



### Zmena počtu mravcov



### Zmeny vytvárania koreňa grafu

- Náhodné vytvorenie
- Turnaj
- Horolezecký algoritmus
- Mutácie

### Zmeny rozmiestnenia mravcov

- Pozdĺž globálne najlepšej trasy
- Pozdĺž iteratívne najlepšej trasy
- Turnajový výber z celého grafu
- Využívanie počtu stagnácií na výber rozmiestnenia

### Zmeny výpočtu fitness funkcie

- Penalizácia
- Zvýšenie váhy počtu krokov

$$Fitness(FSM_t) = \begin{cases} n_{aprove} + \gamma_1 \frac{n_{max} - n_{traj} - 1}{n_{max} - n_{traj} - 1}, & n_{max} > n_{traj} \\ n_{aprove} + (\gamma_1 + \gamma_2) \frac{n_{max} - n_{traj} - 1}{n_{max} - n_{traj} - 1}, & n_{max} \leq n_{traj} \end{cases}$$

### Porovnanie s inými algoritmami

	Typ algoritmu	Dosiahnutie 100000 ohodnotení (%)	Priemer fitness ohodnotení
1	Pôvodný algoritmus	6	24633
2	MuACOsm	n/a	9200
3	Mutation based ACO	n/a	10500
4	MRTS, GP + Subroutines	n/a	43000
5	MRTS, Random Search + Subroutines	n/a	20696
6	<b>Mnou dosiahnuté výsledky</b>	<b>0</b>	<b>8747</b>

### Zmena stratégie riadenia mravcov

- Každý mravec v jednej iterácii vytvárania cesty vykoná jeden krok
- Po vytvorení cesty jedným mravcom začne cestu vytvárať ďalší mravec.

### Zmena výberu nasledujúcej hrany

$$p_{uv} = \frac{\tau_{uv}^\alpha * n_{uv}^\beta}{\sum_{w \in N_u} \tau_{uw}^\alpha * n_{uw}^\beta}$$

- Surčitou pravdepodobnosťou použitý:
- Elitizmus- výber najlepšej hrany
- Náhodný výber
- Turnaj

### Pridanie heuristickej informácie

$$\eta_{ij} = \max(\eta_{min}, f(i) - f(j))$$


### Zmeny pravdepodobnosti $P_{new}$

- Pravdepodobnosť vytvorenia nových hrán mutáciou: 40% 50% 60% 70%

- Celkovo navrhnutých 10 zmien stratégií
- Program má viac ako 30 parametrov, ktoré je možné používateľom zmeniť
- Celkovo otestovaných 55 rôznych stratégií pre dané zmeny
- Celkové zlepšenie o 64,5%
- Pri každej navrhnutej zmene sa našli stratégie, ktoré dosiahli lepšie výsledky ako pôvodný algoritmus

### Zmeny veľkosti $N_{stags}$ (počtu stagnácií)

Zisťovanie vhodného počtu na základe histogramu



### Zmeny typu aktualizácie feromónových hodnôt


- EAS  $\tau_{ij} = (1 - \rho)\tau_{ij} + \sum_{k \in N_{ants}} \Delta \tau_{ij}^k + w_{elit} * \Delta \tau_{ij}^{best}$
- SACO  $\tau_{ij}(t+1) = \tau_{ij}(t) + \sum_{k \in N_{ants}} \Delta \tau_{ij}^k(t)$
- AS Ant cycle  $\tau_{ij}(t+1) = \tau_{ij}(t) + \Delta \tau_{ij}(t)$   
 $\Delta \tau_{ij}^k(t) = \begin{cases} \frac{f(x^k(t))}{Q} & \text{ak sa hrana } (i,j) \in x^k(t) \\ 0 & \text{inak} \end{cases}$
- ACS (global)  $\tau_{ij}(t+1) = (1 - \rho_1)\tau_{ij}(t) + \rho_1 \Delta \tau_{ij}(t)$
- ACS (iterative)  $\Delta \tau_{ij}^k(t) = \begin{cases} \frac{Q}{f(x^k(t))} & \text{ak } (i,j) \in x^k(t) \\ 0 & \text{inak} \end{cases}$
- MMAS – Podobne ako ACS no so zvyšujúcou sa pravdepodobnosťou sa iteratívne mení na global.
- ANTABU  $\tau_{ij}(t+1) = (1 - \rho)\tau_{ij}(t) + \left(\frac{\rho}{f(\bar{x}(t))}\right) \left(\frac{f(x^*(t)) - f(\bar{x}(t))}{f(\bar{x}(t))}\right)$

- Riešenie pozostáva z dvoch častí:
- Celkový návrh vylepšenia algoritmu
- Pozorovanie vplyvu jednotlivých zmien, v rámci ktorých bolo testovaných 55 rôznych stratégií


### Rozdiely oproti klasickému ACO algoritmu

- Reprezentácia stavového priestoru: Kompletne riešenie (konečno-stavový automat (FSM)) predstavujú uzly grafu (v klasickom ACO je uzol komponent riešenia). Hrany v grafe predstavujú malú zmenu v štruktúre FSM (mutáciu).
- Konštrukcia grafu: Na začiatku vytvorené jedno iniciálne riešenie. Nové uzly sa vytvárajú mutáciami alebo sa stochasticky vyberá nasledovník. Dôvod je, že samotný graf by pre 7-stavový FSM obsahoval viac ako  $3 \cdot 10^{18}$  uzlov a v klasickom ACO sa generujú všetky vrcholy na začiatku pri inicializácii.

### Príklad výsledného FSM




### Diagram aktivít algoritmu



Zmena stratégie	Dosiahnutie 100000 ohodnotení (%)	Priemer fitness ohodnotení	Percentuálne zlepšenie počtu fitness ohodnotení	Zníženie počtu ohodnotení nad 100000
1 Pôvodný algoritmus	6	24633	-	-
2 <b>Zmena výpočtu fitness</b>	<b>0</b>	<b>14334</b>	<b>41,8%</b>	<b>6</b>
3 Zmena $N_{stags}$	2	19096	22,5%	4
4 Zmena pravdepodobnosti $P_{new}$	5	19512	20,8%	1
5 Zmena aktualizácie feromónových hodnôt	5	19760	19,8%	1
6 Zmena rozmiestnenia v grafe	3	21431	13%	3
7 Zmena výberu nasledujúcej hrany	6	22091	10,3%	0
8 Pridanie heuristickej informácie	5	23310	5,4%	1
9 Zmena počtu mravcov	5	24172	1,9%	1
10 Zmena vytvorenia koreňa grafu	2	24256	1,5%	4

### Testovaný problém: Santa Fe Trail



Daný algoritmus sa dá aplikovať na riešenie širokej škály problémov. Ak pre daný problém, vyjadrený konečno-stavovým automatom (FSM) vieme definovať účelovú funkciu, vieme daný FSM aj učiť. Návrhy jednotlivých zmien sa dajú aplikovať aj na iné optimalizačné algoritmy a dá sa predpokladať, že zmenou týchto stratégií by došlo aj k zlepšeniu výsledkov týchto algoritmov.