

Diferencialni pristop s stigmergijo mravelj k optimizaciji v zveznem prostoru

Peter Korošec^{1,2}, Jurij Šilc¹

¹ Institut "Jožef Stefan", Odsek za računalniške sisteme, Jamova cesta 39, SI-1000 Ljubljana, Slovenija

² Univerza na Primorskem, Fakulteta za matematiko, naravoslovje in informacijske tehnologije, Glagoljaška 8, SI-6000 Koper, Slovenija

E-pošta: peter.korosec@ijs.si

Povzetek. V prispcvku je predstavljena optimizacijska metoda s kolonijami mravelj za optimizacijo v zveznem prostoru. Predlagan je nov splošen optimizacijski algoritem, imenovan DASA (iz angl. Differential Ant-Stigmergy Algorithm), ki je primerjan z znanimi in uveljavljenimi evolucijskimi algoritmi za zvezno optimizacijo.

Ovrednotenje algoritma DASA, ki je narejeno na standardni množici preskusnih problemov, kaže na njegovo primernost in uporabnost pri reševanju težkih optimizacijskih problemov v zveznem prostoru.

Ključne besede: stigmergija, optimiziranje, zvezni prostor, preskusne funkcije

A Differential Ant-Stigmergy Approach to Continuous Optimization

Extended abstract. The paper presents an extension of the ant-colony optimization metaphor for continuous domain. This new approach was named a Differential Ant-Stigmergy Algorithm (DASA) and was studied on a set of benchmark suite of real-parameter optimization problems defined in 2005 at the IEEE Congress of Evolutionary Computation.

The algorithm was compared with a number of evolutionary optimization algorithms including Covariance Matrix Adaptation Evolutionary Strategy, Differential Evolution, Real-Coded Memetic Algorithm, and Continuous Estimation of Distribution Algorithm.

The result obtained indicates a promising performance of the new approach. One can notice that for a small number of function evaluations the DASA performs better than the rest of the algorithms. Since the selected test functions reflect a different kind of pseudo-real optimization problems, the DASA is applicable to many real-parameter optimization problems.

In future, the important issue of pure continuous ant-stigmergy algorithm needs to be solved. Here, the so-called parameter differences will be in a continuous form instead in the fine-grained discrete form.

Key words: stigmergija, optimizacija, kontinuirani prostor, benchmark funkcije

načinu komunikacije v koloniji mravelj, kjer so te vodene s sledjo feromonov. Pri sestavljanju rešitev se uporablja hevristika, temelječa na verjetnostnem pravilu, ki pravi, da je verjetnost neke odločitve določena z intenzivnostjo feromonov in dodatno hevristično informacijo. Slednja zajema znanje o reševanem problemu, ki je pridobljeno pred izvajanjem algoritma.

Algoritem ACO, ki je bil uspešno uporabljen na klasičnih NP-težkih kombinatoričnih optimizacijskih problemih, je bil v Elektrotehniškem vestniku že predstavljen [6,7,9]. Vendar pa neposredna uporaba algoritma ACO za reševanje optimizacijskih problemov z realnimi parametri ni preprosta. Do zdaj je bilo predlaganih le nekaj prilagoditev algoritma ACO za optimizacijo v zveznem prostoru [2,5,11,13].

V tem sestavku je predstavljen nov, diferencialni pristop s stigmergijo mravelj, ki je primeren za optimizacijo v zveznem prostoru.

2 Diferencialni pristop s stigmergijo mravelj

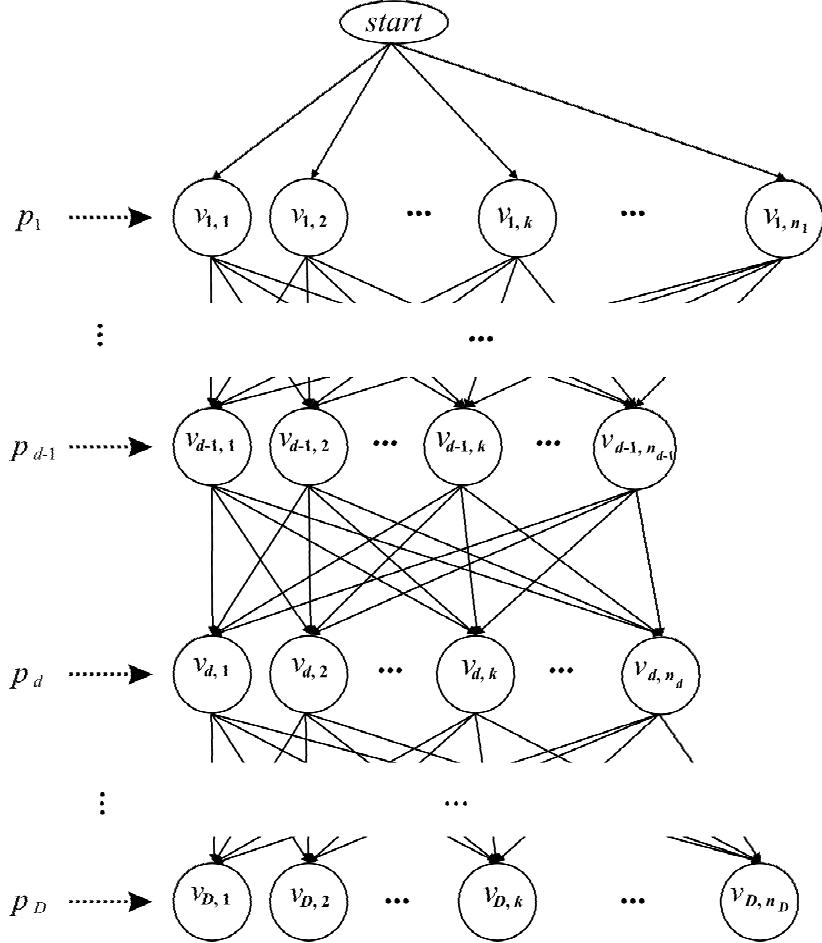
2.1 Diskretizacija zveznega prostora

Prevedba zvezne v drobnozrnatu diskretno obliko poteka na naslednji način. Naj bo p_i' trenutna vrednost i -tega parametra p_i . Med iskanjem njegove optimalne vrednosti se parametru p_i prireja nova vrednost takole:

$$p_i = p_i' + \delta_i. \quad (1)$$

1 Uvod

Marco Dorigo je v svoji doktorski disertaciji [4] predstavil zanimiv optimizacijski algoritem, imenovan optimizacija s kolonijami mravelj (ACO iz angl. *Ant-Colony Optimization*). Algoritem se zgleduje po posrednem



Slika 1. Predstavitev z diferencialnim grafom

Figure 1. Differential graph representation

Pri tem je δ_i t. i. *diferenca parametra* in je izbrana iz množice $\Delta_i = \Delta_i^- \cup \{0\} \cup \Delta_i^+$, kjer je

$$\Delta_i^- = \left\{ \delta_{i,k}^- \mid \delta_{i,k}^- = -b^{k+L_i-1}, k = 1, 2, \dots, d_i \right\}$$

in

$$\Delta_i^+ = \left\{ \delta_{i,k}^+ \mid \delta_{i,k}^+ = b^{k+L_i-1}, k = 1, 2, \dots, d_i \right\}.$$

Tu je $d_i = U_i - L_i + 1$. Za vsak parameter p_i je njegova diferenca δ_i iz intervala med b^{L_i} in b^{U_i} , kjer je b t. i. *baza diskretizacije*. Pri tem velja $L_i = \lfloor \log_b(\varepsilon_i) \rfloor$ in $U_i = \lfloor \log_b(\max(p_i) - \min(p_i)) \rfloor$. S konstanto ε_i je nastavljena največja natančnost parametra p_i , ki je omejena z računalniško aritmetiko s plavajočo vejico.

2.2 Preiskovalni graf

Iz množic Δ_i , $1 \leq i \leq D$ se zgradi t. i. *diferencialni graf* $\mathcal{G} = (V, E)$, kjer je V množica vozlišč, E množica povezav med njimi in D število parametrov (slika 1). Množica Δ_i je predstavljena z množico vozlišč

$V_i = \{v_{i,1}, \dots, v_{i,2d_i+1}\}$ in velja $V = \bigcup_{i=1}^D V_i$. Torej je predstavitev

$$\Delta_i = \underbrace{\left\{ \delta_{i,d_i}^-, \dots, \delta_{i,d_i-(j-1)}^-, \dots, \delta_{i,1}^- \right\}}_{\Delta_i^-}, 0, \underbrace{\left\{ \delta_{i,1}^+, \dots, \delta_{i,j}^+, \dots, \delta_{i,d_i}^+ \right\}}_{\Delta_i^+}$$

enakovredna predstavitevi

$$V_i = \left\{ v_{i,1}, \dots, v_{i,j}, \dots, v_{i,d_i}, \underbrace{v_{i,d_i+1},}_{0} v_{i,d_i+2}, \dots, v_{i,d_i+1+j}, \dots, v_{i,2d_i+1} \right\},$$

kjer velja $j = 1, 2, \dots, d_i$ ter $v_{i,j} \xrightarrow{\delta} \delta_{i,d_i-(j-1)}$, $v_{i,d_i+1} \xrightarrow{\delta} 0$ in $v_{i,d_i+1+j} \xrightarrow{\delta} \delta_{i,j}^+$.

Da bo omogočeno bolj prostvo premikanje po iskalnem prostoru je dodana utež ω , tako da enačba (1) preide v:

$$p_i = p'_i + \omega \delta(v_i), \quad (2)$$

kjer je ω naključno izbrano celo število z intervala $[1, b]$.

Vsako vozlišče iz množice V_i je povezano z vsemi vozlišči, ki pripadajo množici V_{i+1} . Torej je \mathcal{G} usmerjen graf, kjer so vse poti, ki se začno v začetnem vozlišču *start* in končajo v enem od končnih vozlišč, enako dolge. Pot v je definirana kot: $v = v_1 \dots v_i \dots v_D$, kjer je $v_i \in V_i$, $i = 1, 2, \dots, D$.

2.3 Algoritem DASA

Zastavljena optimizacijska naloga je poiskati takšno pot v , da bo $f(\mathbf{p}) < f(\mathbf{p}')$, kjer je \mathbf{p}' trenutna najboljša rešitev in $\mathbf{p} = \mathbf{p}' + \Delta(v)$ (z upoštevanjem enačbe (2) za vse elemente $p_i \in \mathbf{p}$). Če je vrednost kriterijske funkcije $f(\mathbf{p})$ manjša od $f(\mathbf{p}')$, se vrednost \mathbf{p}' nadomesti z vrednostjo \mathbf{p} .

Psevdo koda (algoritem 1) opisuje diferencialni pristop s stigmergijo mravelj k optimizaciji v zveznem prostoru, imenovan algoritem DASA (iz angl. *Differential Ant-Stigmergy Algorithm*).

Algoritem 1 DASA

```

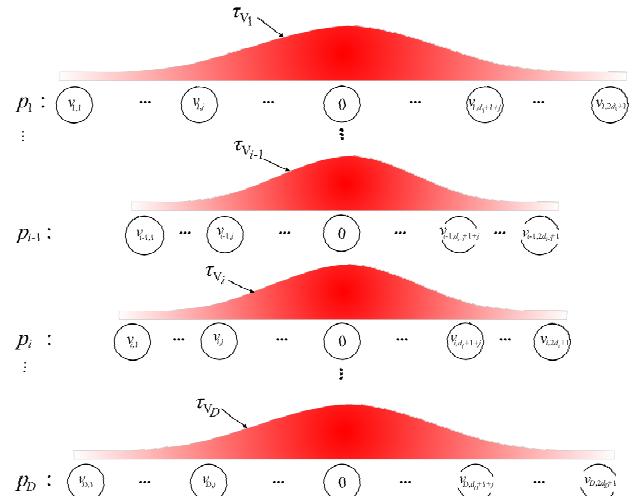
1:  $\mathbf{p}' = \text{Naključna\_rešitev}(\text{parametri})$ 
2: najboljša = Ovrednotenje( $\mathbf{p}'$ )
3: preiskovalni_graf = Inicializacija(parametri)
4: Inicializacija_grafa(začetna_količina_feromona)
5: while ni izpolnjen pogoj za končanje do
6:   trenutno_najboljša = inf
7:   for all  $m$  mravelj do
8:     pot = Najdena_pot(preiskovalni_graf)
9:      $\mathbf{p} = \mathbf{p}' + \omega\delta(\text{pot})$ 
10:    rezultat = Ovrednotenje( $\mathbf{p}$ )
11:    if rezultat < trenutno_najboljša then
12:      trenutno_najboljša = rezultat
13:      najboljša_pot = pot
14:       $\mathbf{p}^b = \mathbf{p}$ 
15:    end if
16:   end for
17:   if trenutno_najboljša < najboljša then
18:     najboljša = trenutno_najboljša
19:      $\mathbf{p}' = \mathbf{p}^b$ 
20:     Prerazporeditev_feromona(najboljša_pot)
21:   end if
22:   Izhlapecanje_feromona(preiskovalni_graf)
23:   Izredna_akcija //možnost
24: end while

```

Najprej se izbere, lahko tudi naključno, neka rešitev \mathbf{p}' , ki se tudi ovrednoti. Nato se kreira preiskovalni graf, v katerega vozlišča se odloži začetna količina feromona. To se naredi takole. Za vsako množico vozlišč $V_i \subset V$, $1 \leq i \leq D$, ki pomeni parameter p_i , se feromon porazdeli po Gaussovi funkciji

$$\text{Gauss}(p_i, \mu, \sigma) = \tau_i^0 + \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(p_i - \mu)^2}{2\sigma^2}},$$

kjer je μ srednja vrednost, σ standardni odklon in τ_i^0 najnižja vrednost količine feromona za parameter p_i . Na začetku velja $\mu \triangleq 0$, $\sigma \triangleq 1$ in $\sigma_{\max} \triangleq 1$ (glej sliko 2).



Slika 2. Začetna porazdelitev feromona
Figure 2. Initial pheromone distribution

Jedro algoritma je zanka, kjer ob vsaki ponovitvi m mravelj sočasno začne pot po preiskovalnem grafu (vedno iz vozlišča *start*). Mravlje izberejo naslednje vozlišče na svoji poti po verjetnostnem pravilu; mravlja α se v koraku i premakne iz nekega vozlišča v množici V_{i-1} v vozlišče $v_{i,j} \in \{v_{i,1}, \dots, v_{i,2d_i+1}\}$ z verjetnostjo:

$$\text{prob}_j(\alpha, i) = \frac{\tau(v_{i,j})}{\sum_{1 \leq k \leq 2d_i+1} \tau(v_{i,k})},$$

kjer je $\tau(v_{i,k})$ količina feromona v vozlišču $v_{i,k}$. To ponavlja, dokler ne doseže končnega vozlišča. Tako ustvarjena pot (oz. rešitev) \mathbf{p} se ovrednoti s kriterijsko funkcijo $f(\mathbf{p})$. Najboljša izmed m rešitev se primerja s trenutno najboljšo. Če je ta rešitev boljša, potem postane to nova trenutno najboljša rešitev. Kadar se to zgodi, se količina feromona prerazporedi glede na pot, s katero je bila ta, nova trenutno najboljša rešitev, dosežena (glej sliko 3). Izhlapecanje feromona je upoštevano pri spremjanju faktorjev μ in σ takole:

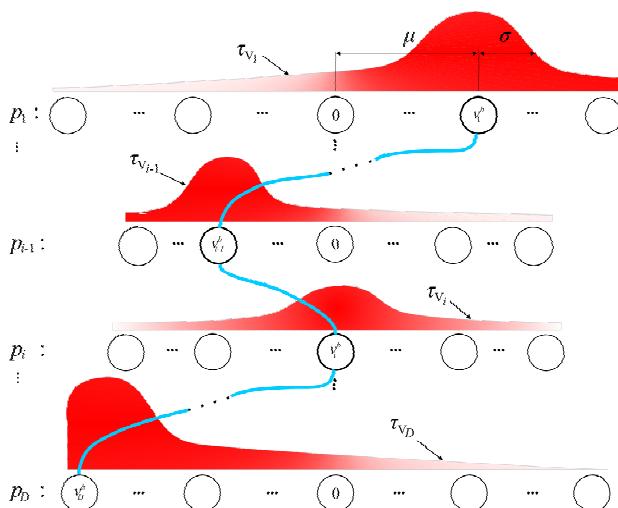
$$\mu^{\text{NEW}} = (1 - \rho)\mu^{\text{OLD}}$$

in

$$\sigma^{\text{NEW}} = \begin{cases} (1 + \rho)\sigma^{\text{OLD}} & (1 + \rho)\sigma^{\text{OLD}} < \sigma_{\max} \\ \sigma_{\max} & \text{otherwise} \end{cases},$$

kjer je ρ v naprej določen faktor izhlapecanja.

Postopek se ponavlja, dokler ni izpolnjen pogoj za končanje (npr. vnaprej omejeno število ovrednotenj). Skozi izvajanje algoritma se σ_{\max} počasi zmanjšuje in s tem se izboljšuje konvergenca algoritma (tj. primer izredne akcije).



Slika 3. Redistribucija feromona
Figure 3. Pheromone distribution

3 Uspešnost algoritma DASA

3.1 Eksperimentalno okolje

Preskusi so potekali na računalniškem sistemu s procesorjem AMD Opteron™ 2.6-GHz, 2 GB RAM pomnilnika in operacijskim sistemom Microsoft® Windows® XP. Algoritem DASA je izveden v programskega jeziku Borland® Delphi™.

Algoritem DASA ima tri parametre: število mrazov m , faktor izhlapevanja feromonov ρ in natančnost parametrov ϵ , ki so predmet optimizacije. Za parametre so bile izbrane naslednje vrednosti: $m = 10$, $\rho = 0.1$ in $\epsilon = 10^{-12}$. Te so bile določene na podlagi omejenega števila predhodnih preskusov (brez podrobnejšega finega nastavljanja).

3.2 Preskusne funkcije

Algoritem DASA je bil preskušen na štirih 30 dimenzijskih preskusnih funkcijah. Podroben opis funkcij je na voljo v [12].

Funkcija f_3 (*Shifted Rotated High Conditional Elliptic Function*) je enomodalna, f_9 (*Shifted Rastrigin's Function*) pa je večmodalna. Funkciji f_{13} (*Expanded Extended Griewangk's plus Rosenbrock's Function*) in f_{15} (*Hybrid Composition Function*) sta rezultat kompozicije več funkcij.

3.3 Primerjani algoritmi

Algoritem DASA je bil na podoben način kot v [3] primerjan s štirimi uveljavljenimi populacijskimi algoritmi:

- evolucijsko strategijo z adaptacijo kovariančne matrike (CMA-ES) [1],

- diferencialno evolucijo (DE) [10],
- memetskim algoritmom (MA) [8] in
- evolucijskim algoritmom z oceno distribucije (EDA) [14],

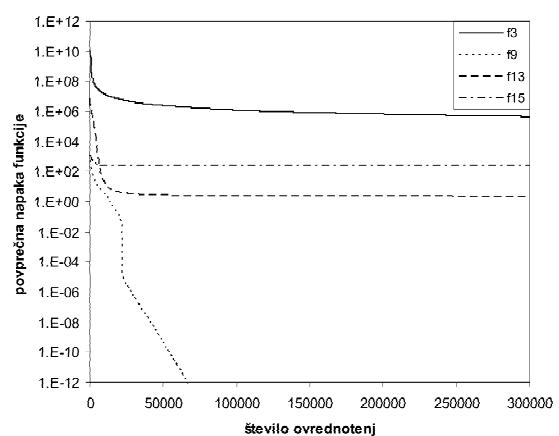
ki so bili 2005 predstavljeni na kongresu IEEE o evolucijskem računanju leta 2005.

3.4 Ovrednotenje

Algoritme smo ovrednotili glede na napako funkcije (oz. odstopanje od optimuma) $\epsilon = f(\mathbf{p}) - f(\mathbf{p}^*)$, kjer je \mathbf{p}^* znani optimum. Napako funkcije smo izračunali po 1000 in 300.000 ovrednotenjih. Te podatke smo zbrali s 25-kratno optimizacijo vsake funkcije, nakar smo naredili statistično analizo; poiskali smo najboljšo in najslabšo vrednost in mediano, izračunali smo tudi aritmetično sredino in standardni odklon. Vrednosti so zbrane v tabelah 1 in 2.

Prikazani rezultati kažejo obetavno kakovost algoritma DASA. Po razvrščanju glede na aritmetično sredino napake se je naš algoritem pri majhnem številu ovrednotenj (1000) izkazal kot najboljši, pri velikem številu ovrednotenj (300 000) pa kot drugi najboljši, takoj za algoritmom CMA-ES.

Konvergenca algoritma DASA za preskusne funkcije f_3 , f_9 , f_{13} in f_{15} je prikazana na sliki 4, in sicer kot povprečje 25-kratne optimizacije vsake od funkcij. Slika prikazuje odvisnost povprečne vrednosti napake od števila ovrednotenj.



Slika 4. Konvergenca algoritma DASA za preskusne funkcije
Figure 4. Convergence for the DASA algorithm on test functions

4 Sklep

Predlagan je bil nov splošen optimizacijski algoritem, ki je bil primerjan z nekaterimi znanimi evolucijskimi algo-

funkcija	napaka	CMA-ES	DE	MA	EDA	DASA
po 1000 ovrednotenjih						
f_3	najmanjša	$4,07 \cdot 10^{-9}$	$5,46 \cdot 10^4$	$5,55 \cdot 10^5$	$2,27 \cdot 10^6$	$1,27 \cdot 10^5$
	mediana	$5,44 \cdot 10^{-9}$	$2,43 \cdot 10^5$	$7,64 \cdot 10^5$	$3,66 \cdot 10^6$	$4,32 \cdot 10^5$
	največja	$8,66 \cdot 10^{-9}$	$9,00 \cdot 10^5$	$1,56 \cdot 10^6$	$5,88 \cdot 10^6$	$8,15 \cdot 10^5$
	aritmetična sredina	$5,55 \cdot 10^{-9}$	$2,89 \cdot 10^5$	$8,77 \cdot 10^5$	$3,75 \cdot 10^6$	$4,59 \cdot 10^5$
	standardni odklon	$1,09 \cdot 10^{-9}$	$1,93 \cdot 10^5$	$5,81 \cdot 10^4$	$9,09 \cdot 10^5$	$2,02 \cdot 10^5$
f_9	najmanjša	$4,35 \cdot 10^{-6}$	0	$7,78 \cdot 10^{-9}$	$2,10 \cdot 10^2$	0
	mediana	$9,95 \cdot 10^{-1}$	0	$9,95 \cdot 10^{-1}$	$2,30 \cdot 10^2$	0
	največja	4,97	0	1,99	$2,48 \cdot 10^2$	0
	aritmetična sredina	$9,38 \cdot 10^{-1}$	0	$6,81 \cdot 10^{-1}$	$2,30 \cdot 10^2$	0
	standardni odklon	1,18	0	$1,21 \cdot 10^{-1}$	9,44	0
f_{13}	najmanjša	1,10	2,31	1,33	$3,82 \cdot 10^1$	$9,62 \cdot 10^{-1}$
	mediana	2,61	3,89	2,54	$6,86 \cdot 10^1$	1,93
	največja	3,20	$1,39 \cdot 10^1$	$1,03 \cdot 10^1$	$1,29 \cdot 10^2$	2,56
	aritmetična sredina	2,49	4,51	3,96	$7,36 \cdot 10^1$	1,88
	standardni odklon	$5,13 \cdot 10^{-1}$	2,26	$5,38 \cdot 10^{-1}$	$2,36 \cdot 10^1$	$3,99 \cdot 10^{-1}$
f_{15}	najmanjša	$2,00 \cdot 10^2$	$4,75 \cdot 10^2$	$2,00 \cdot 10^2$	$4,35 \cdot 10^2$	0
	mediana	$2,00 \cdot 10^2$	$4,81 \cdot 10^2$	$3,00 \cdot 10^2$	$4,59 \cdot 10^2$	$3,00 \cdot 10^2$
	največja	$3,00 \cdot 10^2$	$5,86 \cdot 10^2$	$5,00 \cdot 10^2$	$5,63 \cdot 10^2$	$5,00 \cdot 10^2$
	aritmetična sredina	$2,08 \cdot 10^2$	$4,84 \cdot 10^2$	$3,56 \cdot 10^2$	$4,81 \cdot 10^2$	$2,33 \cdot 10^2$
	standardni odklon	$2,75 \cdot 10^1$	$2,14 \cdot 10^1$	$1,51 \cdot 10^1$	$4,67 \cdot 10^1$	$1,58 \cdot 10^2$
po 300.000 ovrednotenjih						
f_3	najmanjša	$3,84 \cdot 10^8$	$2,18 \cdot 10^8$	$9,63 \cdot 10^7$	$8,95 \cdot 10^8$	$6,11 \cdot 10^7$
	mediana	$1,00 \cdot 10^9$	$5,66 \cdot 10^8$	$2,69 \cdot 10^8$	$1,23 \cdot 10^9$	$2,80 \cdot 10^8$
	največja	$2,07 \cdot 10^9$	$9,53 \cdot 10^8$	$5,82 \cdot 10^8$	$1,92 \cdot 10^9$	$5,57 \cdot 10^8$
	aritmetična sredina	$1,07 \cdot 10^9$	$5,53 \cdot 10^8$	$2,94 \cdot 10^8$	$1,25 \cdot 10^9$	$3,10 \cdot 10^8$
	standardni odklon	$4,43 \cdot 10^8$	$1,78 \cdot 10^8$	$3,04 \cdot 10^7$	$2,67 \cdot 10^8$	$1,31 \cdot 10^8$
f_9	najmanjša	$2,19 \cdot 10^2$	$2,99 \cdot 10^2$	$1,82 \cdot 10^2$	$4,07 \cdot 10^2$	$4,60 \cdot 10^1$
	mediana	$2,50 \cdot 10^2$	$3,72 \cdot 10^2$	$3,00 \cdot 10^2$	$4,76 \cdot 10^2$	$9,13 \cdot 10^1$
	največja	$2,87 \cdot 10^2$	$4,25 \cdot 10^2$	$4,00 \cdot 10^2$	$5,44 \cdot 10^2$	$1,52 \cdot 10^2$
	aritmetična sredina	$2,53 \cdot 10^2$	$3,77 \cdot 10^2$	$2,99 \cdot 10^2$	$4,80 \cdot 10^2$	$9,29 \cdot 10^1$
	standardni odklon	$1,65 \cdot 10^1$	$3,00 \cdot 10^1$	$1,00 \cdot 10^1$	$3,51 \cdot 10^1$	$2,75 \cdot 10^1$
f_{13}	najmanjša	$3,05 \cdot 10^1$	$3,12 \cdot 10^4$	$4,09 \cdot 10^2$	$4,66 \cdot 10^5$	$1,33 \cdot 10^4$
	mediana	$7,36 \cdot 10^1$	$1,29 \cdot 10^5$	$3,86 \cdot 10^3$	$7,39 \cdot 10^5$	$1,38 \cdot 10^5$
	največja	$4,98 \cdot 10^2$	$4,33 \cdot 10^5$	$1,06 \cdot 10^4$	$1,13 \cdot 10^6$	$6,47 \cdot 10^5$
	aritmetična sredina	$1,14 \cdot 10^2$	$1,62 \cdot 10^5$	$3,95 \cdot 10^3$	$7,50 \cdot 10^5$	$2,12 \cdot 10^5$
	standardni odklon	$1,07 \cdot 10^2$	$8,66 \cdot 10^4$	$4,62 \cdot 10^2$	$1,93 \cdot 10^5$	$1,81 \cdot 10^5$
f_{15}	najmanjša	$4,93 \cdot 10^2$	$8,82 \cdot 10^2$	$5,46 \cdot 10^2$	$1,03 \cdot 10^3$	$2,32 \cdot 10^2$
	mediana	$6,93 \cdot 10^2$	$1,08 \cdot 10^3$	$7,49 \cdot 10^2$	$1,14 \cdot 10^3$	$6,28 \cdot 10^2$
	največja	$8,51 \cdot 10^2$	$1,19 \cdot 10^3$	$1,05 \cdot 10^3$	$1,21 \cdot 10^3$	$7,84 \cdot 10^2$
	aritmetična sredina	$6,69 \cdot 10^2$	$1,08 \cdot 10^3$	$7,62 \cdot 10^2$	$1,13 \cdot 10^3$	$5,89 \cdot 10^2$
	standardni odklon	$1,15 \cdot 10^2$	$7,13 \cdot 10^1$	$2,64 \cdot 10^1$	$4,50 \cdot 10^1$	$1,50 \cdot 10^2$

Tabela 1. Vrednosti napak po 1000 in 300.000 ovrednotenjih Table 1. Error values after 1000 and 300,000 function evaluations

ritmi za zvezno optimizacijo. Ovrednotenje je bilo narejeno na standardni množici preskusnih problemov in je potrdilo njegovo primernost in uporabnost za reševanje težkih optimizacijskih problemov v zveznem prostoru.

5 Literatura

- [1] A. Auger, N. Hansen, A restart CMA evolution strategy with increasing population size, *Proc. IEEE Congress on Evolutionary Computation*, Edinburgh, UK, Sept. 2005.

- [2] G. Bilchev, I. C. Parmee, The ant colony metaphor for searching continuous design spaces, *Lect. Notes Comp. Sc.* 993, 1995, pp. 25–39.
- [3] J. Brest, B. Bošković, S. Greiner, V. Žumer, M. Sepesy Maučec, Performance comparison of self-adaptive and adaptive differential evolution algorithms, *Soft Comput.* 11, 2007, pp. 617–629.
- [4] M. Dorigo, Optimization, learning and natural algorithms, PhD thesis, Dipartimento di Elettronica, Politecnico di Milano, Italy, 1992.
- [5] J. Dréo, P. Siarry, A new ant colony algorithm using the heterarchical concept aimed at optimization of multimimima continuous functions, *Lect. Notes Comp. Sc.* 2463, 2002, pp. 216–227.
- [6] P. Korošec, J. Šilc, B. Robič, Populacijske metode kot oblika metahevristične kombinatorične optimizacije, *Elektroteh. vestn.* 72, 2005, pp. 214–219.
- [7] P. Korošec, J. Šilc, B. Robič, Razdelitev mrež s kolonijami mravlj, *Elektroteh. vestn.* 73, 2006, pp. 215–220.
- [8] D. Molina, F. Herrera, M. Lozano, Adaptive local search parameters for real-coded memetic algorithms, *Proc. IEEE Congress on Evolutionary Computation*, Edinburgh, UK, Sept. 2005.
- [9] I. Pešl, V. Žuncer, J. Brešt, Optimizacija s pomočjo kolonije mravlj, *Elektroteh. vestn.* 73, 2006, pp. 93–98.
- [10] J. Rönkkönen, S. Kukkonen, K. V. Price, Real-parameter optimization with differential evolution, *Proc. IEEE Congress on Evolutionary Computation*, Edinburgh, UK, Sept. 2005.
- [11] K. Socha, ACO for continuous and mixed-variable optimization, *Lect. Notes Comp. Sc.* 3172, 2004, pp. 25–36.
- [12] P. N. Suganthan, N. Hansen, J. J. Liang, Y.-P. Chen, A. Auger, S. Tiwari, Problem Definitions and Evaluation Criteria for the CEC 2005 Special Session on Real-Parameter Optimization, Technical Report, Nanyang Technological University, Singapore, May 2005.
- [13] S. Tsutsui, An enhanced aggregation pheromone system for real-parameter optimization in the ACO metaphor, *Lect. Notes Comp. Sc.* 4150, 2006, pp. 60–71.
- [14] B. Yuan, M. Gallagher, Experimental results for the special session on real-parameter optimization at CEC 2005: A simple, continuous EDA, *Proc. IEEE Congress on Evolutionary Computation*, Edinburgh, UK, Sept. 2005.

Peter Korošec je raziskovalec na Institutu "Jožef Stefan" v Ljubljani in predavatelj na Fakulteti za matematiko, naravoslovje in informacijske tehnologije v Kopru. Njegovo raziskovalno področje je uporaba metahevrističnih optimizacijskih metod pri numeričnem in kombinatoričnem optimizirjanju.

Jurij Šilc je višji znanstveni sodelavec na Odseku za računalniške sisteme Instituta "Jožef Stefan" v Ljubljani. Raziskovalno se ukvarja računalniškimi sistemi in strukturami ter metahevrističnim optimiziranjem.