


OPTIMIZACIJA S KOLONIJAMI MRAVELJ

PREDAVANJA 2011/12

J.Tasič

E. Plesnik

OPTIMIZACIJA S KOLONIJAMI MRAVELJ = ANT COLONY OPTIMIZATION (ACO)



VSEBINA

Poglavje I (Uvod)

Zgodovinsko ozadje

Sistem mravljišča

Modificirani algoritmi

Poglavje II (Aplikacije)

TSP

QAP

Poglavje III (Aplikacije +Zaključki)

NRP

VRP

Zaključki, omejitve

UVOD

Uvod (inteligenca rojev)

Naravno obnašanje mravelj

Prvi algoritem: sistem mravelj

Nadgradnje sistema mravelj

Aplikacije

INTELIGENCA ROJEV

Kolektivni sistem, ki je zmožen opavljati zahtevne naloge v dinamičnih in spremenljivih okoljih brez zunanjega vodenja ali nadzora in brez centralne koordinacije.

Kolektiv dosega zmogljivost, ki je posameznik ne zmore.

Predstavlja naravni model, še posebej primeren za porazdeljene reševanje problemov.






<http://www.scs.carleton.ca/~arpwhite/courses/95590Y/notes/SI%20Lecture%203.pdf>







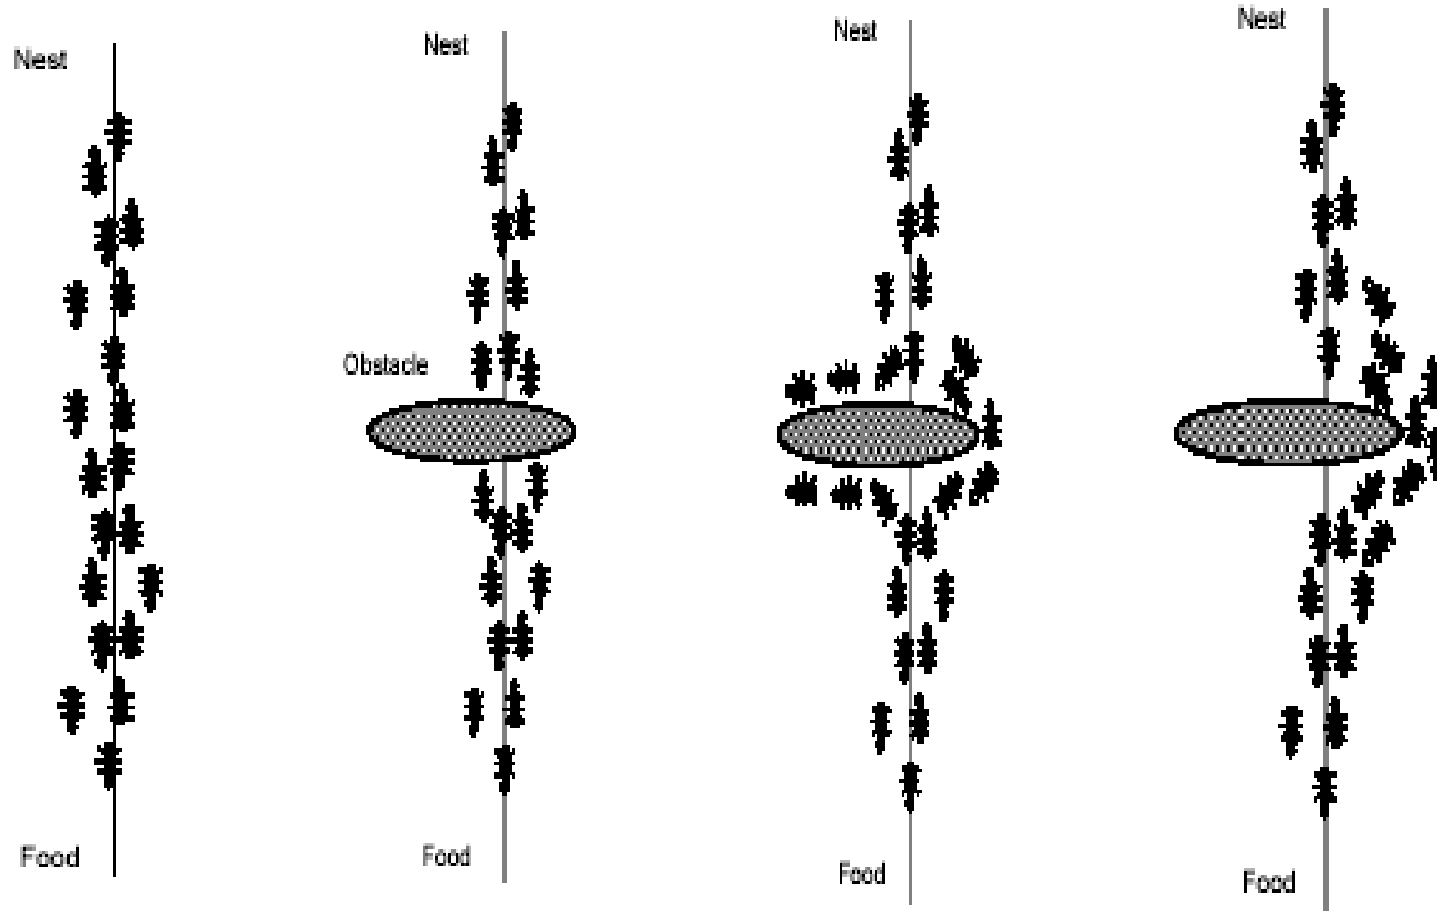
NELOČLJIVE ZNAČILNOSTI

- Paralelizem
- Stohastičnost
- Prilagodljivost
- Pozitivna povratna zanka
- Avtokatalitski v naravi

NARAVNO OBNAŠANJE MRAVLJE

- Potepanje
- Iskanje
- Vračanje
- Privlačenje
- Sledenje
- Nošenje

NARAVNO OBNAŠANJE MRAVLJE



IMPLEMENTACIJA V PROGRAM

Mravlje: Enostavni računalniški agenti

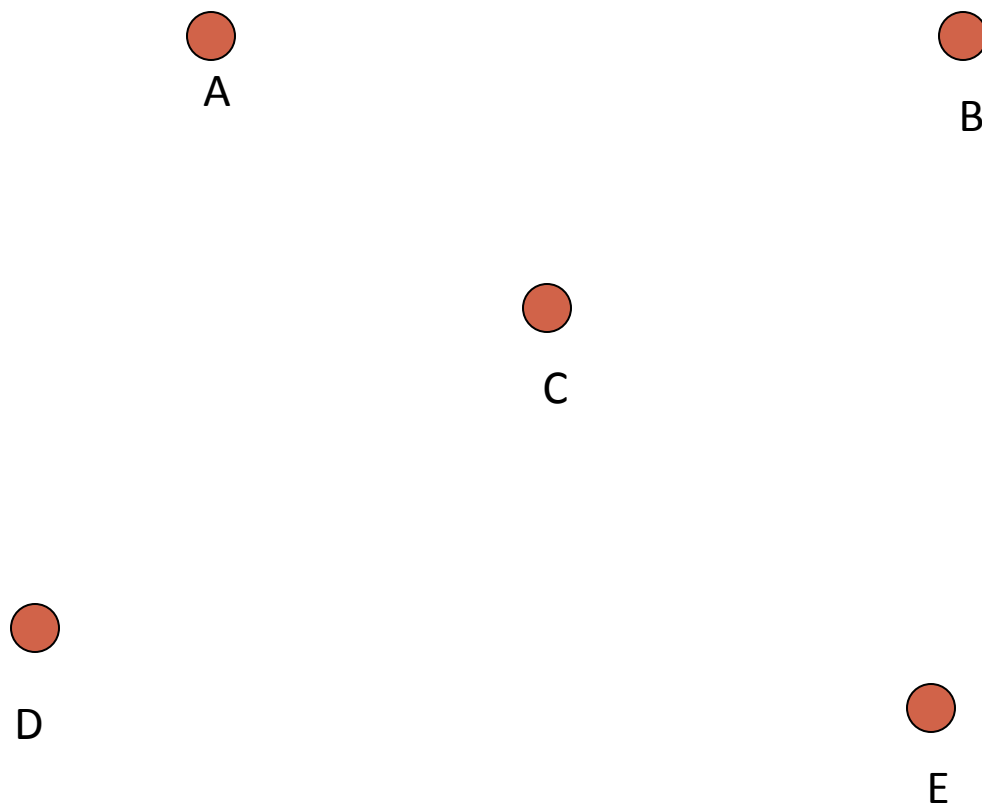
Premik: izberi naslednjo komponento rešitve

Feromoni: $\Delta\tau_{i,j}^k$

Spomin: M_K ali Tabu_K

Naslednja poteza: Uporabi verjetnost za naslednji premik






PREPROST TSP (POTUJOČI TRGOVSKI POTNIK) PRIMER




$$d_{AB} = 100; d_{BC} = 60; d_{DE} = 150$$



ITERACIJA 1



NASLEDNJA REŠITEV?



$$p_{ij}^k(t) = \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}]^\beta}{\sum_{k \in \text{allowed}_k} [\tau_{ik}(t)]^\alpha [\eta_{ik}]^\beta} \quad \text{if } j \in \text{allowed}_k$$

0 otherwise

D


E

ITERACIJA 2


[E,A]




[C,B]




[B,C]



[A,D]




[D,E]




ITERACIJA 3

[D,E,A]




[E,A,B]




[A,D,C]








[B,C,D]



[C,B,E]



ITERACIJA 4




ITERACIJA 5


[C,B,E,D,A]




[A,D,C,E,B]



[D,E,A,B,C]



[E,A,B,C,D]



[B,C,D,A,E]



OCENA POTI IN FEROMONOV

[A,D,C,E,B]



$L_1 = 300$

$$\Delta\tau_{i,j}^k = \begin{cases} \frac{Q}{L_k} & \text{if } (i, j) \in \text{tour} \\ 0 & \text{otherwise} \end{cases}$$

[B,C,D,A,E]



$L_2 = 450$

[C,B,E,D,A]

$$\Delta\tau_{A,B}^{total} = \Delta\tau_{A,B}^1 + \Delta\tau_{A,B}^2 + \Delta\tau_{A,B}^3 + \Delta\tau_{A,B}^4 + \Delta\tau_{A,B}^5$$

[D,E,A,B,C]



$L_4 = 280$

[E,A,B,C,D]



$L_5 = 420$

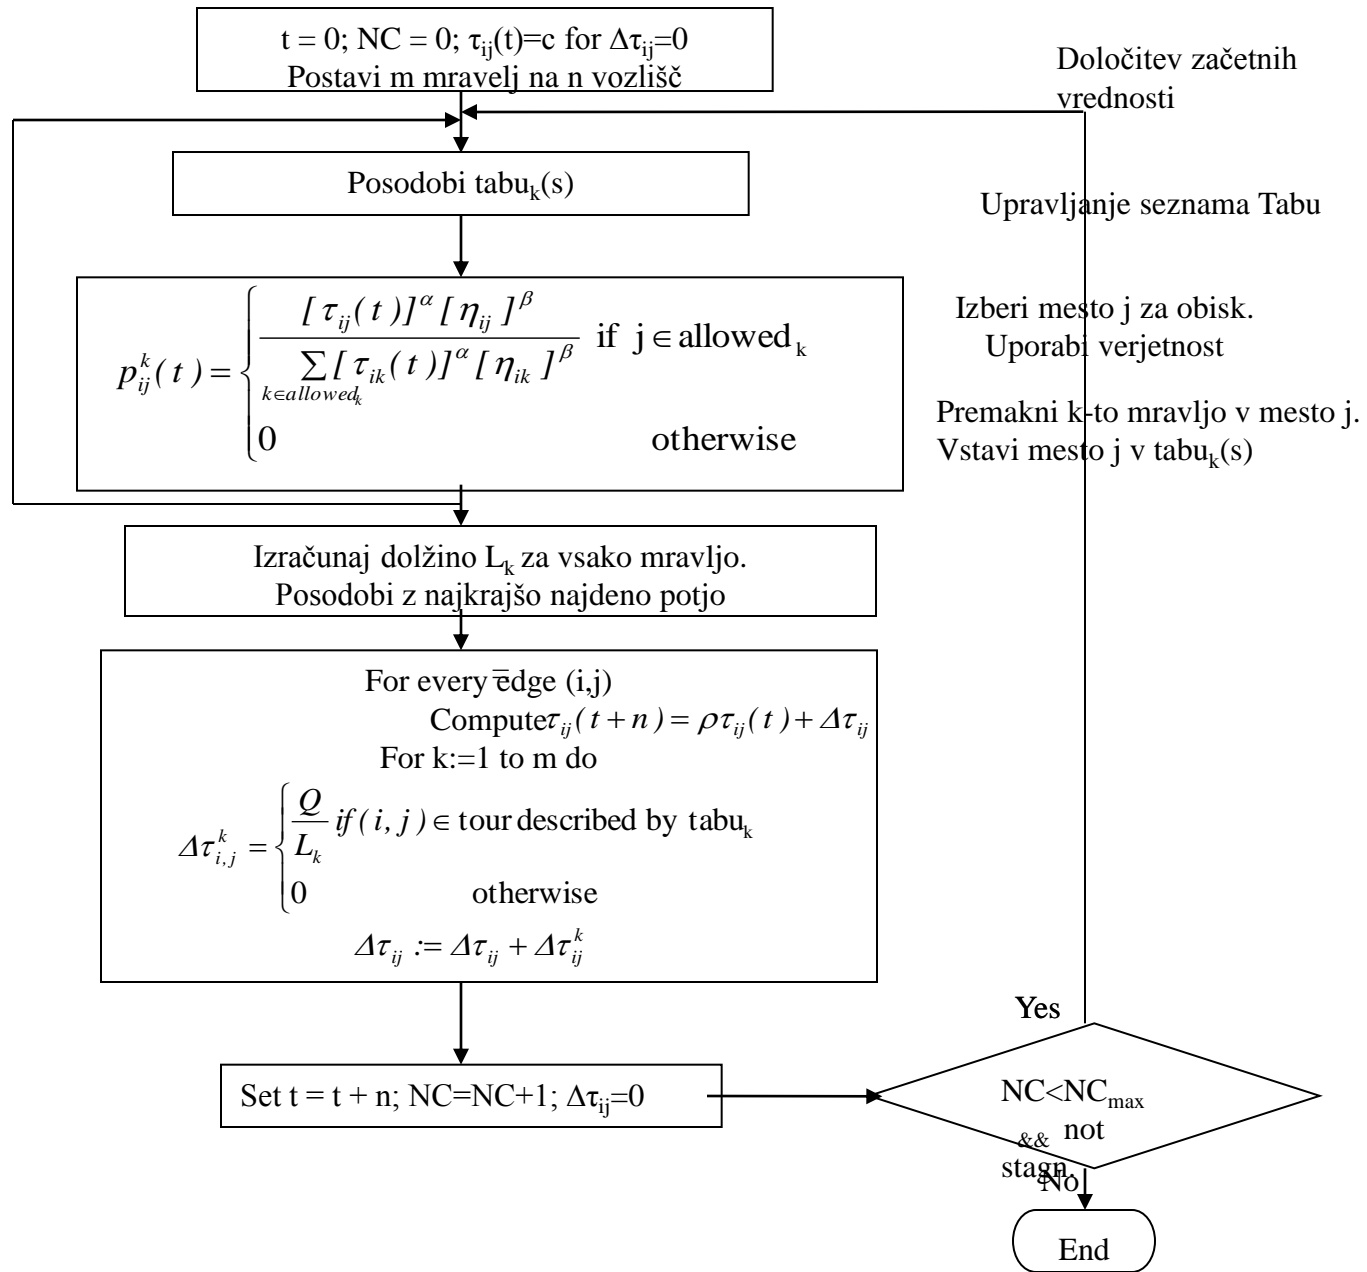
Končan prvi obhod

Shrani najboljši obhod (zaporedje in dolžino)

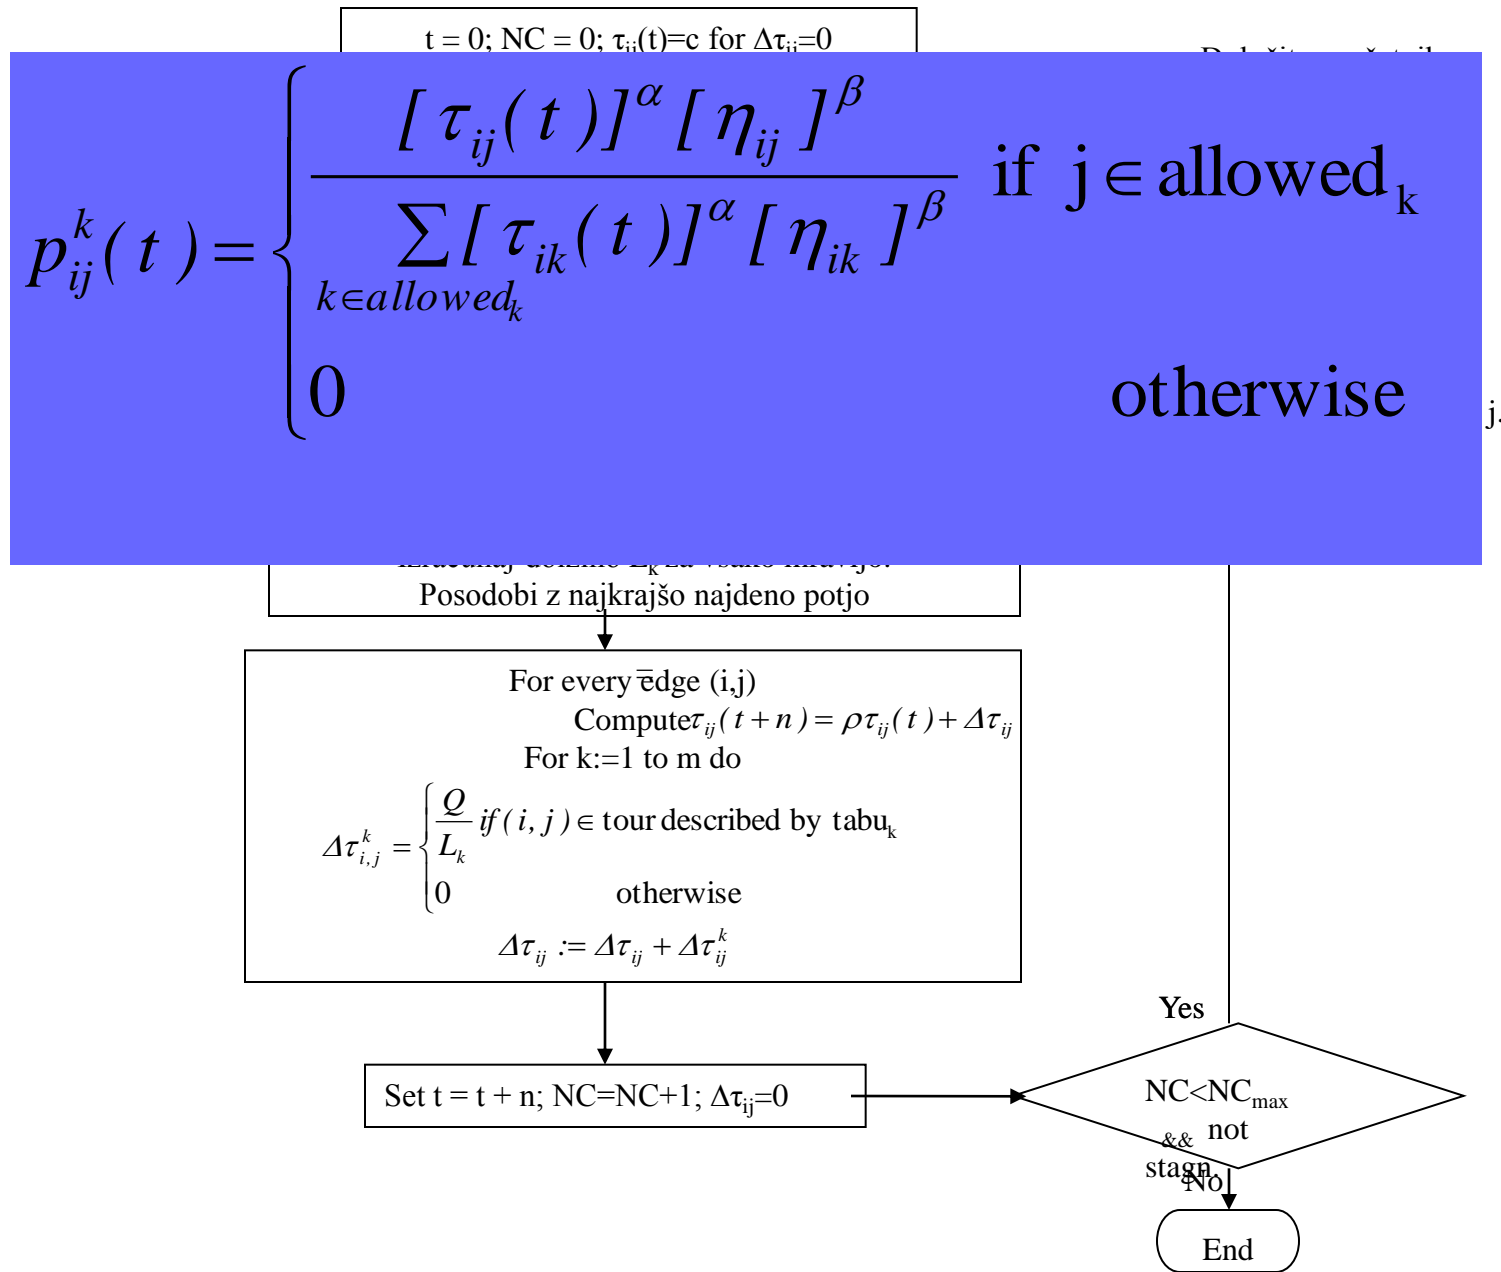
Vse mravlje umrejo

Rodijo se nove mavlje

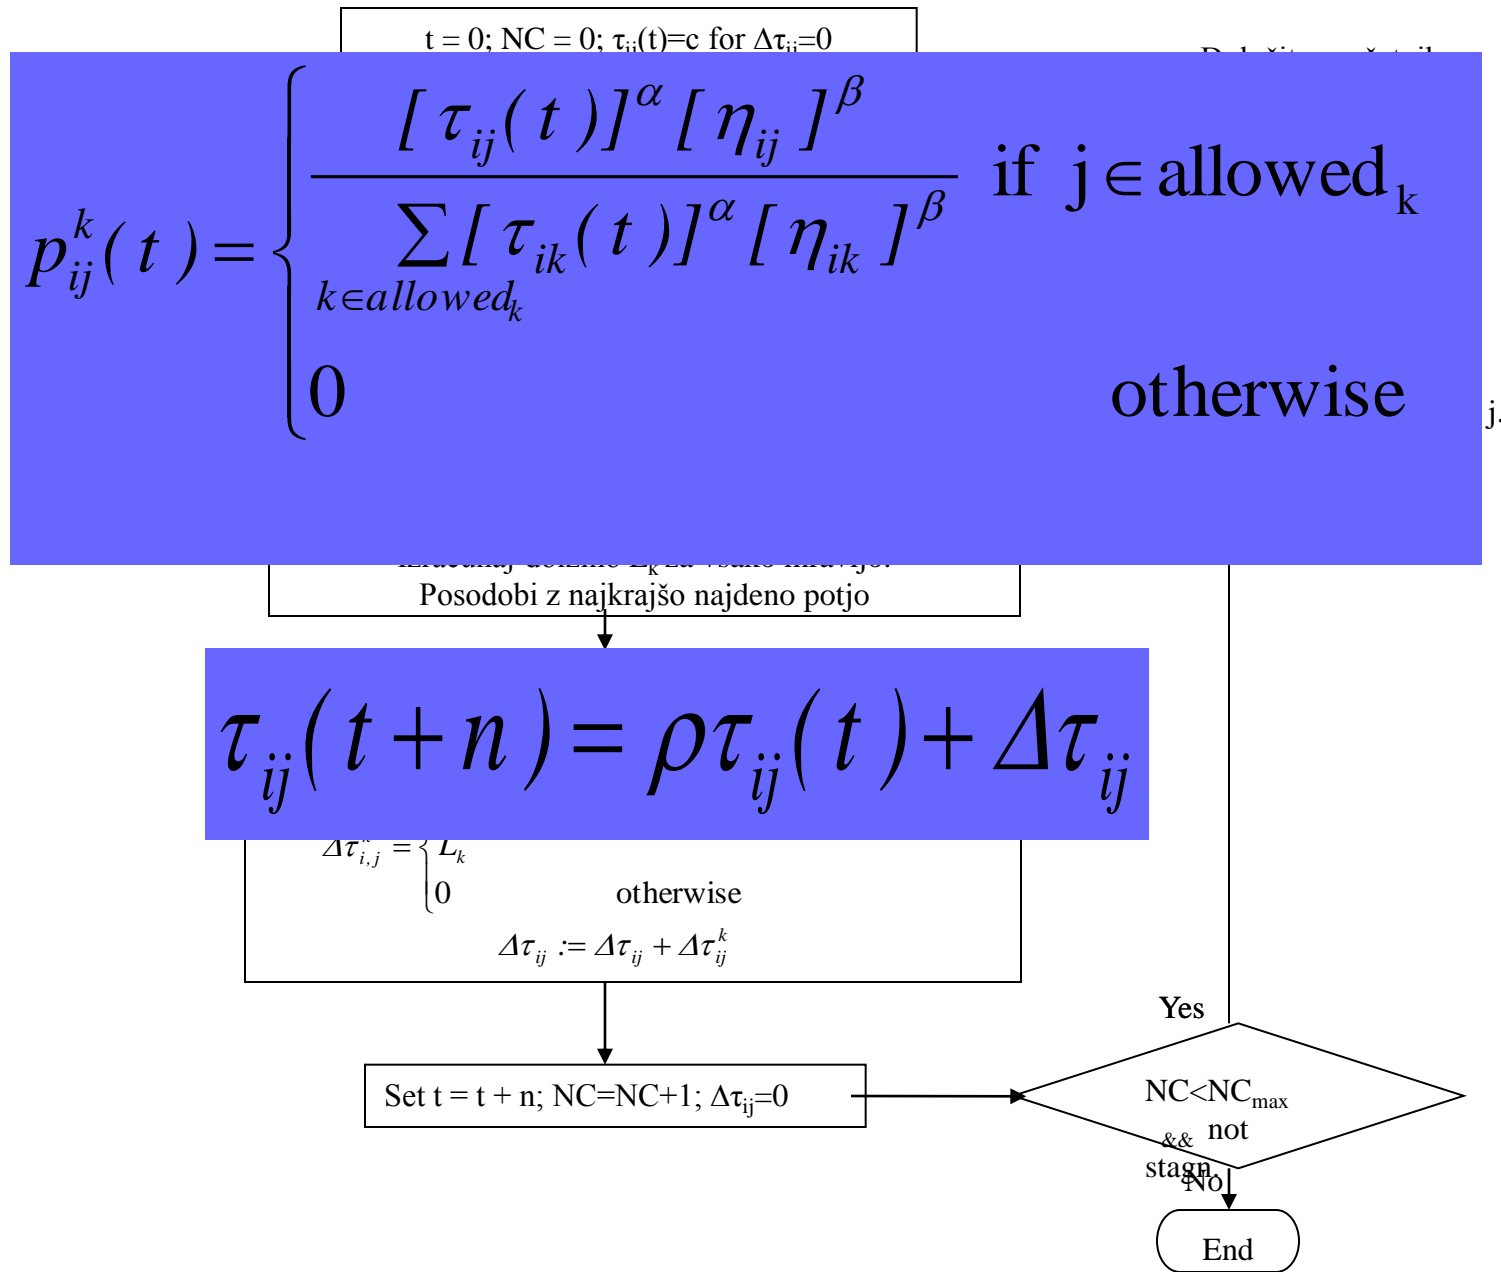
SISTEM MRAVELJ (IZVEDBA ANT CYCLE) DORIGO [1] 1991



SISTEM MRVELJ (IZVEDBA ANT CYCLE) DORIGO [1] 1991



SISTEM MRVELJ (IZVEDBA ANT CYCLE) DORIGO [1] 1991



SISTEM MRVELJ (IZVEDBA ANT CYCLE) DORIGO [1] 1991

$t = 0; NC = 0; \tau_{ij}(t) = c$ for $\Delta\tau_{ij} = 0$

$$p_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}]^\beta}{\sum_{k \in allowed_k} [\tau_{ik}(t)]^\alpha [\eta_{ik}]^\beta} & \text{if } j \in allowed_k \\ 0 & \text{otherwise} \end{cases}$$

Posodobi z najkrajšo najdeno potjo

$$\tau_{ij}(t+n) = \rho\tau_{ij}(t) + \Delta\tau_{ij}$$


$$\Delta\tau_{i,j}^k = \begin{cases} \frac{Q}{L_k} & \text{if } (i, j) \in \text{tour described by } tabu_k \\ 0 & \text{otherwise} \end{cases}$$

End

USTAVITVENI KRITERIJ

Stagnacija

Max iteracij



SPLOŠNO O ACO

Postopek konstrukcije je stohastičen (naključen)

Rešitev je dobljena verjetnostno

Rešitev se iterativno nadgrajuje/dopolnjuje

- hevristični podatki

- feromonska sled

Spomin z okrepitevenim učenjem

Prilagajanje predstavitve problema ob vsaki iteraciji

SPLOŠNO O ACO

Mravlje delujejo sprotno in neodvisno

Kolektivna interakcija vodi do dobrih rešitev preko
indirektne komunikacije

IZVEDBE SISTEMA MRAVELJ

Ant Cycle ($O(NC.n^3)$)


Ant Density (Quantity Q)

Ant Quantity (Quantity Q/d_{ij})


	Optimalni parametri	Povprečni rezultat	Najboljši rezultat
ant-density	$\alpha=1, \beta=5, \rho=0.99$	426.740	424.635
ant-quantity	$\alpha=1, \beta=5, \rho=0.99$	427.315	426.255
ant-cycle	$\alpha=1, \beta=5, \rho=0.5$	424.250	423.741

OSNOVNA ANALIZA


Standardni odklon dolžine poti




Povprečno število vej vozlišč



OSNOVNA ANALIZA




Optimalna dolžina poti



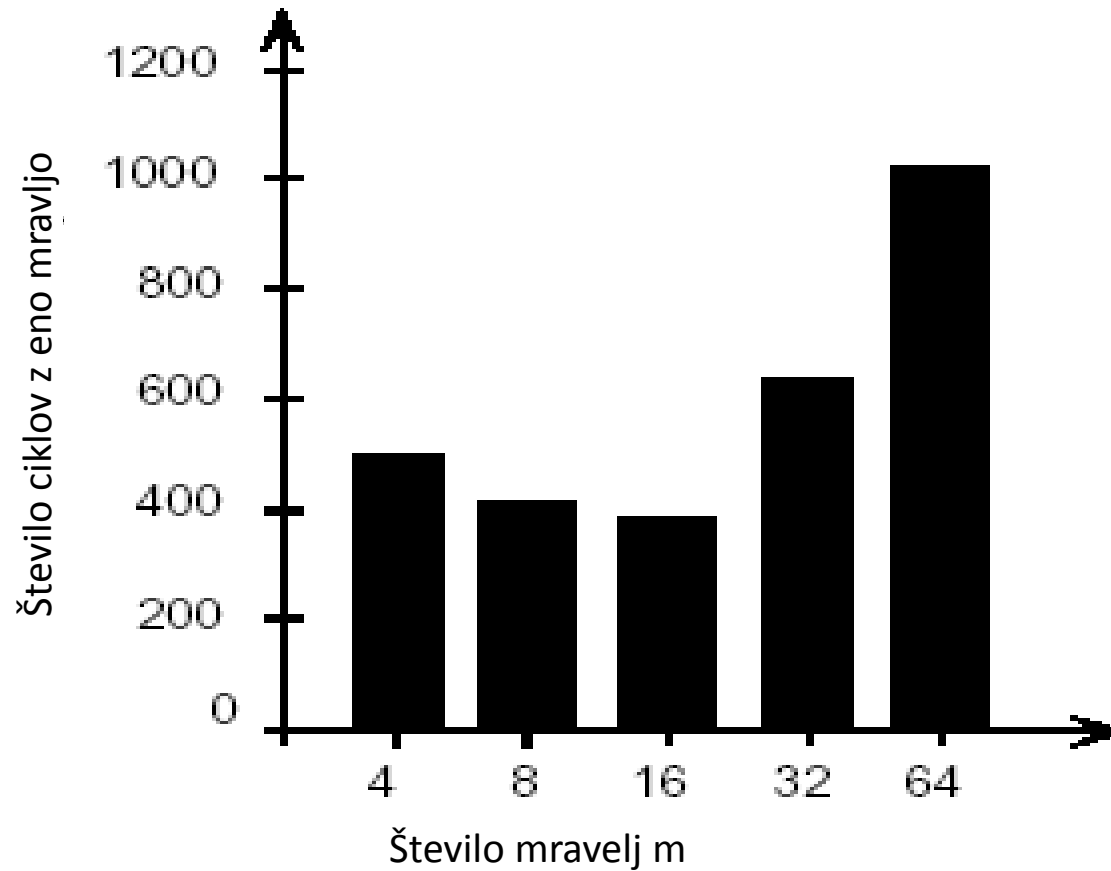
a) $\alpha=0$

Optimalna dolžina poti



b) $\alpha=1$

OPTIMALNO ŠTEVILO MRAVELJ ZA SISTEM MRAVELJ (AS)



VSESTRANSKOST

Enostavna uporaba ATSP

Brez sprememb osnovnega algoritma

NEKATERE POVEZANE PREDNOSTI

S pozitivno povratno vezavo je mogoče hitro iskanje dobrih rešitev

Porazdeljeno računanje preprečuje prezgodnjo konvergenco

S “pohlepno” hevristiko lahko najdemo sprejemljive rešitve že v zgodnji fazi iskanja.

Kolektivna interakcija populacije agentov.

SLABOSTI SISTEMA MRABELJ

Počasnejša konvergenca kot pri drugih hevrističnih metodah

Slabša zmogljivost na TSP problemih z več kot 75 mesti

Brez centralnega procesorja za pridobivanje rešitev v sistemu mravelj

NADGRADNJE SISTEMA MRVELJ

Pritajena (daemon) vpeljava centraliziranih opravil

- Lokalni optimizacijski postopki

- Uravnavanje iskalnega procesa z globalnimi informacijami

NADGRADNJE SISTEMA MRABELJ

Elitistična strategija

$$\Delta\tau_{ij}^{gb}(t) = \begin{cases} e / L^{gb}(t) & \text{if arc}(i, j) \in T^{gb} \\ 0 & \text{otherwise} \end{cases}$$

- AS_{rank}

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

NADGRADNJE SISTEMA MRABELJ

ACS

Močna elitistična strategija

Psevdo-naključno proporcionalno pravilo

z verjetnostjo q_0 :

$$j = \mathit{arg\ max}_{j \in N_i^k} \{ \tau_{ij}(t) \eta_{ij}^\beta \}$$

z verjetnostjo $(1 - q_0)$:

$$p_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}]^\beta}{\sum_{k \in \mathit{allowed}_k} [\tau_{ik}(t)]^\alpha [\eta_{ik}]^\beta} & \text{if } j \in \mathit{allowed}_k \\ 0 & \text{otherwise} \end{cases}$$

NADGRADNJE SISTEMA MRAVELJ

ACS (posodabljanje feromonov)

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

- Posodabljanje feromonske sledi med gradnjo rešitve
- Mravlje se prehranjujejo s feromoni na sledi
- Dodano lokalno iskanje pred posodobitvijo feromonov

NADGRADNJE SISTEMA MRAVELJ

MMAS

$$\tau_{min} \leq \tau_{ij} \leq \tau_{max}$$

- Visoka stopnja raziskovanja na začetku
- Samo najboljši lahko dodajajo feromone
- Občasna uporaba lokalnega iskanja za izboljšanje zmogljivosti

DINAMIČNI OPTIMIZACIJSKI PROBLEMI

ABC (vodovno komutirana omrežja)

AntNet (usmerjanje v paketnih omrežjih)

PRIMERI UPORABE

Problem trgovskega potnika (ang. Traveling Salesman Problem)

Problem kvadratne razporeditve

Modeliranje omrežij

Usmerjanje vozil

Problem trgovskega potnika (ang. Traveling Salesman Problem)

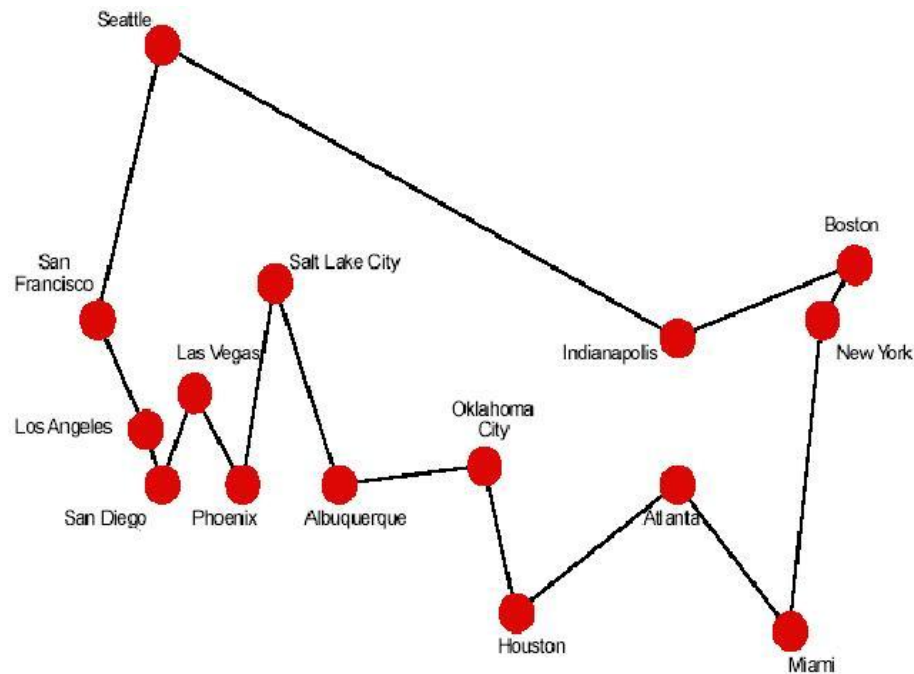
Problem kvadratne razporeditve

Problem trgovskega potnika (ang. Traveling Salesman Problem)

TSP PROBLEM : vzemimo N mest in funkcijo razdalje med mesti. Poišči pot, ki:

1. gre skozi vsa mesta samo enkrat
2. minimizira skupno razdaljo.

- problem je NP-zahteven
- klasična kombinacijska optimizacija za testS



ACO za Problem trgovskega potnika (TSP)



TSP je pomemben v kontekstu optimizacije s kolonijami mravelj, ker je bil pri njem prvič uporabljen sistem mravelj (AS) in je uporabljan kot merilo za preizkušanje novih idej in različic algoritmov.

TSP je izbran zaradi več razlogov:

- predstavlja prisodobo za kolonijo mravelj
- ker je eden največkrat preučevanih NP-težavnih problemov v kombinacijski optimizaciji
- ker ga je enostavno razložiti brez uporabe tehnikalij.


Iskalni prostor

Diskretni graf

Vsakemu vozlišču je prirejena *statična vrednost* kot rezultat hevristične funkcije $\eta(r,s)$ osnovane na strošku roba/poti

Vsi robovi grafa so označeni s feromonsko sledjo $\tau(r,s)$, ki so jo odložile mravlje.

Feromoni so dinamični naučeni so med izvajanjem




Sistem mravelj (AS)

Sistem mravelj za TSP

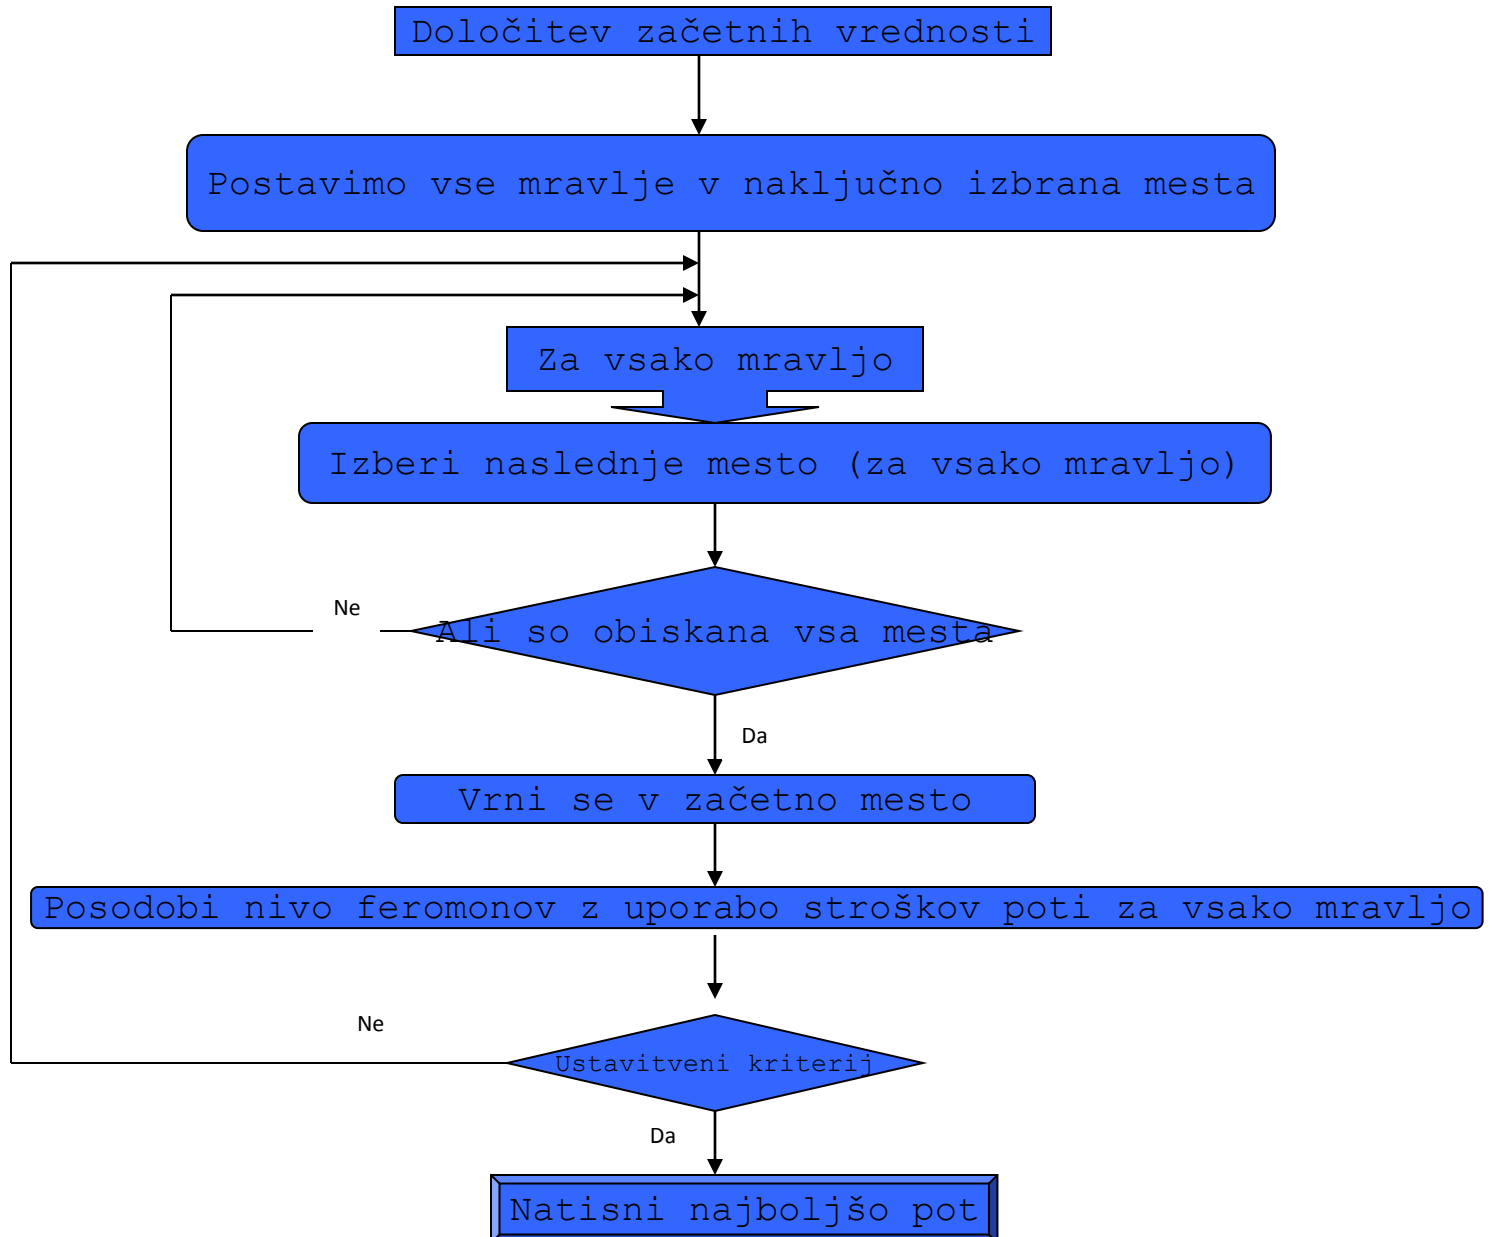
Graf (N,E): kjer je N = mesta/vozlišča, E = robovi

d_{ij} = strošek poti od mesta i do mesta j (utež roba)

Mravlje se premikajo od mesta i do naslednjega mesta j z neko prehodno verjetnostjo.



Algoritem sistema mravelj za TSP



Pravila za verjetnost prehoda

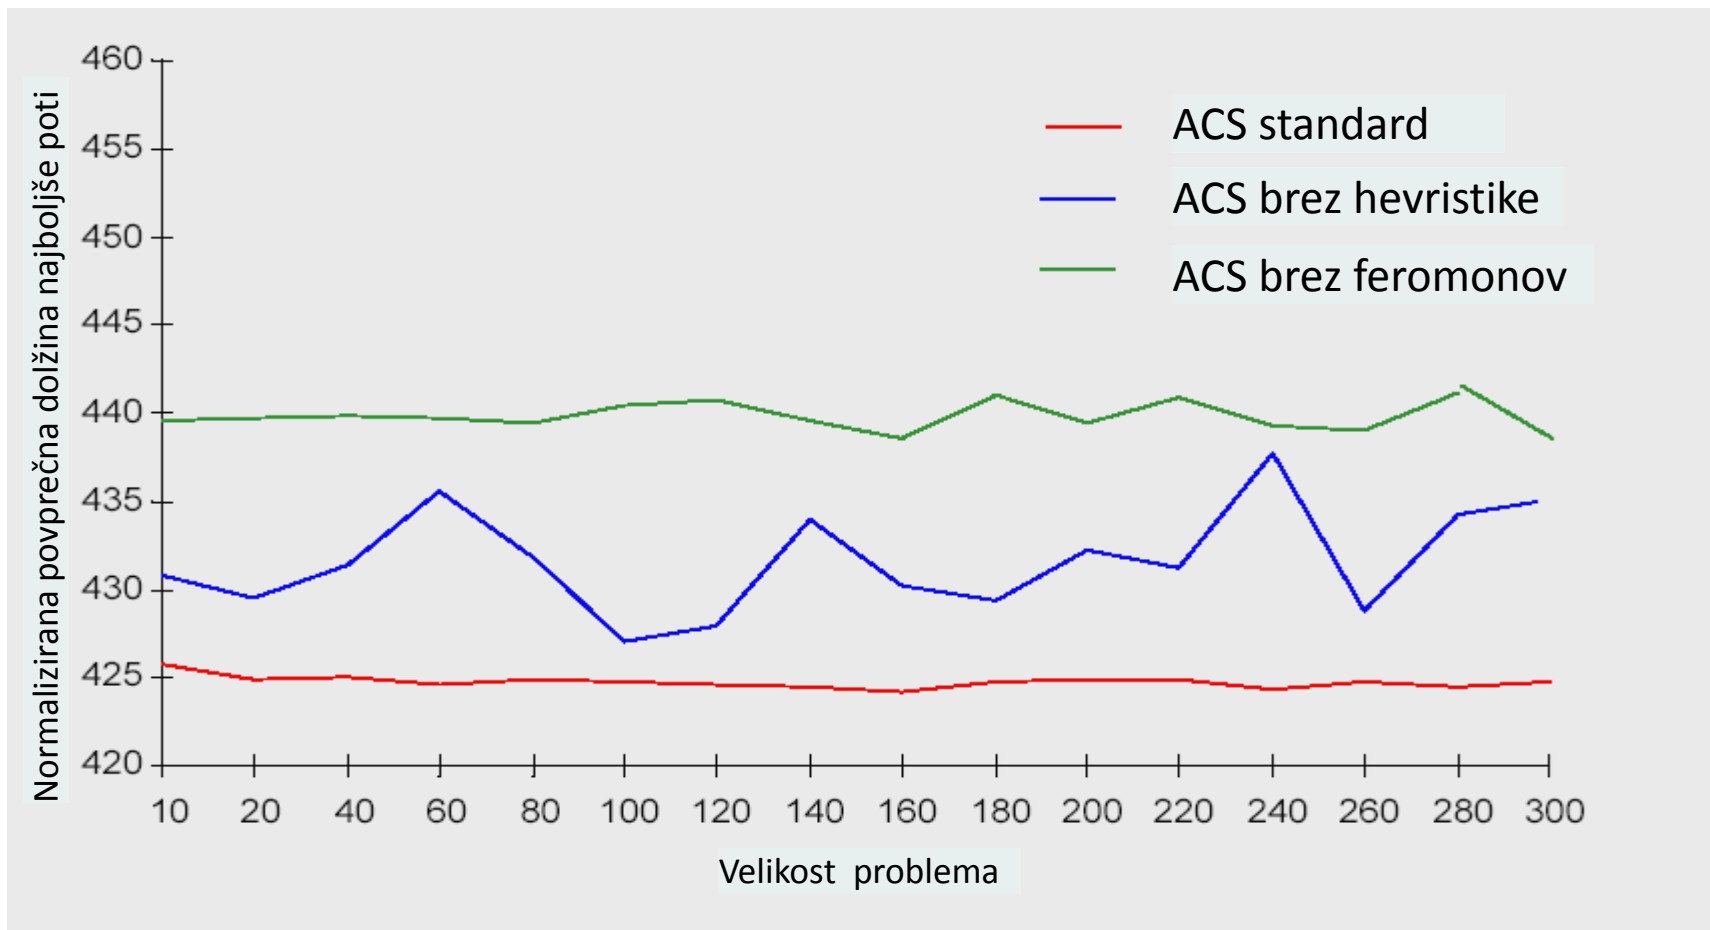
1. Odvisno od tega ali je bilo mesto obiskano ali ne
uporaba **spomina** (tabu seznam): J_i^k : vsa mesta, ki morajo biti obiskana
2. $N_{ij} = \frac{1}{d_{ij}}$ **vidnost**: hevristična zaželenost izbire mesta j , ko smo v mestu i .
3. **Feromonska sled**: $T_{ij}(t)$ globalni tip informacije

Verjetnost prehoda da bo mravlja k šla iz mesta i v mesto j na svoji poti.

$$P_{ij}^k(t) = \frac{[T_{ij}(t)]^a \cdot [n_{ij}]^\beta}{\sum_{l \in J_i^k} [T_{lk}(t)]^a \cdot [n_{lk}]^\beta}$$

$a = 0$: izbrana so najbližja mesta

Uporabnost feromonskih sledi v hevrističnih funkcijah



Primerjava med tremi različicami sistema kolonije mravelj (ACS): standardnim, brez hevristike in brez feromonov. Problem: Oliver30. Povprečen preko 30 poskusov, 10.000/ m iteracij na poskus.

Feromonska sled v AS

Po zaključku svoje poti, vsaka mravlja posodobi feromon

$\Delta T_{ij}^k(t)$ za vsak del poti, ki ga je uporabila. Feromon je odvisen od tega, kako dobro je mravlja opravila svoje delo.

$$\Delta T_{ij}^k(t) = \begin{cases} Q/l^k(t) & \text{if } (i, j) \in T^k(t) \\ 0 & \text{if } (i, j) \notin T^k(t) \end{cases}$$

$$\text{Razpad feromonske sledi} = T_{ij}(t) \leftarrow (1 - p)T_{ij}(t - 1) + \Delta T_{ij}(t)$$

Optimizacija s kolonijami mravelj (ACO)

Dorigo & Gambardella sta vpeljala štiri spremembe v AS (sistem mravelj):

1. Drugačno pravilo prehoda,
2. Lokalne/globalne posodobitve feromonskih sledi,
3. Uporaba lokalnih posodobitev feromonskih sledi za spodbujanje raziskovanja
4. Seznam kandidatov za omejevanje izbora naslednjega mesta za obisk.

ACS : Sistem kolonije mravelj za problem TSP

Zanka

Naključno razporedi m mravelj v n mest

For mesto = 1:n

For mravlja = 1:m

{Vsaka mravlja sestavi rešitev/pot z nizanem obiskov mest}

Izberi glede na verjetnost naslednje mesto glede na mehanizem raziskovanja in izkoriščanja

Uporabi pravilo **lokalnega posodabljanja poti**

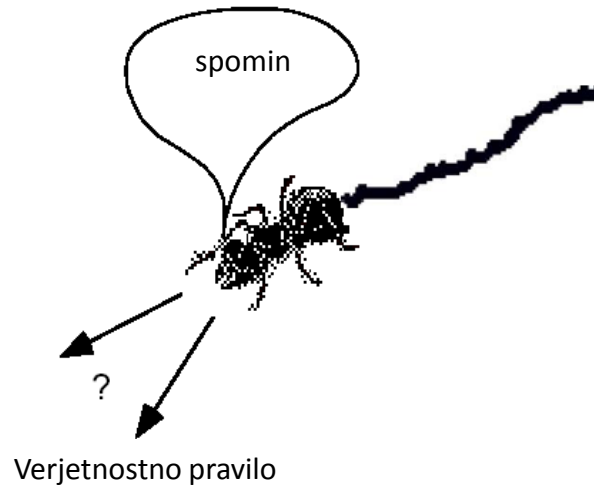
End for

End for

Uporabi pravilo **globalnega posodabljanja poti** z uporabo **najboljše mravlje**

Dokler ustavitveni pogoj

ACO pravilo prehajanja med stanji



Naslednje mesto je izbrano med **neobiskanimi** mesti po *verjetnostnem* pravilu

Izkoriščanje (exploitation): izbrana je najboljša pot

Raziskovanje (exploration): vsaka pot sorazmerno glede na njeno vrednost

Enačbe pravila prehajanja stanj v sistemu kolonij mravelj (ACS)

$$s = \begin{cases} \arg \max_{u \in J_k(r)} \left\{ [\tau(r, u)] \cdot [\eta(r, u)]^\beta \right\} & \text{if } q \leq q_0 & \text{Izkoriščanje} \\ S & \text{drugače} & \text{Raziskovanje} \end{cases}$$

Kjer velja

- **S** je naključna spremenljivka s porazdelitvijo

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

- τ ie sled/pot
- η je inverzna vrednost razdalje
- $J_k(r)$ je zbirka mest, ki jih mora mravlja **k** pozicionirana v mestu **r** še obiskati
- β in q_0 sta parametra


Pravilo prehajanja stanj v ACS: primer

$$\tau(A, B) = 150 \quad \eta(A, B) = 1/10$$

$$\tau(A, B) = 35 \quad \eta(A, B) = 1/7$$

$$\tau(A, B) = 90 \quad \eta(A, B) = 1/15$$

- z verjetnostjo q_0 **izkoriščanje**
(pot AB = 15)
- z verjetnostjo $(1 - q_0)$ **raziskovanje**
 - AB z verjetnostjo 15/26
 - AC z verjetnostjo 5/26
 - AD z verjetnostjo 6/26



Lokalno posodabljanje sledi v ACS

... podobno izhlapevanju

Če mravlja obiše vozlišče (r,s)

$$\tau(r,s) = (1-\rho) \cdot \tau(r,s) + \rho \Delta\tau(r,s)$$

$$\Delta\tau(r,s) = \tau_0$$

Globalno posodabljanje sledi v ACS

Na koncu vsake iteracije lahko najboljša mravlja posodobi rešitev z dodatnimi feromoni obratno sorazmerno z dolžino poti.

$$\tau(r,s) \leftarrow (1-\alpha) \cdot \tau(r,s) + \alpha \cdot \Delta\tau(r,s)_{Global}$$

$$\Delta\tau(r,s)_{Global} = \frac{1}{L_{best}}$$

Učinek lokalnega pravila

- ➡ Lokalno pravilo: naučena zaželenost povezav se dinamično spreminja
- ➡ Pravilo lokalnega posodabljanja zmanjšuje feromon povezave.
- ➡ Obiskane povezave so z obiskovanjem različnih mravelj vse manj zanimive.
- ➡ Daje prednost raziskovanju še ne obiskanih povezav. To pripomore k mešanju mest tako, da so mesta, ki jih je neka mravlja obiskala na začetku svoje poti, obiskana s strani druge mravlje proti koncu njene poti.

ACO vs AS

Posodabljanje feromonske sledi

V AS posodobitev feromonov po opravljeni poti

V ACO je samo ena globalna posodobitev, ki jo lahko opravi mravlja, ki je ustvarila najboljšo pot v poskusu.

V AS je posodobitev sledi uporabljena za vse povezave.

V ACO je globalna posodobitev poti uporabljena zgolj za najboljšo pot posameznega poskusa.

ACO : seznam kandidatov

Uporaba seznama kandidatov

Seznam priljubljenih mest za obisk: namesto pregledovanja celotnega seznama mest se najprej obravnava neobiskana mesta.


Mesta so razvrščena z naraščajočo razdaljo, seznam se pregleduje sekvenčno.

- Naslednje mesto se izbere s seznama kandidatov.
- Druga mesta se upoštevajo, če so že bila obiskana vsa mesta s seznama.

Zmogljivost

- Algoritem najde najboljšo rešitev za majhne probleme (75 mest)
- Pri večjih problemih je tudi našel rešitev, vendar pa ne najboljših
- Pri “statičnih” problemih, npr. TSP, je težko premagljivi specializirani algoritmi.
- Mravlje so “dinamični” iskalci optimumov – ali je sploh smiselno pričakovati dobre rezultate pri statičnih problemih?
- Združevanje mravelj z lokalnimi optimizatorji je vrnilo najboljše rezultate

PROBLEM KVADRATIČNEGA DODELJEVANJA (QUADRATIC ASSIGNMENT PROBLEM QAP)



Problem:

Dodeli n opravil n lokacijam (npr. načrt naselja, trgovskega centra).

$D = [d_{i,j}]_{n,n}$, $d_{i,j}$ je razdalja med lokacijama i in j

$F = [f_{h,k}]_{n,n}$, $f_{i,j}$, prehod od opravila h k opravilu k

Dodelitev je permutacija Π


Minimizacija:

$$C(\pi) = \sum_{i,j=1}^n d_{ij} f_{\pi(i)\pi(j)}$$

- NP zahtevno

QAP primer


Lokacije




Objekti

Najveći pretok: A - B

Kako dodeliti objekte lokacijam?



Višji strošek



Nižji strošek

Poenostavljeni CRAFT (QAP)



Poenostavitev Predpostavimo, da so vsi oddelki enako veliki

Zapis $d_{i,j}$ razdalja med **lokacijama** i in j

$f_{k,h}$ potovalna frekvenca med **oddelkoma** k in h

$X_{i,k} \begin{cases} 1 & \text{if department } k \text{ is assigned to location } i \\ 0 & \text{otherwise} \end{cases}$

Primer



Lokacija



Oddelek („Objekt“)

Razdalja* $d_{i,j}$

	1	2	3	4
1	-	1	1	2
2	1	-	2	1
3	1	2	-	1
4	2	1	1	-

Frekvenca* $f_{k,h}$

	1	2	3	4
1	-	1	3	2
2	2	-	0	1
3	1	4	-	0
4	3	1	1	-

Sistem mravelj (AS-QAP)

Konstruktivna metoda:

Korak 1: izberi objekt j

Korak 2: dodeli ga lokaciji i

Lastnosti:

- vsaka mravlja pusti sled (feromon) na izbranem paru (i,j)
- dodelitev je odvisna od verjetnosti (funkcija feromonske sledi in hevristične informacije)
- že obstoječe kombinacije objektov in lokacij so prepovedane (Tabu seznam)

AS-QAP Hevristična informacija

Razdalja in potenciali pretoka

$$D_{ij} = \begin{bmatrix} 0 & 1 & 2 & 3 \\ 1 & 0 & 4 & 5 \\ 2 & 4 & 0 & 6 \\ 3 & 5 & 6 & 0 \end{bmatrix} \Rightarrow D_i = \begin{bmatrix} 6 \\ 10 \\ 12 \\ 14 \end{bmatrix} \quad F_{ij} = \begin{bmatrix} 0 & 60 & 50 & 10 \\ 60 & 0 & 30 & 20 \\ 50 & 30 & 0 & 50 \\ 10 & 20 & 50 & 0 \end{bmatrix} \Rightarrow F_i = \begin{bmatrix} 120 \\ 110 \\ 130 \\ 80 \end{bmatrix}$$

Sklopna matrika:

$$S = \begin{bmatrix} 720 & 1200 & 1440 & 1680 \\ 660 & 1100 & 1320 & 1540 \\ 780 & 1300 & 1560 & 1820 \\ 480 & 800 & 960 & 1120 \end{bmatrix} \quad \begin{aligned} s_{11} &= f_1 \cdot d_1 = 720 \\ s_{34} &= f_3 \cdot d_4 = 960 \end{aligned}$$

Mravlje izberejo lokacijo glede na hevristično zaželenost “potencialna dobrota”

$$\zeta_{ij} = \frac{1}{s_{ij}}$$

AS-QAP Določitev rešitve

- objekti so razvrščeni glede na padajoče potenciale pretoka
- Mravlja k dodeli objekt i lokaciji j z verjetnostjo:

$$p_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}]^\beta}{\sum_{l \in N_i^k} [\tau_{il}(t)]^\alpha [\eta_{il}]^\beta} & \text{if } j \in N_i^k \end{cases}$$

Kjer je N_i^k dosegljiva sosesčina vozlišča i

✧ Ko mravlja k dodeli objekt j lokaciji i označi s feromonom par (i,j)

➤ Proces se ponavlja dokler ni dodeljevanje končano

AS-QAP posodabljanje feromonov

➤ posodobitev feromonske sledi za vse pare:

$$\tau_{ij}(t+1) = \rho \cdot \tau_{ij}(t) + \sum_{k=1}^m \Delta \tau_{ij}^k$$

$\Delta \tau_{ij}^k$ Sprememba feromona za par (i,j) , ki jo napravi mravlja k

$$\Delta_{ij}^k = \begin{cases} \frac{Q}{J_{\psi}^k} & \text{če je objekt } i \text{ dodeljen lokaciji } j \text{ v rešitvi mravlje } k \\ 0 & \text{drugače} \end{cases}$$



J_{ψ}^k ...vrednost ciljne funkcije



Q...količina oddanega feromona mravlje k

Hibridni sistem mravelj za QAP

- Rezultat konstruktivnih algoritmov so pogosto nekvalitetne rešitve v primerjavi z lokalnimi iskalnimi algoritmi.
- S ponavljanjem lokalnih iskanj iz naključnih začetnih rešitev predstavlja za večino problemov precejšnjo razliko do optimalne rešitve.
- Hibridni algoritmi, ki kombinirajo iskanje rešitev s sistemi mravelj in z lokalnimi iskalnimi algoritmi, so precej bolj zmogljivi in nudijo boljše rešitve.

Hibridni sistem mravelj za QAP (HAS-QAP)

- HAS-QAP uporablja feromonske sledi na nestandarden način uporabljen za spreminjanje trenutne rešitve,
- rešitev sistema mravelj se izboljša z lokalnim iskanjem optimuma.
- Mehanizmi stopnjevanja in raznolikosti.

Hibridni sistem mravelj za QAP (HAS-QAP)

Ustvari m začetnih rešitev za vsako mravljo posebej

Inicializiraj feromonsko sled

For I_{max} iteracij ponovi

For $k = 1:m$ do

Spremeni mravlja $k;s$ rešitev z uporabo feromonske sledi

Uporabi **lokalno iskanje za** spremenjeno rešitev

nova začetna rešitev za mravljo k z uporabo mehanizma **stopnjevanja**

End For

Posodobi feromonsko sled

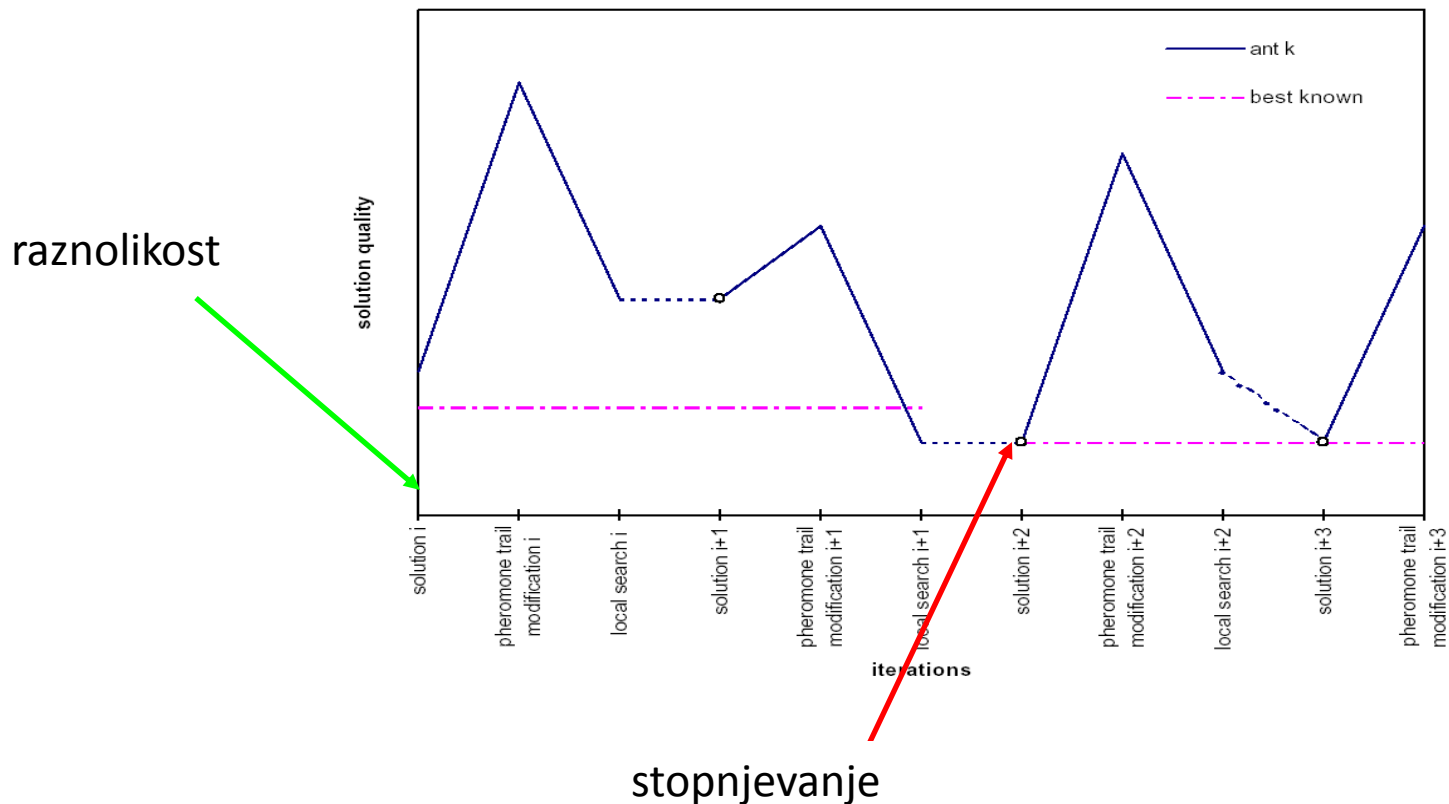
Uporabi mehanizem **raznolikosti**

End For

HAS-QAP mehanizmi stopnjevanja in raznolikosti

➤Mehanizem stopnjevanja se uporabi, kadar je najboljša rešitev najdena z lokalnim iskanjem izboljšana

➤Mehanizem raznolikosti se uporabi, kadar v zadnjih S iteracijah ni bilo izboljšave najboljše rešitve.



Zmogljivost HAS-QAP algoritmov

- Primerjave z najboljšimi QAP algoritmi so pokazale, da so HAS-QAP algoritmi med najboljšimi pri reševanju realnih in strukturiranih problemov.
- Edini resni tekmeč je genetski hibridni algoritem.
- Za naključne, nestrukturirane probleme je zmogljivost HAS-QAP algoritmov manj konkurenčna in za te probleme so tabu iskanja še vedno najboljši algoritmi.
- Do sedaj so bili za optimizacijo s kolonijami mravelj najbolj zanimivi problemi omejeni na problem trgovskega potnika in problem kvadratičnega dodeljevanja.


Omrežno usmerjanje

Usmerjanje vozil

Zaključek

Usmerjanje v komunikacijskih omrežjih

Usmerjanje izvajajo usmerjevalniki, ki uporabljajo usmerjevalne tabele za usmerjanje paketov/podatkov.



Usmerjanje v komunikacijskih omrežjih

Problem

- **Dinamično usmerjanje**

v vsakem trenutku mora biti pot sporočila čim krajša.
(Promet in struktura omrežja se neprestano spreminjata)

- **Izravnavanje obremenitve**

Porazdelitev spremenljive obremenitve po sistemu in
minimizacija izgub.

USMERJANJE V KOMUNIKACIJSKIH OMREŽJIH

Cilj:

Minimizacija: izgubljeni klici z izogibanjem
zamašitvi ,

Minimizacija : dolžina poti

Problem dinamične optimizacije

+

Več ciljev optimizacijskega problema

USMERJANJE V KOMUNIKACIJSKIH OMREŽJIH

Tradicionalno:

“Centralni kontrolorji”

Slabost:

Communicacijska preobremenitev.

Toleranca napak ~ odpoved kontrolorja.

Skalabilnost

Dinamičnost ~ negotovost

Avtoriteta.

ALGORITEM I

Omrežje ima n vozlišč.

Vsako vozlišče ima svojo usmerjevalno tabelo (feromone tabelo) $\{R_i[n-1][k]\}$

Inicializacija: ravnovesje usmerjevalne tabele (vsa vozlišča imajo enako vrednost ali normalizirano naključno vrednost)

Vsako vozlišče ustvari $\{n-1\}$ mravelj (agentov), po eno za vsako destinacijo.

Vsaka mravlja izbere svoje naslednje vozlišče proporcionalno z dobroto usmerjevalne tabele vsakega sosednjega vozlišča.

Ob prihodu mravlje se usmerjevalna tabela vozlišča posodobi:

ALGORITEM I (NADALJ.)

Povečaj verjetnost obiskane povezave:

$$\rho = \frac{\rho_{old} + \Delta\rho}{1 + \Delta\rho}$$


Zmanjšaj verjetnost ostalih, neobiskanih povezav:

$$\rho = \frac{\rho_{old}}{1 + \Delta\rho}$$

$$\Delta\rho = f\left(\frac{1}{age}\right)$$

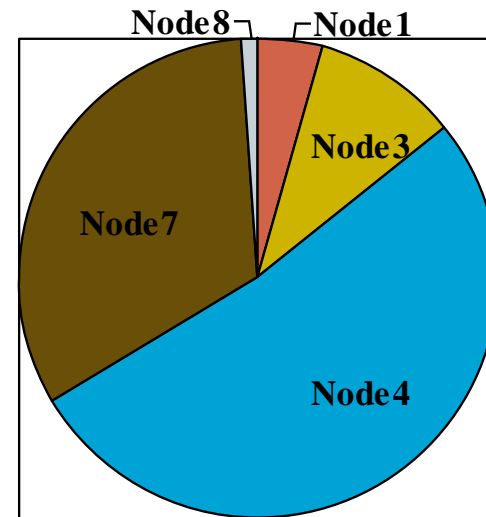
ALGORITEM I (NADALJ.)

Primer:



Feromonska tabela za vozlišče 6

	Next node				
	1	3	4	7	8
1	0.850	0.100	0.009	0.001	0.090
2	0.045	0.100	0.520	0.325	0.010
3	0.020	0.925	0.045	0.008	0.002
4	0.004	0.100	0.800	0.090	0.006
5	0.010	0.095	0.470	0.410	0.015
7	0.005	0.003	0.020	0.948	0.024
8	0.015	0.005	0.002	0.023	0.955



ALGORITEM I (NADALJ.)

Primer :

$$\rho = \frac{\rho_{old} + \Delta\rho}{1 + \Delta\rho}$$

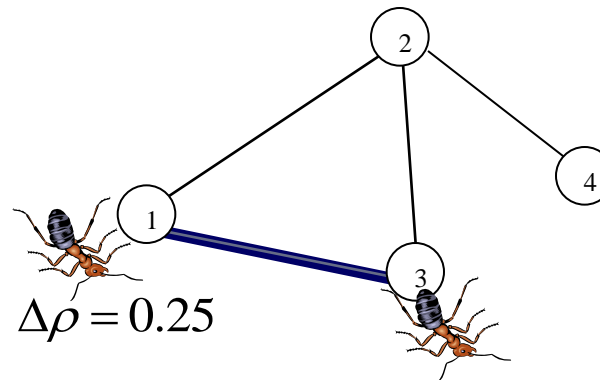
Usmerjevalna tabela za vozlišče 1

		Next node	
		2	3
Destination node	3	0.50	0.50
	2	0.50	0.50
	4	0.50	0.50



		Next node	
		2	3
Destination node	3	0.40	0.60
	2	0.50	0.50
	4	0.50	0.50

$$\rho = \frac{\rho_{old}}{1 + \Delta\rho}$$




ALGORITEM I (NADALJ.)


	Mean	Std. Dev.
Brez uravnavanja obremenitve	12.53%	2.04%
Mobilni agent	4.41%	0.85%
Mravlje	2.72%	1.24%

Srednje vrednosti (po 10 poskusov) in standardni odkloni za izgubljene klice v odstotkih

ALGORITEM II



F-Mravlje merijo tudi kvaliteto poti (št. vozlišč, statistika vozlišč)



ZELO DOBRI REZULTATI, vendar pa je potrebnih več omrežnih virov.

PROBLEM USMERJANJA VOZIL S ČASOVNIMI OKNI (VEHICLE ROUTING PROBLEM WITH TIME WINDOWS – VRPTW)

K vozil mora obiskati N strank

Podani podatki

Skladišča (številka, lokacija)

Vozila (kapaciteta, stroški, čas do odhoda, čas na cesti,...)

Stranke (zahteve, okna, prioritete,...)

Podatki o poti (najdaljši čas ali razdalja poti, stroški poti)

PROBLEM USMERJANJA VOZIL S ČASOVNIMI OKNI

Ciljne funkcije za minimizacijo

Skupna razdalja potovanja

Skupni čas potovanja

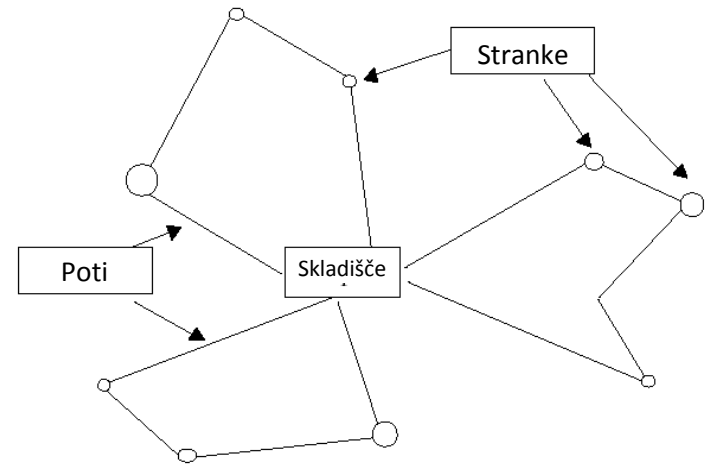
Število vozil

Glede na :

Vozila (število, kapaciteta, čas na poti, dolžina potovanja)

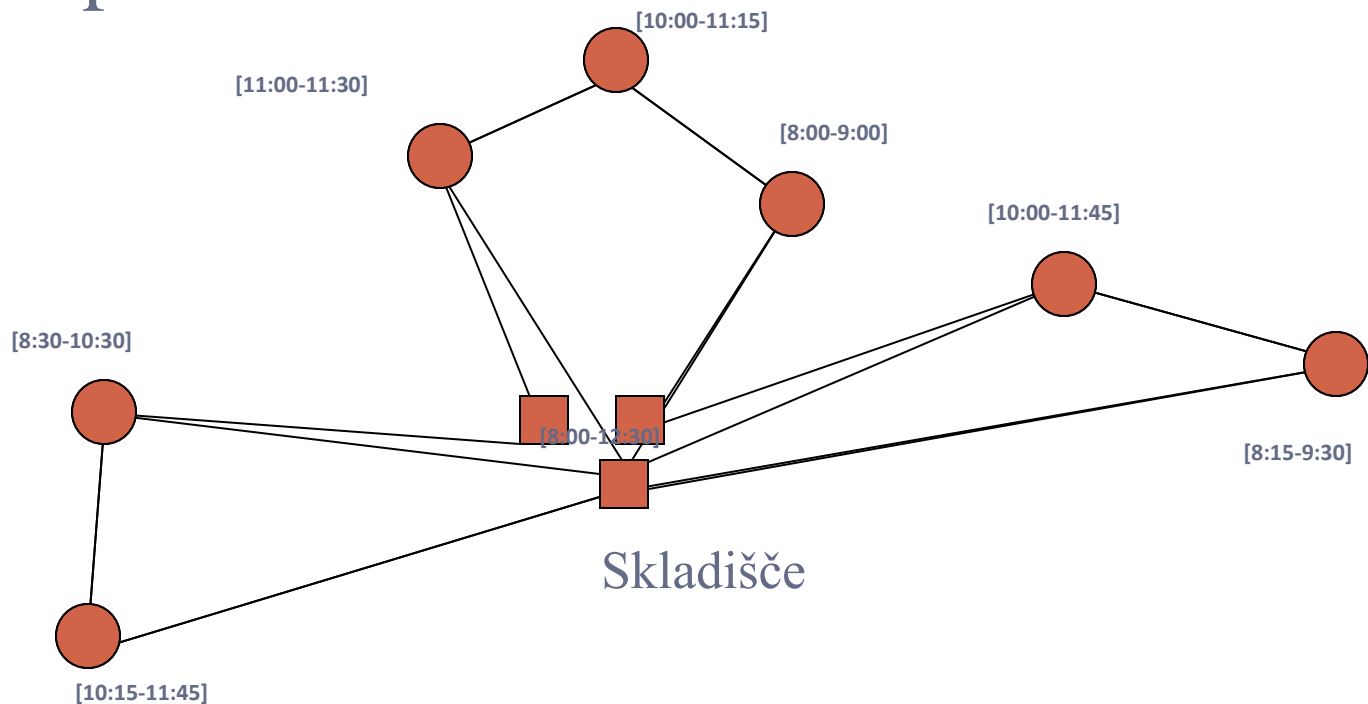
Skladišča (Število)

Stranke (zahteve, časovna okna)



PROBLEM USMERJANJA VOZIL S ČASOVNIMI OKNI

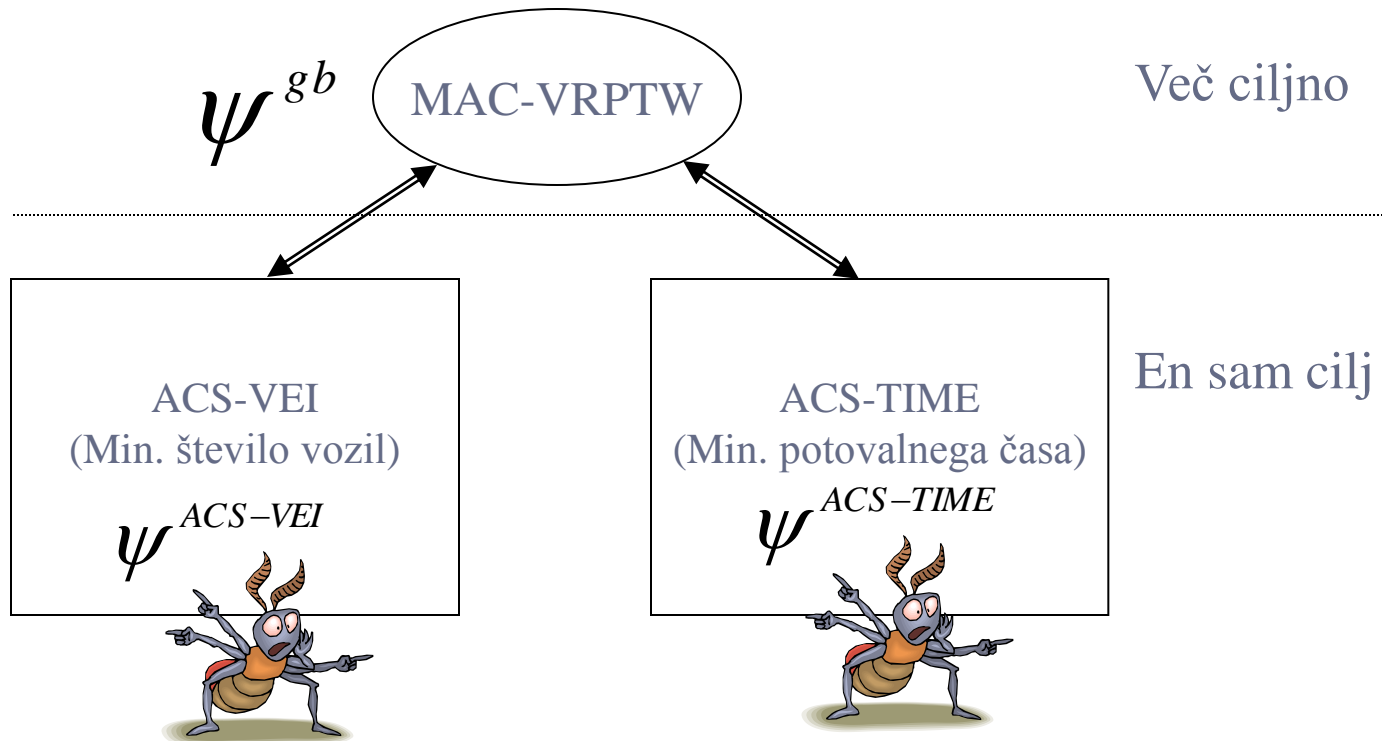
Odnos/podobnost s TSP?!



Problem usmerjanja vozil (VRP) - “preprosti algoritem”

- Mravlje postavimo v skladišča (št. skladišč = št. vozil).
- Verjetnostna izbira
 - ~ $(1/\text{razdalja}, d_i, Q)$
 - ~ količina feromona
- Če vse neobiskane stranke vodijo k neizvedljivim rešitvam:
 - Izberi skladišče kot naslednjo stranko.
- Izboljšanje z lokalnim iskanjem.
- Samo najboljše mravlje lahko posodablajo feromonsko sled.

VEČKRATNI ACS ZA VRPTW



VZPOREDNA IMPLEMENTACIJA

Vzporednost (paralelizem) na nivoju mravelj.

Mravlje delajo vzporedno za iskanje rešitev.

Vzporednost (paralelizem) na nivoju podatkov.

Mravlje delajo vzporedno na manjših problemih.

Funkcionalna vzporednost.

Generiranje_mravelj()

Hlapienje_feromonov()

Pritajene_aktivnosti()



Podobnosti z drugimi optimizacijskimi tehnikami

Populacije, elitizem	~	GA	
Verjetnost, naključnost	~	GRASP	
Konstruktivnost	~	GRASP	
Hevristične informacije, spomin		~	TS

Načrtovalske izbire

Število mravelj.

Ravnovesje med raziskovanjem in izkoriščanjem

Kombiniranje z drugimi hevrističnimi tehnikami

Kdaj se zgodi posodobitev feromonov?

Katere mravlje lahko posodobijo feromone?

Ustavitveni kriteriji

Trenutni projekti

DYVO: ACO za usmerjanje vozil

MOSCA: Dinamično in časovno odvisno
usmerjanje vozil (VRP)

Ant@ptima: raziskovalna uporaba



MOSCA

The spin-off company of Mosca


Ant@ptima
we speed up your business



The Spin-Off company: AntOptima

Ant@ptima

we speed up your business



Zaključek

ACO je nedavno predlagani metahevristični pristop k reševanju zahtevnih kombinatornih optimizacijskih problemov.

Z mravljami je možna implementacija naključne hevrisitke za verjetnostne odločitve.

Skupna iskalna izkušnja se upošteva s prilagajanjem feromonske sledi.

ACO je visoko zmogljiva za probleme nepravilnih struktur kot npr. omrežno usmerjanje.

V ACO je za pridobitev dobrih rezultatov izredno pomembno lokalno iskanje.

Literatura

Dorigo M. and G. Di Caro (1999). **The Ant Colony Optimization Meta-Heuristic**. In D. Corne, M. Dorigo and F. Glover, editors, *New Ideas in Optimization*, McGraw-Hill, 11-32.

M. Dorigo and L. M. Gambardella. Ant colonies for the traveling salesman problem. *BioSystems*, 43:73–81, 1997.

M. Dorigo and L. M. Gambardella. Ant Colony System: A cooperative learning approach to the traveling salesman problem. *IEEE Transactions on Evolutionary Computation*, 1(1):53–66, 1997.

G. Di Caro and M. Dorigo. Mobile agents for adaptive routing. In H. El-Rewini, editor, *Proceedings of the 31st International Conference on System Sciences (HICSS-31)*, pages 74–83. IEEE Computer Society Press, Los Alamitos, CA, 1998.

M. Dorigo, V. Maniezzo, and A. Coloni. The Ant System: An autocatalytic optimizing process. Technical Report 91-016 Revised, Dipartimento di Elettronica, Politecnico di Milano, Italy, 1991.

L. M. Gambardella, E. D. Taillard, and G. Agazzi. MACS-VRPTW: A multiple ant colony system for vehicle routing problems with time windows. In D. Corne, M. Dorigo, and F. Glover, editors, *New Ideas in Optimization*, pages 63–76. McGraw Hill, London, UK, 1999.

L. M. Gambardella, E. D. Taillard, and M. Dorigo. Ant colonies for the quadratic assignment problem. *Journal of the Operational Research Society*, 50(2):167–176, 1999.

V. Maniezzo and A. Coloni. The Ant System applied to the quadratic assignment problem. *IEEE Transactions on Data and Knowledge Engineering*, 11(5):769–778, 1999.

Gambardella L. M., E. Taillard and M. Dorigo (1999). **Ant Colonies for the Quadratic Assignment Problem**. *Journal of the Operational Research Society*, 50:167-176.

