234	3068
8.	9-8-10-3-7-4-5-2-6-1	206,86	68571	3-1-9-6-2-4-5-7-8-10	232,84	74156
9.	2-5-4-7-3-10-8-9-1-6	224,72	70349	10-1-9-6-2-4-5-7-3-8	13,14	4407
10.	2-5-4-7-3-10-8-9-1-6	267,03	67821	9-6-2-4-5-7-8-10-3-1	17,4	5872
$\bar{x}$	/	223,047	72743,5	/	54,3597	17718,3

Izvor: autori (2021)

Iz navedenog se može uočiti da postoji i određena razina fleksibilnosti pri konačnom odabiru rute. Pritom se, na primjer, pri određivanju polazišnog čvora u obzir može uzeti blizina autobusnog stajališta, a pri određivanju smjera kretanja pripremljena naracija turističkog vodiča i/ili trenutačni broj posjetitelja po atrakcijama. Konačno odabrana ruta prema najmanjoj udaljenosti može biti, na primjer {1, 6, 2, 5, 4, 7, 3, 10, 8, 9, 1}, s Arenom kao polazištem, nakon čega slijede Tvrđava Kaštel, Augustov Hram, Aquarium, Zlatna vrata, Herkulova vrata, Arheološki muzej, Zerostrasse, Dvojna vrata, Titov park/Riva, s povratkom do Arene.

Pri utvrđivanju najkraćeg trajanja ciklusa koji obuhvaća sve čvorove, nužan je osrvt na postojanje jednakih težina pripisanih različitim bridovima, što omogućuje veći broj ruta koje će rezultirati jednakom vrijednošću funkcije cilja. Navedeno je uočljivo u varijabilnosti utvrđenih ruta na temelju deset pokušaja. Detaljnijim uvidom i usporedbom s rutom utvrđenom prvim pokušajem, može se uočiti da preostali ciklusi slijede istu (pokušaji 2, 3, 5, 6, 7) ili obrnutu (pokušaji 4, 8, 9 i 10) sekvencu s permutacijom čvorova ili bez permutacije čvorova {1, 10, 8, 3}. Udaljenosti izražene u minutama između čvorova 1 i 3, 1 i 8 te 1 i 10 su jednake i iznose 4 minute, kao i udaljenosti između čvorova 3 i 8, 3 i 10 te 8 i 10 koje iznose po 1 minutu. Pritom se u ostatku sekvence, {7, 5, 4, 2, 6, 9} ne mijenja

redoslijed osim u obrnutom smjeru. U promatranim pokušajima, čvor 9 uvijek se nalazi uz čvor 1, a čvor 7 nalazi se uz čvor 3 ili 8. Težine na bridovima između čvora 9 i čvorova 1, 3 i 10 jednake su i iznose 3 minute. Težine na bridovima između čvora 7 i čvorova 3, 8 i 10 jednake su i iznose 1 minutu. Dakle, mogućom permutacijom navedenih čvorova nastaje osamnaest ruta, pri čemu je moguć obrnut redoslijed čvorova koji rezultira s još toliko ruta, a promjenom polazišnog čvora nastaje deset puta više ruta. U ovom je slučaju još izraženija fleksibilnost pri konačnom odabiru rute, kao i mogućnost primjene dodatnih kriterija ili na primjer, organizacije mimoilaženja turističkih grupa.

Po pitanju izvedbe, pri rješavanju prvog modela prosječno je potrebno 230.05 sekundi (približno 3 minute i 50 sekundi). Prosječno je analizirano 72 743.5 potproblema (što čini približno 2 % mogućih sekvenci čvorova). Za drugi model prosječno trajanje dolaska do rješenja iznosilo je 54.36 sekundi uz prosjek od 17 718.3 analiziranih potproblema (približno 0,49 % mogućih sekvenci čvorova).

U slučaju primjene evolucijske metode pri utvrđivanju minimalnog trajanja, bilo je nužno ponoviti postupak izračuna kako bi se stekao uvid u sve mogućnosti vezane uz jednaku funkciju cilja. Jedna od prednosti metode vezana je i uz korištenje u situacijama s mogućim višestrukim rješenjima. Ipak, dobivena je rješenja nužno staviti u kontekst i vodeći računa o karakteristikama analizirane pojave kritički se osvrnuti na rezultat. U nekim situacijama, to će značiti i ponavljanje postupka, što može dovesti do smanjenja atraktivnosti metode iz perspektive potrebnog vremenskog angažmana. Dakle, uz jednostavnost upotrebe koja evolucijsku metodu čini privlačnom za primjenu, potrebno je voditi računa o *trade-offu* između potrebnog vremena i pronalaženja kako optimuma funkcije cilja te o alternativama koje vode do optimuma.

Što se grafičkog prikaza ruta tiče, mogućnosti Excela su ograničene. Ipak, grafički je prikaz ruta moguć uz korištenje podataka pripremljenih u proračunskoj tablici kao inputa pri korištenju drugih alata. Koristeći jednostavnije i široko dostupne besplatne alate, geolokacijski prikaz ruta moguć je na temelju redoslijednog popisa ruta i upotrebe MyGoogleMaps, a interaktivni prikaz može se kreirati R programskim jezikom, Leafletom (Java dodatak) i OpenStreetMapsom. Za drugu varijantu geolokacijskog prikaza, potrebno je lokacijama u zasebnim stupcima pripisati zemljopisnu širinu i dužinu (te opis atrakcije u slučaju željenog korištenja *pop-upa* na takav način). Osim toga, na raspolaganju su i specijalizirani softveri za mrežne modele (kao na primjer, GNU Gephi), koji iziskuju pripremu podataka kao tablicu bridova (engl. *edge table*) i/ili tablicu čvorova (engl. *node table*) te instalaciju Map of Countries dodatka.

## 5 Zaključak

U ovom je radu razmatrano određivanje optimalne rute po turističkim atrakcijama. Na primjeru odabranih deset atrakcija u gradu Puli, dokazano je da problem optimalne rute može biti rješiv modeliranjem po uzoru na TSP te primjenom evolucijske (heurističke) metode. Prikaz rješavanja koristeći MS Excel upućuje na mogućnost jednostavne i intuitivne pripreme podataka za analizu te relativno brzog utvrđivanja rješenja. Detaljan opis primjene metode omogućuje validaciju i replikaciju rezultata. Pri interpretaciji rješenja potrebno je razmotriti karakteristike analizirane pojave i kontekst, imajući na umu mogućnost postojanja višestrukih rješenja. Osim toga, potrebno je voditi računa o *trade-offu* između potrebnog vremena i pronalaženja kako optimuma funkcije cilja, tako i alternativa koje vode do optimuma. Ponavljanje postupka može dovesti do smanjenja atraktivnosti metode iz perspektive potrebnoga vremenskog angažmana, ali upućuje i na fleksibilnost metode. Dobivena rješenja predstavljaju ciklus u kojem se svaki čvor osim početnog pojavljuje samo jedanput te promjena početnog

čvora krećući se po sekvenci atrakcija u ciklusu neće dovesti do promjene ukupne udaljenosti. Navedeno stvara pretpostavku za mogućnost primjene dodatnih kriterija pri konačnom odabiru rute te prostor za dodatno obogaćivanje modela u budućim istraživanjima.

Određivanjem jedne ili nekoliko ruta za deset odabranih atrakcija u jednom gradu neće se riješiti problem organizacije turističkih obilazaka, ali se ponuđeni primjer može iskoristiti i za utvrđivanje alternativa te upućuje na prednost primjene kvantitativnih metoda. Osim toga, uočen je potencijal za obogaćivanje modela u budućim istraživanjima te dodavanje kriterija koji se mogu odnositi, na primjer, na broj turista prisutnih na pojedinoj atrakciji, tempiranje ruta ili međusobno zaobilaženje turističkih grupa. Nadalje, prikazana prilagodba modela otvara mogućnost daljnog razvoja u obliku integracije u zajednički sustav organizacije i praćenja turističkih obilazaka po gradovima.

Iako je model zamišljen ponajprije iz perspektive organiziranih obilazaka i razmatran s obzirom na potpornu ulogu pri organizaciji turističkih ruta u destinaciji, može se upotrijebiti i u individualnom kreiranju ruta te kao primjer upotrebe mrežnih modela u obrazovanju.

Uz već utvrđene prednosti organizacije turističkih ruta, kao što su olakšavanje odabira turistima i ušeda prikupljanja informacija, bolje iskorištavanje vremena turističkih vodiča, smanjenje gužvi te ekološka održivost destinacija, u aktualnoj pandemijskoj situaciji one mogu služiti i organizaciji turističkih obilaska uz poštovanje zaštitnih mjera. Organizacija turističkih obilaska stvara pretpostavku za kreiranje više razine sigurnosti turista (što se tiče zaraze COVID-19). Sigurnost je jedan od važnih čimbenika pri odabiru turističke destinacije, a kreiranje predispozicije za sigurno ljetovanje može pridonijeti učestalijem odabiru turističke destinacije. Taj je aspekt nezanemariv za gradove (i regije) u kojima je veći udio djelatnosti i prihoda vezan za turizam. Organizirani pristup razgledavanju atrakcija nije jedini čimbenik, ali mogao bi pridonijeti upravljanju destinacijom i pogodovati održivosti turizma, kako u pandemijskim uvjetima, tako i u postpandemijskim uvjetima.

## Literatura

Alt, R., Leimeister, J. M., Priemuth, T., Sachse, S., Urbach, N., Wunderlich, N. (2020). Software-Defined Business, *Business & Information Systems Engineering*, 62 (6), 609-621.

Annual report 2016. Microsoft Corporation. Dostupno na:  
<https://www.microsoft.com/investor/reports/ar16/index.html> (pristupljeno 9. 5. 2021.)

Annual report 2019. Microsoft Corporation. Dostupno na:  
<https://www.microsoft.com/investor/reports/ar19/index.html> (pristupljeno 9. 5. 2021.)

Basic, M., Skoric, M. (2020). CROATIA: Q1-Q3 2020 Tourism Results in Context of COVID-19 Pandemic, *Economic and Social Development: Book of Proceedings*, 259-268.

Baker, K. R., Camm, J. D. (2005). On the use of integer programming versus evolutionary solver in spreadsheet optimization, *INFORMS Transactions on Education*, 5 (3), 1-7.

Bérubé, J. F., Gendreau, M., Potvin, J. Y. (2009). An exact  $\epsilon$ -constraint method for bi-objective combinatorial optimization problems: Application to the Traveling Salesman Problem with Profits, *European journal of operational research*, 194 (1), 39-50.

Best Free Things to do in Pula, Tripadvisor. Dostupno na: [https://www.tripadvisor.com/Attractions-g295373-Activities-zft11292-Pula\\_Istria.html](https://www.tripadvisor.com/Attractions-g295373-Activities-zft11292-Pula_Istria.html) (pristupljeno 15. 4. 2021.)

Butt, S. E., Cavalier, T. M. (1994). A heuristic for the multiple tour maximum collection problem, *Computers & Operations Research*, 21 (1), 101-111.

Cui, F., Liu, Y., Chang, Y., Duan, J., Li, J. (2016). An overview of tourism risk perception, *Natural Hazards*, 82 (1), 643-658.

Google maps. Dostupno na: <https://goo.gl/maps/9Jub1n6CU1JCcPKx9> (pristupljeno 15. 4. 2021.)

Floričić, T., Tuličić, K. (2019). Kulturna baština u atrakcijskoj osnovi – Uloga turističkih zajednica u održivom promicanju kulturnih atrakcija, *Kulturna baština u turističkoj destinaciji – vrednovanje i održivi menadžment*, 1-27.

Jiang, C. (2010). A Reliable Solver of Euclidean Traveling Salesman Problems with Microsoft Excel Add-in Tools for Small-size Systems, *JSW*, 5 (7), 761-768.

Kordov, K., Eminov, D. (2018). Applied Software for Managing a Small Business, *Mathematical and Software Engineering*, 4 (1), 12-17.

Kostelić, K., Turk, M. (2021). Topology of the World Tourism Web, *Applied Sciences*, 11 (5), 2253.

Križman Pavlović, D. (2019). Održivi menadžment turističke destinacije i suradnja, *Kulturna baština u turističkoj destinaciji – vrednovanje i održivo upravljanje*, 72-108.

Macroeconomic Developments and Outlook (2020). Croatian National Bank (HNB), *Publishing Department*, 5 (9).

Malik, S., Kim, D. (2019). Optimal travel route recommendation mechanism based on neural networks and particle swarm optimization for efficient tourism using tourist vehicular data, *Sustainability*, 11 (12), 3357.

Mor, M., Fisher-Gewirtzman, D., Yosifof, R., Dalyot, S. (2021). 3D Visibility Analysis for Evaluating the Attractiveness of Tourism Routes Computed from Social Media Photos, *ISPRS International Journal of Geo-Information*, 10 (5), 275.

Patterson, M. C., Harmel, B. (2003). An algorithm for using Excel Solver© for the traveling salesman problem, *Journal of Education for Business*, 78 (6), 341-346.

Perera, D., Rathnayaka, C., Dilan, S., Siriweera, L., Rankothge, W. H. (2018). December. Sustainable Tourism: Application of Optimization Algorithms to Schedule Tour Plans, *2018 IEEE Region 10 Humanitarian Technology Conference (R10-HTC)*, 1-6.

Prasetyowati, S. S., Sibaroni, Y., Prabangkara, D. (2018). The Prediction of Optimal Route of City Transportation Based on Passenger Occupancy using Genetic Algorithm: A Case Study in The City of Bandung, *Telkomnika*, 16 (3), 1201-1207.

Pula – Znamenitosti istarske povijesti, Topdestinacije.hr. Dostupno na: <https://topdestinacije.hr/pula-znamenitosti-istarske-povijesti/> (pristupljeno 15. 4. 2021.)

Reisinger, Y., Mavondo, F. (2005). Travel anxiety and intentions to travel internationally: Implications of travel risk perception, *Journal of travel research*, 43 (3), 212-225.

Qian, X., Zhong, X. (2019). Optimal individualized multimedia tourism route planning based on ant colony algorithms and large data hidden mining, *Multimedia Tools and Applications*, 78 (15), 22099-22108.

Što posjetiti (znamenitosti) u Puli, Putovnica.net. Dostupno na: <https://www.putovnica.net/odredista/hrvatska/pula/sto-posjetiti-znamenitosti-u-puli> (pristupljeno 15. 4. 2021.)

Turistička zajednica Istre. Dostupno na: <https://www.istra.hr/en/destinations/pula> (pristupljeno 15. 4. 2021.)

Turistička zajednica Pule. Dostupno na: <https://www.pulainfo.hr/> (pristupljeno 15. 4. 2021.)

Van Steen, M. (2010). Graph theory and complex networks, *An introduction*, 144.

Vansteenwegen, P., Souffriau, W., Berghe, G. V., van Oudheusden, D. (2009). Iterated local search for the team orienteering problem with time windows, *Computers & Operations Research*, 36 (12), 3281-3290.

Vasilev, J. (2016). Solving the Travelling Salesman Problem With The Alldifferent Constraint in MS Excel, *Conference Paper at 5th International Conference on Application of Information and Communication Technology and Statistics in Economy and Education (ICAICTSEE)*.

Wu, X., Guan, H., Han, Y., Ma, J. (2017). A tour route planning model for tourism experience utility maximization, *Advances in Mechanical Engineering*, 9 (10), 1687814017732309.

Yarmolenko, A. S., Putintseva, N. Y., Pisetskaya, O. N. (2019). Modern geoinformation and communication technologies of economic analysis in ms office 365, *The European Proceedings of Social & Behavioural Sciences EpSBS*, 643-656.

Yuan, C., Uehara, M. (2019). March. An optimal travel route recommendation system for tourists' first visit to Japan, *International Conference on Advanced Information Networking and Applications*, 872-882, Springer, Cham.

Zhou, X., Zhan, Y., Feng, G., Zhang, D., Li, S. (2019). Individualized Tour Route Plan Algorithm Based on Tourist Sight Spatial Interest Field, *ISPRS International Journal of Geo-Information*, 8 (4), 192.