

Stigmergični pristop za reševanje dinamičnih optimizacijskih problemov

Peter Korošec^{1,2}, Jurij Šilc^{1,3}

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

³ Mednarodna podiplomska šola Jožefa Stefana, Jamova cesta 39, SI-1000 Ljubljana, Slovenija

E-pošta: peter.korošec@ijs.si

Povzetek. Številni realni optimizacijski problemi so dinamični in zahtevajo algoritme, ki so sposobni zvezno slediti časovnim spremembam optimuma. V sestavku prikazujemo, kako uspešno je to mogoče doseči z diferencialnim algoritmom s stigmergijo mravelj (DASA), ki je v osnovi primeren za optimizacijo v zveznem prostoru. Učinkovitost algoritma DASA je ocenjena s pomočjo preskusnih problemov, ki so bili predlagani za posebno sekcijo o dinamičnem optimiziranju na kongresu o evolucijskem računanju CEC 2009. Algoritom DASA se je v primerjavi z drugimi algoritmi, kot so optimizacija z roji, samoprilagodljiva diferencialna evolucija, evolucijsko programiranje in imunski algoritem, izkazal za enega izmed najuspešnejših. Pri preizkusu mnogoterih primerjav med algoritmi je bila uporabljena statistična analiza na rankih in uporabljeni popravljene p -vrednosti.

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

A Stigmeric Approach to Solving Dynamic Optimization Problems

Extended abstract. Many real-world problems are dynamic. Their solving requires an optimization algorithm. Apart from being able to locate the optimum, as it does in the static sense, it should also detect changes in the environment and track a new optimum.

The paper presents a differential ant-based stigmergy algorithm (DASA) developed for solving numerical optimization problems. The DASA was applied to dynamic optimization problems with continuous variables proposed for a special session on evolutionary computation in dynamic and uncertain environments at the 2009 IEEE Congress on Evolutionary Computation held in Trondheim, Norway.

Results of using DASA show that it can find reasonable solutions for any problem of the kind. One of its advantages is that there is no need of changing the original algorithm. So, it can be used for both cases of numerical optimization, i.e. static and dynamic. Also, the DASA is not sensible to different types of changes and can be used, when the knowledge about the certain problem is limited, i.e. when only the maximal dimension and input problem parameters are known.

The performance of the DASA is compared to that of the following four algorithms: a clustering particle swarm algorithm, self-adaptive differential evolution, evolutionary programming with an ensemble of memories, and dynamic artificial immune algorithm. An advanced statistical procedure for performing all pairwise comparisons between the observed algorithms is used. It can be seen that the DASA does not perform much worse than the self-adaptive differential evolution and much better than the other three algorithms.

Key words: stigmergy, dynamic optimization, continuous

space, benchmark functions

1 Uvod

Optimizacijski problemi, pri katerih se optimalna rešitev med samo optimizacijo spreminja, igrajo pomembno vlogo na številnih področjih človekove dejavnosti. Takšni dinamični optimizacijski problemi so definirani kot:

$$F = f(x, \phi, t),$$

kjer je F optimizacijski problem, f je kriterijska funkcija, x je dopustna rešitev iz množice rešitev \mathbf{X} , t je čas in ϕ je krmilni parameter, ki določa porazdelitev rešitev in pokrajino uspešnosti.

V zadnjih letih se optimizacija s kolonijami mravelj (ACO iz angl. Ant Colony Optimization) ne uporablja le za reševanje kombinatoričnih optimizacijskih problemov, temveč prodira tudi na zahtevna aktualna področja optimizacij. Eno takšnih je tudi dinamična optimizacija, kjer je po literaturi mogoče v zadnjem času zaslediti tudi uporabo ACO [2, 3, 7, 8, 16].

V tem sestavku je prikazano, kako uspešno je mogoče diferencialni pristop s stigmergijo mravelj, ki je primeren za optimizacijo v zveznem prostoru [10, 11], uporabiti za reševanje dinamičnih optimizacijskih problemov.

2 Stigmergično optimiziranje

Na kratko si oglejmo diferencialni pristop s stigmergijo mravelj, ki ga imenujemo algoritom DASA (iz angl. *Differential Ant-Stigmergy Algorithm*) in smo ga podrobneje opisali v [10].

Postopek je naslednji. Najprej se izbere, lahko tudi naključno, neka rešitev, ki se tudi ovrednoti. Nato se zgradi preiskovalni graf, v katerega vozlišča se odloži začetna količina feromona. Jedro algoritma je zanka, kjer ob vsaki ponovitvi m mravelj sočasno začne pot po preiskovalnem grafu. Mravlje izberejo naslednje vozlišče na svoji poti po verjetnostnem pravilu glede na količino feromona. To ponavlja, dokler ne doseže končnega vozlišča. Tako ustvarjena pot (oz. rešitev) se ovrednoti s kriterijsko funkcijo. 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. Ob tem pa feromon po vseh poteh tudi izhlapeva. Postopek se ponavlja, dokler ni izpolnjen pogoj za končanje (npr. vnaprej omejeno število ovrednotenj).

3 Ocena učinkovitosti

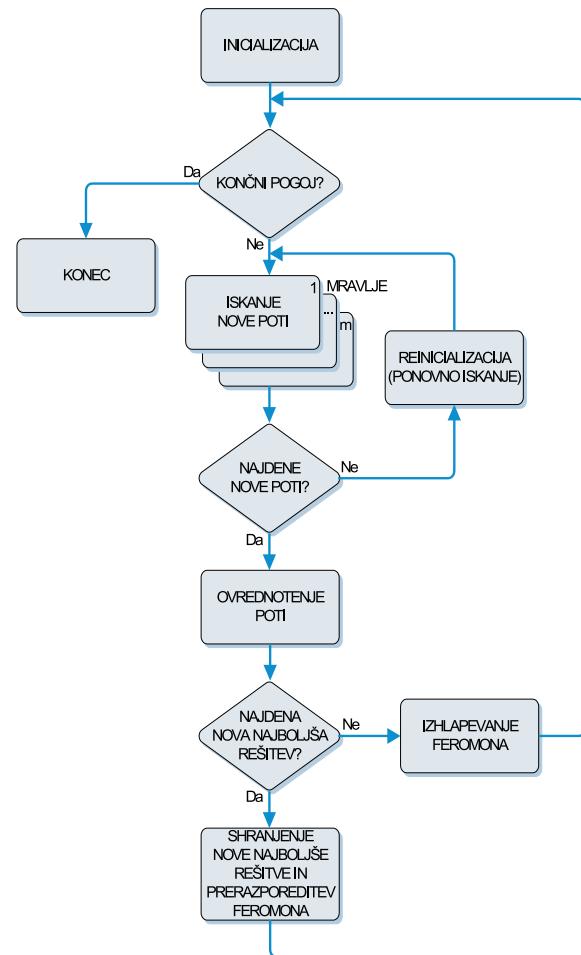
3.1 Eksperimentalno okolje

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 programskejem jeziku Borland® Delphi™.

3.2 Preskusni problemi

Algoritem DASA je bil preskušen na šestih preskusnih problemih, ki so bili predlagani za posebno sekcijo o dinamičnem optimizirjanju na kongresu o evolucijskem računanju CEC 2009, in sicer:

- F_1 : rotacijska koničasta funkcija (multimodalna, razširljiva, rotirana, število lokalnih optimumov je umetno vodeno),
- F_2 : kompozicija sferne funkcije (multimodalna, razširljiva, rotirana, deset lokalnih optimumov),
- F_3 : kompozicija Rastriginove funkcije (multimodalna, razširljiva, rotirana, veliko lokalnih optimumov),
- F_4 : kompozicija Griewankove funkcije (multimodalna, razširljiva, rotirana, veliko lokalnih optimumov),
- F_5 : kompozicija Ackleyeve funkcije (multimodalna, razširljiva, rotirana, veliko lokalnih optimumov),



Slika 1. Diferencialni pristop s stigmergijo mravelj
Figure 1. Differential ant-stigmergy approach

- F_6 : hibridna kompozicija funkcij (multimodalna, razširljiva, rotirana, veliko lokalnih optimumov, lastnosti različnih funkcij so pomešane, sferne funkcije vnašajo dvoje ploskih področij).

Vrste dinamičnih sprememb (ds) so naslednje:

- 1: spremembe majhnih korakov,
- 2: spremembe velikih korakov,
- 3: naključne spremembe,
- 4: kaotične spremembe,
- 5: ponavljajoče se spremembe,
- 6: ponavljajoče se spremembe s šumom,
- 7: naključne spremembe s spremembou dimenzij.

Podrobni opis preskusnih problemov in vrst dinamičnih sprememb je na voljo [15].

problem	napake	$\bar{ds}_1, n = 10$	$\bar{ds}_2, n = 10$	$\bar{ds}_3, n = 10$	$\bar{ds}_4, n = 10$	$\bar{ds}_5, n = 10$	$\bar{ds}_6, n = 10$	$\bar{ds}_7, 5 \leq n \leq 15$
F_1 $m = 10$	\bar{E}_{\min}	4, 17 E-13	3, 80 E-13	3, 80 E-13	6, 57 E-13	5, 56 E-13	7, 90 E-13	3, 55 E-14
	\bar{E}_{\max}	5, 51 E+00	3, 85 E+01	3, 97 E+01	9, 17 E+00	2, 09 E+01	4, 71 E+01	2, 91 E+01
	\bar{E}_{sr}	1, 80 E-01	4, 18 E+00	6, 37 E+00	4, 82 E-01	2, 54 E+00	2, 34 E+00	4, 84 E+00
	Std	1, 25 E+00	9, 07 E+00	1, 07 E+01	1, 95 E+00	4, 80 E+00	8, 66 E+00	8, 96 E+00
F_1 $m = 50$	\bar{E}_{\min}	5, 97 E-13	5, 03 E-13	3, 57 E-13	7, 73 E-13	8, 02 E-13	6, 73 E-13	7, 39 E-14
	\bar{E}_{\max}	7, 67 E+00	2, 91 E+01	3, 10 E+01	5, 58 E+00	1, 16 E+01	3, 51 E+01	3, 22 E+01
	\bar{E}_{sr}	4, 42 E-01	4, 86 E+00	8, 42 E+00	5, 09 E-01	1, 18 E+00	2, 07 E+00	7, 84 E+00
	Std	1, 39 E+00	7, 00 E+00	9, 56 E+00	1, 09 E+00	2, 18 E+00	5, 97 E+00	9, 05 E+00
F_2	\bar{E}_{\min}	1, 97 E-11	2, 34 E-11	2, 72 E-11	1, 41 E-11	3, 59 E-11	1, 65 E-11	1, 30 E-12
	\bar{E}_{\max}	3, 39 E+01	4, 03 E+02	3, 56 E+02	1, 65 E+01	4, 33 E+02	2, 49 E+01	3, 67 E+01
	\bar{E}_{sr}	3, 30 E+00	2, 56 E+01	1, 89 E+01	1, 45 E+00	4, 96 E+01	2, 11 E+00	3, 87 E+00
	Std	8, 78 E+00	8, 32 E+01	6, 78 E+01	3, 83 E+00	1, 12 E+02	5, 29 E+00	8, 12 E+00
F_3	\bar{E}_{\min}	3, 39 E-11	4, 34 E+01	1, 38 E+00	4, 51 E-11	3, 08 E+00	4, 21 E-11	1, 06 E-01
	\bar{E}_{\max}	4, 35 E+02	9, 88 E+02	9, 37 E+02	1, 17 E+03	9, 23 E+02	1, 47 E+03	9, 09 E+02
	\bar{E}_{sr}	1, 57 E+01	8, 24 E+02	6, 88 E+02	4, 35 E+02	6, 97 E+02	6, 26 E+02	4, 33 E+02
	Std	6, 71 E+01	2, 04 E+02	2, 98 E+02	4, 41 E+02	3, 15 E+02	4, 60 E+02	3, 80 E+02
F_4	\bar{E}_{\min}	2, 01 E-11	2, 95 E-11	2, 87 E-11	1, 85 E-11	5, 89 E-11	2, 09 E-11	7, 10 E-12
	\bar{E}_{\max}	5, 76 E+01	5, 05 E+02	5, 40 E+02	1, 88 E+01	5, 28 E+02	3, 97 E+01	4, 51 E+02
	\bar{E}_{sr}	5, 60 E+00	6, 56 E+01	5, 36 E+01	1, 85 E+00	1, 08 E+02	2, 98 E+00	2, 74 E+01
	Std	2, 65 E+01	1, 60 E+02	1, 40 E+02	4, 22 E+00	1, 78 E+02	7, 59 E+00	9, 00 E+01
F_5	\bar{E}_{\min}	3, 22 E-11	3, 74 E-11	3, 86 E-11	2, 69 E-11	5, 99 E-11	2, 85 E-11	1, 93 E-12
	\bar{E}_{\max}	1, 71 E+01	2, 22 E+01	1, 60 E+01	8, 10 E+00	2, 90 E+01	8, 75 E+00	1, 87 E+01
	\bar{E}_{sr}	9, 55 E-01	9, 90 E-01	9, 49 E-01	3, 92 E-01	2, 30 E+00	4, 67 E-01	1, 11 E+00
	Std	3, 43 E+00	4, 05 E+00	3, 31 E+00	1, 61 E+00	6, 36 E+00	1, 73 E+00	3, 76 E+00
F_6	\bar{E}_{\min}	2, 36 E-11	3, 58 E-11	3, 69 E-11	2, 55 E-11	6, 37 E-11	2, 56 E-11	6, 48 E-12
	\bar{E}_{\max}	4, 83 E+01	5, 54 E+02	5, 29 E+02	8, 16 E+01	4, 99 E+02	2, 49 E+02	1, 37 E+02
	\bar{E}_{sr}	8, 87 E+00	3, 70 E+01	2, 67 E+01	9, 74 E+00	3, 79 E+01	1, 33 E+01	1, 17 E+01
	Std	1, 33 E+01	1, 22 E+02	9, 84 E+01	2, 20 E+01	1, 18 E+02	5, 74 E+01	3, 67 E+01

Tabela 1. Dosežene napake pri različnih preskusnih problemih in različnih dinamičnih spremembah
Table 1. Error values achieved for different test problems and different dynamic changes

3.3 Nastavitev parametrov

Algoritem DASA ima šest parametrov: število mravelj m , faktor izhlapevanja feromonov ρ , natančnost parametrov ε , ki so predmet optimizacije, bazo diskretizacije b , skalirni faktor povečevanja s_+ in skalirni faktor zmanjševanja s_- . Glede na njihove običajne nastavitev [13] smo tokrat zaradi boljše odzivnosti algoritma zmanjšali število mravelj na $m = 3$ in povečali faktor izhlapevanja ρ na 0.1, s čimer smo pospešili konvergenco algoritma. Preostale nastavitev so ostale običajne: $\varepsilon = 10^{-15}$, $b = 10$, $s_+ = 0.01$ in $s_- = 0.02$. Vse vrednosti so bile določene na podlagi omejenega števila predhodnih preskusov in brez podrobnejšega finega nastavljanja.

3.4 Preskusni postopek

Za vse preskusne probleme smo uporabili naslednji preskusni postopek. Z vidika samega algoritma je bil ta pognan nad v naprej predpisanim številom ovrednotenj kriterijske funkcije. Med izvajanjem algoritmu niso bile posredovane nikakršne dodatne informacije o dinamičnih spremembah pokrajine uspešnosti in dimenzij problema. Za dinamične spremembe je skrbel poseben vmesnik. Npr. pri preskusnih dinamičnih spremembah \bar{ds}_7 se je algoritmu nastavilo $6 \cdot 10^6$ ovrednotenj kriterijske funkcije in dimenzijo problema $n = 15$, čeprav se je ta med op-

timizacijo spremenjala med 5 in 15. Torej je algoritem obravnaval problem kot statični 15-dimenzijski problem, vmesnik pa je poskrbel, da so se obravnavale le veljavne dimenzije problema.

3.5 Rezultati

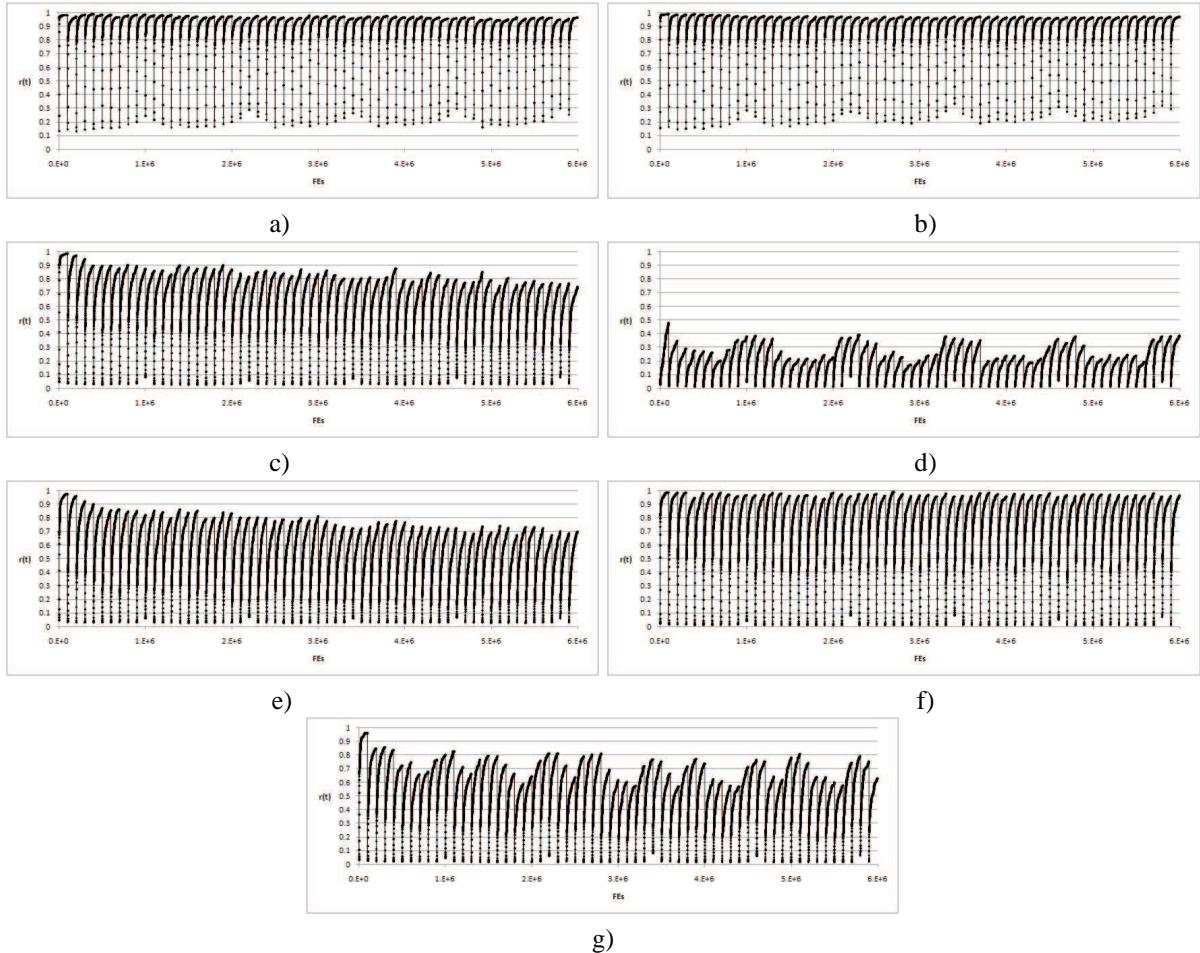
V tabeli 1 so prikazane vrednosti napak kriterijske funkcije pri različnih preskusnih problemih in različnih dinamičnih spremembah. Za vsako vrsto dinamične spremembe \bar{ds}_1 do \bar{ds}_7 ($\text{št_spr} = 7$) in za vsak preskusni problem F_1 do F_6 ($\text{št_pr} = 7$, saj imamo pri maksimizacijskem problemu F_1 enkrat število vrhov 10 in drugič 50) so podane vrednosti povprečne najmanjše napake \bar{E}_{\min} , povprečne srednje napake \bar{E}_{sr} , povprečne največje napake \bar{E}_{\max} , kakor tudi vrednosti standardnih odklonov (Std) po 20 ponovitvah preskusa. Povprečne vrednosti napak so določene kot:

$$\bar{E}_{\min} = \sum_{i=1}^{\text{št_pr}} \min_{j=1}^{\text{št_spr}} \frac{E_{i,j}^{\text{zadnji}}(t)}{\text{št_pr}},$$

$$\bar{E}_{\text{sr}} = \sum_{i=1}^{\text{št_pr}} \sum_{j=1}^{\text{št_spr}} \frac{E_{i,j}^{\text{zadnji}}(t)}{\text{št_pr} * \text{št_spr}}$$

in

$$\bar{E}_{\max} = \sum_{i=1}^{\text{št_pr}} \max_{j=1}^{\text{št_spr}} \frac{E_{i,j}^{\text{zadnji}}(t)}{\text{št_pr}},$$



Slika 2. Konvergenčni graf za: a) F_1 , $m = 10$; b) F_1 , $m = 50$; c) F_2 ; d) F_3 ; e) F_4 ; f) F_5 ; g) F_6
Figure 2. Convergence graph for a) F_1 , $m = 10$; b) F_1 , $m = 50$; c) F_2 ; d) F_3 ; e) F_4 ; f) F_5 ; g) F_6

kjer je $E^{\text{zadnji}}(t) = |f(x_{\text{najboljši}}(t)) - f(x^*(t))|$ napaka, ki jo algoritem doseže po vnaprej določenem številu ovrednotenj kriterijske funkcije po vsaki dinamični spremembni (Max_ŠO/spr). Pri tem je $x_{\text{najboljši}}(t)$ najboljša rešitev, ki jo je algoritem našel med dvema dinamičnima spremembama in $x^*(t)$, pripadajoča optimalna vrednost.

Slika 2 prikazuje konvergenčni graf za vsak preskusni problem. Graf prikazuje potek povprečne relativne učinkovitosti $r(t)$ v odvisnosti od števila ovrednotenj kriterijske funkcije. Za vsak preskusni problem je povprečeno 20 ponovitev in šest preskusnih okolij dinamičnih sprememb (ds₁ do ds₆).

Za maksimizacijski problem F_1 je

$$r(t) = \frac{f(x_{\text{najboljši}}(t))}{f(x^*(t))},$$

za minimizacijske probleme F_2 do F_6 pa je

$$r(t) = \frac{f(x^*(t))}{f(x_{\text{najboljši}}(t))}.$$

3.6 Primerjava

Uspešnost algoritma DASA [12] bomo primerjali z vsemi najnovejšimi algoritmi, ki so bili predstavljeni v posebni sekciji o dinamičnem optimiziranju na kongresu o evolucijskem računanju CEC 2009 in so bili priznani prav v ta namen. Ti algoritmi so:

- CPSO: optimizacija z gručami rojev [14],
- jDE: samoprilagodljiva diferencialna evolucija [1],
- EP: evolucijsko programiranje z zunanjimi pomnilniki [17] in
- dopt-aiNet: imunski algoritem [4].

Tabela 2 prikazuje učinkovitost algoritmov DASA, CPSO, jDE, EP in dopt-aiNet. Ocena za vsak problem in vsako vrsto dinamične spremembe se izračuna kot:

$$\text{ocena}_{\text{p-ds}} = \text{utež}_{\text{p-ds}} * \sum_{i=1}^{\text{št-pr}} \sum_{j=1}^{\text{št-spr}} \frac{r_{ij}}{\text{št_spr} * \text{št_pr}}$$

in

$$r_{ij} = \frac{r_{ij}^{\text{zadnji}}}{1 + \sum_{s=1}^S \frac{1-r_{ij}^s}{S}}.$$

Tu je r_{ij}^{zadnji} vrednost relativne učinkovitosti po doseženih Max-ŠO/spr ovrednotenjih za vsako spremembo, r_{ij}^s je relativna vrednost učinkovitosti po sistemu vzorčenju in $S = \frac{\text{Max-ŠO/spr}}{s_f}$, kjer je s_f frekvence vzorčenja. V našem primeru imamo: $s_f = 100$, $\text{Max-ŠO/spr} = 10000 * n$ in $n = 10$. Vrednost uteži $\alpha_{\text{p.ds}}$ je določena v [15].

problem	ds, n	ocena _{p.ds}				
		DASA	CPSO	jDE	EP	dopt-aiNet
F_1 $m = 10$	1, 10	1,471	1,413	1,477	1,280	1,354
	2, 10	1,357	1,338	1,369	1,174	1,135
	3, 10	1,280	1,304	1,383	1,153	1,145
	4, 10	1,416	1,466	1,472	1,385	1,163
	5, 10	1,396	1,334	1,394	1,231	1,060
	6, 10	1,355	1,323	1,413	1,251	1,011
	7, 5-15	0,885	0,857	0,911	0,730	0,770
F_1 $m = 50$	1, 10	1,455	1,412	1,469	1,279	1,341
	2, 10	1,339	1,332	1,359	1,124	1,197
	3, 10	1,241	1,257	1,353	1,059	1,187
	4, 10	1,423	1,463	1,469	1,395	1,210
	5, 10	1,438	1,377	1,436	1,350	1,113
	6, 10	1,346	1,310	1,387	1,352	1,060
	7, 5-15	0,832	0,830	0,899	0,752	0,786
F_2	1, 10	1,865	1,747	2,110	1,509	1,757
	2, 10	1,446	1,380	1,353	1,487	1,211
	3, 10	1,583	1,392	1,308	1,590	1,149
	4, 10	1,890	2,160	2,100	1,786	1,581
	5, 10	1,420	1,366	1,240	1,569	0,734
	6, 10	1,826	1,546	1,778	1,678	1,210
	7, 5-15	1,215	1,048	1,019	1,016	0,913
F_3	1, 10	1,413	0,631	1,571	0,574	0,036
	2, 10	0,072	0,041	0,298	0,588	0,020
	3, 10	0,174	0,091	0,281	0,656	0,020
	4, 10	0,742	0,665	1,276	0,793	0,014
	5, 10	0,223	0,065	0,441	0,646	0,045
	6, 10	0,455	0,084	0,735	0,628	0,012
	7, 5-15	0,282	0,118	0,549	0,483	0,014
F_4	1, 10	1,759	1,651	2,066	1,488	1,588
	2, 10	1,233	1,128	1,315	1,431	0,695
	3, 10	1,327	1,175	1,355	1,491	0,929
	4, 10	1,788	2,120	1,993	1,728	1,370
	5, 10	1,091	1,111	1,238	1,574	0,368
	6, 10	1,699	1,365	1,795	1,640	1,091
	7, 5-15	1,005	0,915	1,018	0,957	0,679
F_5	1, 10	2,021	1,596	2,177	1,321	0,930
	2, 10	2,012	1,468	2,087	1,257	0,867
	3, 10	2,030	1,446	2,093	1,345	0,859
	4, 10	2,049	2,099	2,220	1,573	0,681
	5, 10	2,019	1,461	2,131	1,260	0,144
	6, 10	2,024	1,293	2,074	1,364	0,319
	7, 5-15	1,346	0,942	1,379	0,833	0,374
učinkovitost [%]		65,21	57,57	69,73	58,09	38,29
rang		2,31	3,10	1,47	3,31	4,82

Tabela 2. Učinkovitosti algoritmov pri različnih preskusnih problemih in različnih dinamičnih spremembah
Table 2. Performances of algorithms achieved for different test problems and different dynamic changes

Celotna učinkovitost algoritma je ovrednotena kot:

$$\text{učinkovitost} = \sum_{\text{p.ds}=1}^{\text{št.primerov}} \text{ocena}_{\text{p.ds}}.$$

Skupno število testnih primerov št.primerov = 49.

V tabeli 2 so vsi algoritmi tudi razvrščeni glede na doseženo oceno učinkovitosti ocena_{p.ds}.

3.7 Statistična analiza na rangih

Ničelna domneva trdi, da so vsi rangi enakomerno prisotni v vseh k primerjanih algoritmih. Za potrditev oz. zavrnitev te domneve uporabimo statistični preizkus [9], ki temelji na naslednji statistiki:

$$F_F = \frac{(\text{št.primerov} - 1)\chi_F^2}{(k - 1)\text{št.primerov} - \chi_F^2},$$

kjer je χ_F^2 Friedmanova statistika [5]. Pri izbranem α je ničelna domneva zavrnjena, če je p -vrednost manjša od tveganja α . Pri preizkušu mnogoterih primerjav je treba p -vrednost ustrezno popraviti, tako da jo lahko neposredno primerjamo z izbrano α . Za izračun popravljeni p -vrednosti smo uporabili naslednje metode [6]: Nemenyievo, Holmovo, Shafferjevo in Bergmann-Hommelovo. Kot je razvidno iz tabele 3, pri $\alpha = 0.10$ Nemenyieva metoda zavrača domneve 1–8, Holmova, Shafferjeva in Bergmann-Hommelova pa domneve 1–9. Pri $\alpha = 0.01$ Nemenyieva metoda zavrača domneve 1–6, Holmova, Shafferjeva in Bergmann-Hommelova pa domneve 1–7.

4 Sklep

V sestavku je prikazan diferencialni algoritem s stigmergijsko mraveljjo (DASA), ki je namenjen numerični optimizaciji. Algoritem DASA je uporabljen za dinamične optimizacijske probleme z zveznimi spremenljivkami, ki so bili predlagani za posebno sekcijo o dinamičnem optimizirjanju na kongresu o evolucijskem računanju, ki je potekal maja 2009 v Trondheimu na Norveškem.

Algoritem DASA se je v primerjavi z drugimi prijerenimi algoritmi, kot so optimizacija z roji (PSO), samoprilagodljiva diferencialna evolucija (DE), evolucijsko programiranje (EP) in imunski algoritem (IA), izkazal za enega najuspešnejših. Uspešno je rešil skoraj vse probleme, le pri kompoziciji Rastriginove funkcije (F_3) ni dovolj hitro sledil dinamičnim spremembam.

Očitna prednost algoritma DASA je, da se lahko v nespremenjeni obliki uporablja za reševanje statičnih in tudi dinamičnih optimizacijskih problemov. Pri dinamični optimizaciji je algoritem neobčutljiv na različne dinamične spremembe. Uporaben je tudi tedaj, ko o reševanem problemu ne vemo veliko, saj mu zadošča le poznavanje največje razsežnosti problema in njegovih vhodnih parametrov.

domneva	nepopravljena <i>p</i> -vrednost	popravljena <i>p</i> -vrednost			
		Nemenyi	Holm	Shaffer	Bergman-Hommel
1 jDE vs. dopt-aiNet	1.10 E–25	1.10 E–24	1.10 E–24	1.10 E–24	1.10 E–24
2 DASA vs. dopt-aiNet	3.90 E–15	3.90 E–14	3.51 E–14	2.34 E–14	2.34 E–14
3 jDE vs. EP	8.93 E–09	8.93 E–08	7.14 E–08	5.36 E–08	5.36 E–08
4 CPSO vs .dopt-aiNet	8.03 E–08	8.03 E–07	5.62 E–07	4.82 E–07	3.21 E–07
5 jDE vs. CPSO	3.20 E–07	3.20 E–06	1.92 E–06	1.92 E–06	1.28 E–06
6 EP vs. dopt-aiNet	2.27 E–06	2.27 E–05	1.14 E–06	9.08 E–06	4.54 E–06
7 DASA vs. EP	0.0017	0.0175	0.0070	0.0070	0.0052
8 jDE vs. DASA	0.0088	0.0881	0.0264	0.0264	0.0176
9 DASA vs. CPSO	0.0127	0.1272	0.0264	0.0264	0.0176
10 CPSO vs. EP	0.5229	1.0	0.5229	0.5229	0.5229

Tabela 3. Popravljene *p*-vrednosti
Table 3. Adjusted *p*-values

5 Literatura

- [1] J. Brest, A. Zamuda, B. Bošković, M. Sepesy Maučec, V. Žumer, Dynamic optimization using self-adaptive differential evolution, *Proc. IEEE Congress on Evolutionary Computation*, Trondheim, Norway, May 2009, pp. 415–422.
- [2] C. J. Eyckelhof, M. Snoek, Ant systems for a dynamic TSP, *Lecture Notes in Computer Science*, 2463:88–99, 2002.
- [3] C. Fernandes, V. Ramos, A. C. Rosa, Stigmergic optimization in dynamic binary landscapes, *Proc. 22nd Annual ACM Symposium on Applied Computing*, Seoul, Korea, March 2007, pp. 747–748.
- [4] F. O. de França, F. J. Von Zuben, A dynamic artificial immune algorithm applied to challenging benchmarking problems, *Proc. IEEE Congress on Evolutionary Computation*, Thondheim, Norway, May 2009, pp. 423–430.
- [5] M. Friedman, The use of ranks to avoid the assumption of normality implicit in the analysis of variance, *Journal of the American Statistical Association*, 32(200):675–701, 1937.
- [6] S. García, F. Herrera, An extension on “Statistical comparisons of classifiers over multiple data sets” for all pairwise comparisons, *Journal of Machine Learning Research*, 9:2677–2694, 2008.
- [7] M. Guntsch, M. Middendorf, A population based approach for ACO, *Lecture Notes in Computer Science*, 2279:72–81, 2002.
- [8] M. Guntsch, M. Middendorf, Applying population based ACO to dynamic optimization problems, *Lecture Notes in Computer Science*, 2463:111–122, 2002.
- [9] R. L. Iman, J. M. Davenport, Approximations of the critical region of the Friedman statistic, *Communication in Statistics*, 9:571–595, 1980.
- [10] P. Korošec, J. Šilc, Diferencialni pristop s stigmergijo mravjej k optimizaciji v zveznem prostoru, *Elektrotehniški vestnik*, 75(4):217–222, 2008.
- [11] P. Korošec, J. Šilc, A stigmergy-based algorithm for continuous optimization tested on real-life-like environment, *Lecture Notes in Computer Science*, 5484:675–684, 2009.
- [12] P. Korošec, J. Šilc, The differential ant-stigmergy algorithm applied to dynamic optimization problems, *Proc. IEEE Congress on Evolutionary Computation*, Trondheim, Norway, May 2009, pp. 407–414.
- [13] P. Korošec, J. Šilc, K. Oblak, F. Kosel, The differential ant-stigmergy algorithm: An experimental evaluation and a real-world application, *Proc. IEEE Congress on Evolutionary Computation*, Singapore, September 2007, pp. 157–164.
- [14] C. Li, S. Yang, A clustering particle swarm optimizer for dynamic optimization, *Proc. IEEE Congress on Evolutionary Computation*, Trondheim, Norway, May 2009, pp. 439–446.
- [15] C. Li, S. Yang, T. T. Nguyen, E. L. Yu, X. Yao, Y. Jin, H.-C. Beyer, P. N. Suganthan, Benchmark Generator for CEC’2009 Competition on Dynamic Optimization, September 15, 2008. <http://www.cs.le.ac.uk/people/syang/ECiDUE/>
- [16] W. Tfaili, J. Dréo, P. Siarry, Fitting of an ant colony approach to dynamic optimization through a new set of test functions, *International Journal of Computational Intelligence Research*, 3:203–216, 2007.
- [17] E. L. Yu, P. N. Suganthan, Evolutionary programming with ensemble of external memories for dynamic optimization, *Proc. IEEE Congress on Evolutionary Computation*, Trondheim, Norway, May 2009, pp. 431–438.

Peter Korošec je raziskovalec na Institutu “Jožef Stefan” v Ljubljani in predavatelj na Fakulteti za matematiko, naravnostvije in informacijske tehnologije Koper. 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 in predavatelj na Mednarodni podiplomski šoli Jožefa Stefana v Ljubljani. Raziskovalno se ukvarja z računalniškimi sistemmi in strukturami ter metahevrističnim optimiziranjem.