

Optimizacija s pomočjo kolonije mravelj

Ivan Pešl, Viljem Žumer, Janez Brest

*Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, Smetanova ul. 17, 2000 Maribor,
Slovenija*

E-pošta: ivan.pesl@hermes.si

Povzetek. V naravi so mravlje sposobne najti najkrajšo pot od vira hrane do gnezda brez uporabe vizualnih informacij. Poleg tega so se zmožne prilagoditi spremembam v okolju, na primer najti novo najkrajšo pot, ko trenutno pot preseka ovira. Pri tem nastane zamisel, da bi lahko bilo posnemanje takšnega obnašanja mravelj učinkovito tudi v diskretnem svetu. V članku bomo prikazali reševanje problema trgovskega potnika s pomočjo optimizacije s kolonijo mravelj.

Ključne besede: kolonija mravelj, umetna inteligenca, inteligenca roja, problem trgovskega potnika

ACO - Ant Colony Optimization

Extended abstract. Ant colony optimization is a relatively new approach to solving NP-Hard problems. It is based on the behavior of real ants, which always find the shortest path between their nest and a food source. Such behavior can be transferred into the discrete world, where real ants are replaced by simple agents. Such simple agents are placed into the environment where different combinatorial problems can be solved.

In this paper we describe an artificial ant colony capable of solving the travelling salesman problem (TSP). Artificial ants successively generate shorter feasible tours by using information accumulated in the form of a pheromone trail deposited on edges of the TSP graph [1]. The basic ant behavior can be improved by adding heuristic information, e.g. local search.

We describe several different algorithms used in solving the TSP (and similar) problems. We start from the first algorithm that was first used in ant optimization named Ant System. This algorithm has been followed by many others approaches resulting in better performance of ant colony optimization. The main job is to test the ant behavior on different graphs, taken from the *TSP LIB95* library. At the end we show a comparison of ant algorithms on several instances of TSP.

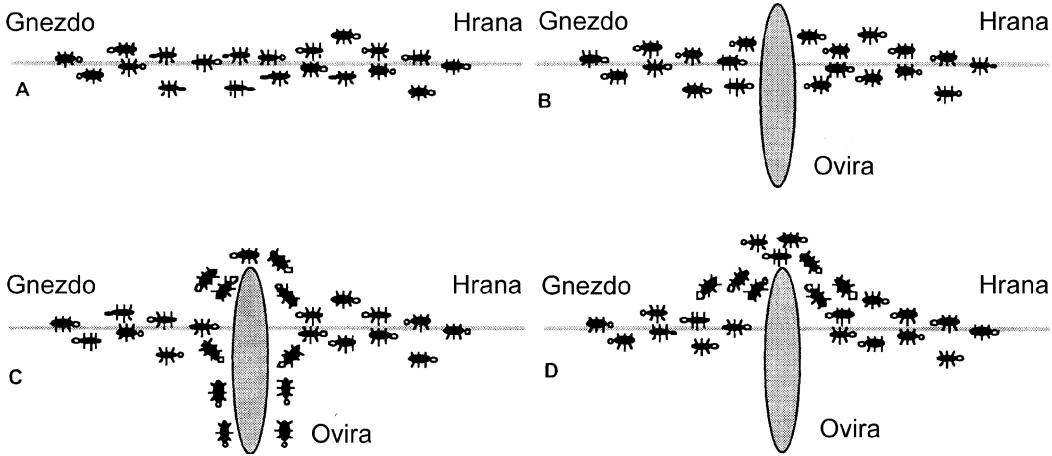
Key words: ant colony optimization, artificial intelligence, swarm intelligence, travelling salesman problem

večjo količino feromona. Mravlje odlagajo feromon med hojo in vsaka mravlja daje prednost sledenju smerem, ki so bogatejše s feromonom. To elementarno obnašanje mravelj uporabimo za razlaganje, kako lahko poiščejo najkrajšo pot, ki ponovno poveže prekinjeno povezavo po tem, ko se je na začetni poti nenadoma znašla ovira (slika 1B). Ko nastane ovira, mravlje pred oviro ne morejo nadaljevati sledenja poti. V tem primeru lahko pričakujemo, da se bo polovica mravelj obrnila desno, druga polovica pa levo. Podoben položaj nastane tudi na drugi strani ovire (slika 1C). Zanimivo je, da bodo mravlje, ki po naključju izberejo krajšo pot okoli ovire, hitreje rekonstruirale prekinjeno pot kot mravlje, ki so izbrala daljšo pot. Zato bo krajsa pot dobila večjo količino feromona na enoto časa in čez čas bo večje število mravelj izbralo krajšo pot (slika 1D). Mravlje so prednosti nagnjene k potem z večjo vsebnostjo feromona, kar naredi nabiranje feromona še hitrejše na krajsih poteh. Pokazali bomo, kako lahko naredimo podoben proces v simuliranem svetu, naseljenem z umetnimi mravlji, ki pa skušajo rešiti problem trgovskega potnika.

Optimizacija s pomočjo kolonije mravelj ACO (Ant Colony Optimization) [1] je del večjega območja, ki se ukvarja z raziskovanjem, temelječim na algoritmu mravelj oz. inteligentnosti roja, in se ukvarja z algoritmčnimi pristopi, ki so povzeti po obnašanju kolonij mravelj in drugih družabnih insektov. Posebnega pomena so kolektivne aktivnosti, kot so nabava hrane, skrb za zarod, gradnja gnezd itd., ki so mehanizmi samoorganizacije, komunikacije in razdelitev opravil. Optimizacija ACO je povzeta po obnašanju mravelj pri iskanju hrane. Mravlje uporabljam posebne sledi feromona za označevanje poti do vira hrane.

1 Uvod

V naravi so mravlje sposobne poiskati najkrajšo pot od vira hrane do gnezda brez uporabe vizualnih informacij. Poleg tega so se zmožne prilagoditi spremembam v okolju, na primer poiskati novo najkrajšo pot, ko se sedanja prekine zaradi ovire. Na sliki 1A so prikazane mravlje, ki se gibljejo po poti, ki povezuje vir hrane z njihovim gnezdom. Za medsebojno komunikacijo mravlje uporabljajo feromon. Poti, ki so bolj obiskane, imajo



Slika 1. Potovanje mravelj med virom hrane ter gnezdom

Figure 1. Ants travelling between the source of food and their

Optimizacija s pomočjo kolonije mravelj se uporablja za reševanje težkih kombinacijskih optimizacijskih procesov, kot so: problem trgovskega potnika, kvadratni delitveni problemi, problemi razvrščanja, dinamični usmerjevalni problemi v telekomunikacijskih omrežjih. Žal je težko teoretično analizirati algoritme ACO, glavni razlog za to je, da so zasnovani na zaporedjih naključnega odločanja, ki ponavadi ni neodvisno in pri katerem se verjetnosti porazdelitve spreminjajo od iteracije do iteracije.

V nadaljevanju bomo natančneje predstavili algoritme ACO. Pokazali bomo uspešnost reševanja na različnih primerih trgovskega potnika, tudi v kombinaciji z algoritmi za izboljšanje rešitev, kot je 2-opt.

2 Vrste algoritmov ACO

2.1 Sistem mravlje - AS

Sistem mravlje (Ant System) [3] je prednik vseh raziskav o algoritmih mravelj in je bil najprej uporabljen pri problemu trgovskega potnika.

Sistem mravlje uporablja predstavitev z grafom, ki je enak grafu trgovskega potnika, dopolnjen s stroškom $\delta(r, s)$ in z zaželenostjo $\tau(r, s)$, imenovano feromon. Feromon med izvajanjem posodablja mravlje. Če je AS uporabljen na simetričnih vrstah TSP, je $\tau(r, s) = \tau(s, r)$, na asimetričnih vrstah pa je mogoče, da $\tau(r, s) \neq \tau(s, r)$.

Sistem mravlje deluje tako, da vsaka mravlja zgenerira celotno pot z izbiranjem mest glede na pravilo prehoda stanj (state transition rule) – mravlje se raje premikajo k mestom, ki so povezana s krajšimi povezavami (z nižjim stroškom) in z veliko količino feromona. Ko vse mravlje opravijo svojo pot, se uporabi pravilo globalne posodobitve feromona (global pheromone updating rule) – na vseh povezavah del feromona izhlapi. Nato vsaka mravlja odloži količino feromona na povezave, ki pri-

padajo njeni poti v razmerju dolžine njene poti (povezave, ki pripadajo veliko kratkim potem, dobijo večjo količino feromona). Proses se potem ponavlja.

Pravilo prehoda stanj se imenuje naključno proporcionalno pravilo (random-proportional rule) in je podano v (1). Pravilo prehoda stanj podaja verjetnost, s katero mravlja k v mestu r izbere mesto s , v katero se premakne:

$$p_k(r, s) = \begin{cases} \frac{[\tau(r, s)] \cdot [\eta(r, s)]^\beta}{\sum_{u \in J_k(r)} [\tau(r, u)] \cdot [\eta(r, u)]^\beta}, & \text{če } s \in J_k(r), \\ 0, & \text{sicer} \end{cases} \quad (1)$$

kjer je τ feromon, $\eta = 1/\delta$ je inverzna vrednost stroška, $J_k(r)$ je množica mest, ki ostanejo, da jih obišče mravlja k in so povezane z r (da je rešitev mogoča), β je parameter, ki določi relativno pomembnost feromona proti strošku ($\beta > 0$).

Če v (1) pomnožimo količino feromona na povezavi (r, s) s pripadajočo hevristično vrednostjo $\eta(r, s)$, damo prednost izbirki povezav, ki so kraje in imajo večjo količino feromona.

Pravilo globalne posodobitve je implementirano kot: ko vse mravlje zgradijo svoje poti, je feromon posodobljen na vseh povezavah glede na:

$$\tau(r, s) \leftarrow (1 - \alpha) \cdot \tau(r, s) + \sum_{k=1}^m \Delta\tau_k(r, s), \quad (2)$$

kjer je:

$$\Delta\tau_k(r, s) = \begin{cases} \frac{1}{L_k}, & \text{če } (r, s) \in \text{poti od mravlje } k \\ 0, & \text{sicer} \end{cases}$$

$0 < \alpha < 1$ je parameter razpada feromona, L_k je dolžina poti narejena od mravlje k in m je število mravelj.

Posodabljanje feromona je namenjeno dodeljevanju večje količine feromona krajšim potem. Formula posodabljanja feromona je namenjena posnemanju spremnjanja

količine feromona zaradi dodajanja novega feromona na povezavah, ki so jih obiskale mravlje, ter izhlapevanja feromona.

Feromon, postavljen na povezave, igra vlogo porazdeljenega dolgotrajajočega spomina; ta spomin ni lokalno shranjen znotraj posamezne mravlje, temveč je porazdeljen po povezavah grafa, kar dovoljuje indirekten način komunikacije.

Čeprav je sistem mravlje uporaben za iskanje dobrih rešitev za majhne TSP (do 30 mest), je potreben čas za reševanje večjih problemov neustrezen. Zato so bile predlagane tri glavne spremembe za izboljšanje algoritma, ki so pripeljale do definicije sistema kolonije mravlj (Ant Colony System – ACS).

2.2 Sistem kolonije mravlj - ACS

ACS [4] se od AS razlikuje v treh glavnih pogledih:

- pravilo prehajanja stanj zagotovi direktni način za uravnovešanje med raziskovanjem novih povezav in izkoriščanjem danih in akumuliranih znanj o problemu,
- pravilo globalne posodobitve je dodano samo povezavam, ki pripadajo samo najboljši poti mravlj, in
- medtem ko mravlje gradijo rešitev, je uporabljeno pravilo lokalne posodobitve feromona.

Incializacija

```

do {
    Vsaka mravlja je postavljena na začetno točko
    do {
        Vsaka mravlja doda pravilo prehajanja stanj,
        da naraščajoče zgradi rešitev, in pravilo
        lokalne posodobitve feromona
    } while (Vse mravlje ne zgradijo kompletne rešitve)
        Dodano je pravilo globalne posodobitve feromona
    } while (Zaključni pogoj)
}
```

Slika 2. Algoritem za ACS

Figure 2. Algorithm for ACS optimization

Algoritem ACS, ki je prikazan na sliki 2, lahko zapišemo: m mravlje je postavljenih na n mest izbranih glede na poljubno incializacijsko pravilo. Vsaka mravlja zgradi pot (mogoča rešitev TSP) s ponavljanjem se dodajanjem stohastičnega požrešnega pravila (pravilo prehoda stanj). Med konstrukcijo svoje poti mravlja tudi spreminja količino feromona na obiskujocih povezavah z dodajanjem lokalnega posodobitvenega pravila. Ko vse mravlje končajo svojo pot, je količina feromona na povezavah spet posodobljena – z dodajanjem globalnega posodobitvenega pravila. Enako kot v AS tudi tu mravlje

uporabljam za gradnjo svojih poti obe, hevristično informacijo (raje izbirajo krajše povezave) in informacijo o količini feromona.

2.2.1 Pravilo prehoda stanj

V ACS je pravilo prehoda stanj naslednje: mravlja postavljena v mesto r , izbere mesto s , kamor se bo premaknila s pravilom:

$$s = \begin{cases} \arg \max_{u \in J_k(r)} \{ [\tau(r, u)] \cdot [\eta(r, u)]^\beta \}, \\ \text{če } q \leq q_0 \text{ (izkoriščanje)} \\ S, \text{ sicer (pristransko raziskovanje)}, \end{cases} \quad (3)$$

kjer je q naključno število uniformno porazdeljeno v $[0..1]$, q_0 je parameter ($0 \leq q_0 \leq 1$) in S je naključna spremenljivka, izbrana glede na verjetnost porazdelitve v (1).

Pravilo prehajanja stanj, sestavljeno iz (3) in (1), se imenuje psevdonaključno proporcionalno pravilo (pseudo random proportional rule). To pravilo prehajanja stanj je prav tako kot prejšnje naključno proporcionalno pravilo naklonjeno prehodom k mestom, ki so povezana s krajšimi povezavami in z veliko količino feromona. Parameter q_0 določa relativno pomembnost izkoriščanja glede na raziskovanje: vsakič ko mora mravlja v mestu r izbrati mesto s za premik, naključno izbere število $0 \leq q \leq 1$. Če je $q \leq q_0$, potem je izbrana povezava glede na (3), sicer je izbrana povezava glede na (1).

2.2.2 Globalno posodobitveno pravilo

V ACS samo globalno najboljša mravlja (mravlja, ki je zgradila najkrajšo pot od začetka procesa) lahko položi feromon. Ta izbira skupaj z uporabo psevdonaključnega proporcionalnega pravila naredi iskanje bolj direktno: mravlje iščejo v sosedstvu trenutno najboljše najdene poti. Globalno posodabljanje je izvedeno, ko vse mravlje končajo svoje poti. Stopnja feromona je posodobljena z uporabo globalnega posodobitvenega pravila:

$$\tau(r, s) \leftarrow (1 - \alpha) \cdot \tau(r, s) + \alpha \Delta \tau(r, s), \quad (4)$$

kjer je:

$$\Delta \tau(r, s) = \begin{cases} (L_{gb})^{-1}, \text{ če } (r, s) \in \text{globalno} \\ \text{najboljše poti} \\ 0, \text{ sicer} \end{cases}$$

$0 < \alpha < 1$ je parameter izhlapevanja feromona in L_{gb} je dolžina globalno najboljše poti od začetka procesa.

Namen globalnega posodabljanja je zagotovitev večje količine feromona na kratkih poteh. Enačba (4) narekuje, da samo povezave, ki pripadajo globalno najboljši poti, dobijo ojačitev. Preizkušen je tudi drugi tip globalno posodobitvenega pravila, imenovan ponovitveno

najboljši, ki uporablja L_{ib} (dolžina najboljše poti trenutne iteracije) v enačbi (4). Pri ponovitveno najboljšem pravilu povezave, ki dobijo ojačitev, pripadajo najboljši poti trenutne iteracije. Preizkusi so pokazali, da je razlika med tem dveema shemama minimalna, z manjšo prednostjo pri uporabi globalno najboljšega pravila.

2.2.3 Lokalno posodobitveno pravilo

Med gradnjo rešitve za TSP mrvlje obiskujejo povezave in spreminjajo njihovo stopnjo feromona z uporabo lokalnega posodobitvenega pravila:

$$\tau(r, s) \leftarrow (1 - \rho) + \rho \cdot \Delta\tau(r, s), \quad (5)$$

kjer je $0 < \rho < 1$ parameter.

Vloga lokalnega posodabljanja v ACS je, da pomeša poti, tako da so zgodnja mesta v poti ene mrvlje pozneje raziskana v poteh drugih mrvelj. Z drugimi besedami, učinek lokalnega posodabljanja je, da se zaželenost povezav dinamično spreminja: vsakič ko mrvlja uporabi povezavo, ta postane malo manj zaželena (ker izgubi nekaj svojega feromona). V tej smeri bodo mrvlje bolje izkoristile informacijo o feromonu: brez lokalnega posodabljanja bi vse mrvlje iskale v ozki sosečini najboljše prejšnje poti.

2.3 MAX-MIN sistem mrvlje - MMAS

MAX-MIN sistem mrvlje [5] je direktna izboljšava AS. Rešitve v MMAS so zgrajene natančno tako kot v AS, to pomeni, da so verjetnosti izbire izračunane enako kot v enačbi (1). Dodatno obstaja tudi vrsta MMAS, ki uporablja psevdonaključno proporcionalno izbirno pravilo povzeto po ACS. Z uporabo tega pravila so dobre rešitve najdene zelo hitro, medtem ko je kakovost končne rešitve slabša.

Glavne spremembe v MMAS glede na AS so naslednje:

- za uporabo najboljše najdene rešitve lahko po vsaki iteraciji samo ena mrvlja doda feromon (kot v ACS),
- da se izognemo zastajanju iskanja, je dovoljeni obseg sledi feromona omejen z intervalom $[\tau_{min}, \tau_{max}]$, kar pomeni, da za $\forall \tau_{ij}$ velja $\tau_{min} \leq \tau_{ij} \leq \tau_{max}$, in
- sledi feromona so inicializirane na zgornjo mejo, kar povzroči večje raziskovanje na začetku algoritma.

Ko vse mrvlje zgradijo rešitev, se sledi feromona posodobijo glede na:

$$\tau_{ij}(t+1) = (1 - \rho) \cdot \tau_{ij}(t) + \Delta\tau_{ij}^{best}, \quad (6)$$

kjer $\Delta\tau_{ij}^{best} = 1/L^{best}$. Mravlja, kateri je dovoljeno, da doda feromon, je lahko iteracijsko najboljša T^{ib} ali globalno najboljša T^{gb} . Če so določene povezave pogosto uporabljeni v najboljših rešitvah, bodo dobine večjo količino feromona.

Sledi feromona so v MMAS inicializirane na maksimalno vrednost feromona. Zato je raziskovanje poti na začetku algoritma povečano, ker je relativna razlika med količino feromona manj razločna.

2.4 Sistem mrvlje z rangiranjem - AS_{rank}

Naslednja izboljšava je sistem mrvlje z rangiranjem *Rank-Based Version of Ant System* [7]. V AS_{rank} je vedno uporabljeni globalno najboljša pot za posodobitev sledi feromona, podobno kot v AS. Dodatno pa lahko še nekaj najboljših mrvelj trenutne iteracije doda feromon. Da to dosežemo, so mrvlje urejene po njihovi dolžini poti ($L^1(t) \leq L^2(t) \leq \dots \leq L^m(t)$) in količina feromona, ki ga lahko mrvlja položi, je določena z njenim položajem. Samo $(w-1)$ najboljšim mrvljam je dovoljeno, da dodajo feromon. Globalno najboljši rešitvi, ki da najmočnejši odziv, je dana utež w . r -ta najboljša mrvlja trenutne iteracije prispeva feromon z utežjo, dano glede na $\max\{0, w-r\}$. Modificirano pravilo posodobitve feromona je naslednje:

$$\tau_{ij}(t+1) = (1 - \rho) \cdot \tau_{ij}(t) + \sum_{r=1}^{w-1} (w-r) \cdot \Delta\tau_{ij}^r(t) + w \cdot \Delta\tau_{ij}^{gb}(t), \quad (7)$$

kjer je $\Delta\tau_{ij}^r(t) = 1/L^r(t)$ in $\Delta\tau_{ij}^{gb}(t) = 1/L^{gb}(t)$.

3 Stagnacija iskanja

Očitno je, da imajo predlagani algoritmi ACO veliko skupnih značilnosti. Sistem mrvlje je lahko viden kot prva študija za demonstriranje sposobnosti algoritmov ACO za reševanje težkih kombinacijskih problemov, vendar je njegova učinkovitost slabša v primerjavi z drugimi pristopi. Zato je predlaganih nekaj algoritmov ACO, ki močno izboljšajo učinkovitost sistema mrvlje. Glavna skupna značilnost med predlaganimi izboljšavami je, da bolj močno izkoriščajo najboljšo najdeno rešitev med raziskovanjem.

Problem, ki nastane pri močnejšem izkoriščanju najboljše rešitve, je stagnacija iskanja, to je situacija, kjer vse mrvlje sledijo isti poti. Zato nekateri algoritmi ACO (ACS in MMAS) predstavljajo dodatne značilnosti, da se izognejo stagnaciji. V ACS imamo lokalno posodabljanje, pri MMAS pa vpeljemo meje na dovoljeno količino feromona na povezavah.

Drugi zanimivi pristop za izboljšanje rešitev, dobljenih z algoritmi ACO, je uporaba lokalne optimizacije. Pravzaprav se že kar hitro pokaže, da je za

gradnjo dobrih rešitev optimizacija s pomočjo kolonije mravlj primeren pristop. Da pa takšno rešitev še popravimo, uporabimo na njej lokalne algoritme.

4 Lokalno iskanje

Ker se je pri preizkušanju pokazalo, da konstruktivni algoritmi pripeljejo do slabših rezultatov kot lokalni iskalni algoritmi, se poraja zamisel, da oba pristopa združimo. V našem primeru uporabimo ACO za iskanje rešitev, ki jih potem optimiramo z lokalnim iskanjem in dobljeno rešitev nadalje uporabimo v ACO (za posodabljanje feromona).

```

do {
    for (vsako začetno točko i) {
        for (vsako končno točko j) {
            if ((δ(i,i+1)+δ(j,j+1)) > (δ(i,j)+δ(i+1,j+1))) {
                zamenjam povezave, ter popravimo
                pripadajoče zaporedje
            } // if
        } // for j
    } // for i
} while (imamo izboljšavo)

```

Slika 3. Algoritem za optimizacijo 2-opt
Figure 3. 2-opt optimization algorithm

Izbira lokalnega iskalnega algoritma je odvisna od problema, ki ga rešujemo. Za TSP se uporablja algoritma 2-opt (slika 3) in 3-opt, ki iterativno zamenjujeta po dve ali tri povezave, dokler ne najdeta boljše rešitve. Lokalno iskanje, ki zamenjuje več kot tri povezave, se zaradi velike časovne zahtevnosti ne uporablja. V tem članku uporabljam samo algoritmom 2-opt.

5 Eksperimentalni rezultati

Primerne nastavitev parametrov za algoritme ACO je treba dobiti s preliminarnimi poskusi. Za preizkuse smo uporabljali naslednje nastavitev:

- število mravlj m je enako številu mest, tako da pride ena mravlja na vsako mesto,
- moč hevristične informacije β je nastavljena na 2,
- mero izhlapevanja ρ smo nastavili na 0.2, kar se je izkazalo za dobro izbrano vrednost (ne prehitro in ne prepočasno izhlapevanje),
- velikost seznama kandidatov smo nastavili na 10 odstotkov števila mest,
- pomembna je nastavitev količine feromona na povezavah in njegovih mej (τ_{min}, τ_{max}). Količina feromona je odvisna od dolžine najdene rešitve in je nastavljena na $\tau_{max} = 1/(\rho \cdot T^{gb})$, kjer je T^{gb}

dolžina globalno najboljše najdene rešitve. Spodnja meja je izbrana glede na $\tau_{min} = \tau_{max}/(2 \cdot n)$.

Za testni prostor smo iz knjižnice TSPLIB izbrali naslednje primere:

- a280.tsp - Drilling problem (Ludwig),
- att48.tsp - 48 capitals of the US (Padberg/Rinaldi),
- lin318.tsp - 318 city problem (Lin/Kernighan),
- eil51.tsp - 51 city problem (Christofides/Eliton),
- kroA100.tsp - 100 city problem (Krolik/Felts/Nelson).

Knjižnica TSPLIB je na <http://www.iwr.uni-heidelberg.de/groups/comopt/software/TSPLIB95/>.

Cilj raziskave je poleg predstavitev algoritmov ACO tudi preverjanje delovanje algoritma ACS ter vpliv lokalnega iskanja na končni rezultat. Končni rezultat primerjamo tudi z optimalnim rezultatom za določeni testni primer. Prav tako primerjamo vpliv lokalnega iskanja ter razlike z naključnimi sprehodi po grafu. Hitrosti algoritma z drugimi algoritmi nismo primerjali, ker je težko zagotoviti enake pogoje, kot so bili izvedeni v drugih raziskavah.

V tabeli 1 so prikazani rezultati reševanja problemov trgovskega potnika. V prvem stolpcu so imena problemov. V drugem je njihova optimalna rešitev oz. najboljša najdена rešitev. Tretji stolpec vsebuje rešitev, dobljeno z algoritmom ACS brez lokalnega iskanja. Četrti stolpec vsebuje rešitev z uporabo algoritma ACS in dodanega lokalnega iskanja. Za lokalni iskalni algoritem smo uporabili 2-opt, ki je uporabljen na vsakih 25 iteracij. V petem stolpcu prikazujemo rezultate, dobljene samo z algoritmom 2-opt, ki je dodan rešitvi, dobljeni z naključnim sprehajanjem po grafu. V zadnjem stolpcu so rešitve, dobljene z naključnim sprehajanjem po grafu. Pri naključnem sprehajjanju po grafu izbiramo samo najbližja mesta s seznama kandidatov, kar pomeni, da je to naključno sprehajanje rahlo voden. Rezultati so dobljeni s tridesetimi ponovitvami vsakega algoritma in so podani kot najslabša (Max), najboljša (Min) in povprečna (Avg) vrednost.

Iz prikazanih rezultatov vidimo, da je reševanje optimizacijskih problemov z ACO učinkovito, še posebej kadar jih uporabimo skupaj z algoritmi za izboljšanje rešitev (primerjava ACS in ACS + 2-opt). Algoritem ACS gradi rešitev (konstrukcijski algoritem), 2-opt pa je po svoji naravi algoritmom, ki izboljšuje rešitev. Rezultati algoritma ACS so primerljivi z rezultati algoritma 2-opt. Vidi se tudi razlika pri uporabi samo algoritmov ACS za gradnjo rešitev, kar potrjuje tezo, da se splača združiti algoritme, ki rešitev gradijo, z algoritmi, ki izboljšujejo

Problem	Optimalna rešitev	ACS			ACS + 2-opt			2-opt			Naključno		
		Max	Min	Avg	Max	Min	Avg	Max	Min	Avg	Max	Min	Avg
att48	33523	36588	35116	35764	33957	33523	33686	37323	34604	35552	77017	70614	74032
eil51	426	459	443	453	432	428	430	488	446	456	912	878	891
kroa100	21282	23245	22601	22968	21390	21294	21343	23762	22020	22871	75580	72374	74232
a280	2579	3016	2940	2969	2711	2625	2668	2919	2821	2873	13925	13286	13718
lin318	42029	47829	45365	46671	43325	42974	43202	46916	44159	45488	255012	243265	250330

Tabela 1. Rezultati algoritmov na TSPLIB testnih primerih

Table 1. Results of algorithms on the TSPLIB test examples

rešitev. To tezo nam dokazuje primerjava rezultatov algoritma ACS z uporabo algoritma 2-opt in samo z algoritmom 2-opt ali ACS. Dobljeni rezultati se ne razlikujejo veliko od optimalnih, včasih jih celo dosežejo. Prednost algoritmov ACO je tudi ta, da so primerni za vzporedno obdelavo [6] (vsaka mravlja lahko gradi pot na svojem procesorju, pomnilnik (feromon) pa je skupen).

6 Tehnike za pohitritev algoritma ACS

Časovna zahtevnost predstavljenega algoritma ACS je $O(n^2)$, kjer je n število mest. Tudi zahtevnost lokalnega iskanja (2-opt) je $O(n^2)$, kar da skupaj časovno zahtevnost $O(n^4)$. Takšno časovno zahtevnost se da zmanjšati z uvedbo tehnik, imenovane seznam kandidatov [2]. Seznam kandidatov vsebuje mesta, ki so najbližje trenutnemu mestu (urejena po naraščajočem vrstnem redu) in ko izbiramo naslednje mesto za obisk, vzamemo mesto s tega seznama. Če smo obiskali že vsa mesta s seznama kandidatov, potem vzamemo prvo še ne obiskano mesto. Praktične izkušnje so pokazale, da lahko seznam kandidatov vsebuje sorazmerno malo mest za enako učinkovitost iskanja. Na primer za TSP s 500 mesti je dovolj od 6 do 10 mest. Enako tehniko lahko uporabimo tudi pri lokalnem iskanju [2].

Podoben primer imamo tudi pri posodabljanju feromona. Ker je feromon shranjen v matriki z $O(n^2)$ elementi (eden za vsako povezavo), mora biti tudi feromon posodobljen za vsako povezavo v vsaki iteraciji. Ker je to draga operacija, posodobimo samo feromon, ki je na seznamu kandidatov vsakega mesta.

7 Sklep

V delu sta predstavljeni analiza algoritmov ACO in njihova uporaba za reševanje problema trgovskega potnika. Največji poudarek je na algoritmu ACS, ki je med predstavljenimi algoritmi najuspešnejši, posebej kadar ga združimo z algoritmi, ki izboljšujejo rešitev. Dobljeni rezultati potrjujejo uporabnost takšnega pristopa za reševanje težkih optimizacijskih problemov.

8 Literatura

- [1] Marco Dorigo, Thomas Stutzle: *Ant Colony Optimization*, MIT Press, 2004.
- [2] Thomas Stutzle, Marco Dorigo: ACO Algorithms for the Traveling Salesman Problem, *Evolutionary Algorithms in Engineering and Computer Science: Recent Advances in Genetic Algorithms, Evolution Strategies, Evolutionary Programming, Genetic Programming and Industrial Applications*, pp. 163-184, Belgium, 1999.
- [3] Marco Dorigo, Luca Maria Gambardella: Ant colonies for Traveling Salesman Problem, *BioSystems*, pp. 73-81, 1997.
- [4] Marco Dorigo, Luca Maria Gambardella: Ant Colony System: A Cooperative Learning Approach to the Traveling Salesman Problem, *IEEE Transaction on Evolutionary Computation*, Vol. 1, pp. 53-66, 1997.
- [5] Thomas Stutzle, Holger Hoos: MAX-MIN Ant System and Local Search for Combinatorial Optimization Problems, *Meta-Heuristic, Advances and Trends in Local Search Paradigma for Optimization*, Kluwer Academic Publishers, pp. 313-329, 1998.
- [6] Bernd Bullnheimer, Gabriele Kotsis, Christine Strauss: Parallelization Strategies for the Ant System, *SFB Adaptive Information Systems and Modelling in Economics and Management Science*, Austria, 1997.
- [7] Bernd Bullnheimer, Richard F. Hartl, Christine Strauss: A New Rank Based Version of the Ant System, *SFB Adaptive Information Systems and Modelling in Economics and Management Science*, Austria, 1997.

Ivan Pešl je diplomiral leta 2002 na Fakulteti za elektrotehniko, računalništvo in informatiko Univerze v Mariboru. Trenutno je študent podiplomskega študija na omenjeni fakulteti. Njegovo področje raziskovanja so evolucijski algoritmi. Od leta 2000 je zaposlen v podjetju Hermes Softlab, d.d.

Viljem Žumer je redni profesor na Fakulteti za elektrotehniko, računalništvo in informatiko Univerze v Mariboru. Vodi Inštitut za računalništvo in Laboratorij za računalniške arhitekture in jezike. Področja, s katerimi se ukvarja, so programski jeziki, parallelno in porazdeljeno procesiranje ter računalniške arhitekture.

Janez Brest je diplomiral leta 1995, magistriral leta 1998 in doktoriral leta 2001 na Fakulteti za elektrotehniko, računalništvo in informatiko Univerze v Mariboru. Od leta 1994 je zaposlen v Laboratoriju za računalniške arhitekture in jezike, kjer se ukvarja s spletnim programiranjem, s parallelnim in porazdeljenim procesiranjem. Njegovo področje dela so tudi programski jeziki, ukvarja pa se tudi z optimizacijskimi raziskavami.