

# Pareto tipo modeliai modeliuojamojo atkaitinimo algoritmuose

Gražvydas FELINSKAS, Leonidas SAKALAUSKAS (ŠU)  
el. paštas: grazvis@fm.su.lt

## Ivadas

Praktiniai optimizavimo uždaviniai dažnai yra tokie sudėtingi, kad uždavinį laikyti iškilu nerealu. Globalaus optimumo neiškuose uždaviniuose radimui yra taikomi keletas principinių algoritmų. Daugeliu atvejų šių algoritmų elgesys gali būti nagrinėjamas atsitiktinių klaidžiojimų teorijos požiūriu, minimizuojant arba maksimizuojant tikslą funkciją lokalines (pvz. stochastinių gradientų metodais) arba globalines (modeliuojamojo atkaitinimo, genetiniais algoritmais, Monte Karlo [7] metodais) paieškos būdais. Sprendžiant praktinius globalines optimizacijos uždavinius susiduriama su bendrų kriterijų, kuriais remiantis būtų galima tvirtinti, jog pasiektais globalus optimumas, stoka, bei rekomendacijų algoritmų parametru efektyviam parinkimui nebuvinu [2,5].

Modeliuojamojo atkaitinimo (simulated annealing – SA) metodo konvergavimo teoriniai tyrimai rodo, kad šiuose algoritmuose paieškos sekos formavimui efektyviai gali būti pritaikomi Pareto tipo modeliai [2], t.y. tokie modeliai, kurių skirtiniai turi „sunkias uodegas“ [1]. Taikydami modeliuojamojo atkaitinimo algoritmą, mes galime išitikinti, jog tokie modeliai leidžia efektyviau rasti globalujį optimumą.

Darbo tikslas – ištirti konvergavimo į globalų ekstremumą greitį kompiuterinio modeliavimo būdu. Algoritmo efektyvumo charakteristikomis yra laikomos minimizuojamos funkcijos reikšmė ir globalaus optimumo radimo tikimybė po tam tikro iteracijų skaičiaus.

## Modeliuojamojo atkaitinimo (Simulated Annealing) algoritmas

### Nagrinėkime optimizavimo uždavinį (minimizavimo)

$$\min_{x \in \Xi} f(x), \quad (1)$$

čia  $\Xi$  yra  $R^n$  poaibis ir  $f$  yra reali funkcija, apibrėžta srityje  $\Xi$  ir turinti globalų minimumą  $f^*$  srityje  $\Xi$ .

Aprašysime SA algoritmą sprendžiant (1) uždavinį [2,3,4].

**1 žingsnis.** Pasirenkame pradinę tašką  $x^0 \in \Xi$ , pradinę temperatūrą  $T_0 > 0$ , tam tikrą nuo temperatūros priklausančią generavimo tikimybinę tankio funkciją, atitinkamą temperatūros atnaujinimo funkciją, ir seką  $\{\rho_j; j \geq 0\}$  monotoniskai mažėjančiu teigiamu skaičiu. Suskaičiuojame  $f(x^0)$ . Nustatome  $X^0 = x^0$  ir  $k = 0$ .

**2 žingsnis.** Generuojame atsitiktinį vektorių  $Z^k$  naudodami generavimo tikimybinę tankio funkciją. Jei egzistuoja  $1 \leq i \leq n$  tokis, kad  $|Z_i^k| < \rho_k$ , kur  $Z_i^k$  yra  $i$ -asis vektoriaus  $Z^k$  komponentas, kartoti 2 žingsnį. Kitu atveju, gaunamas naujas taškas  $Y^k$  pridėdant atsitiktinį vektorių  $Z^k$  prie dabartinės iteracijos taško  $Z^k$ ,

$$Y^k = X^k + Z^k. \quad (2)$$

Jei  $Y^k \notin \Xi$ , kartojame 2 žingsnį; kitu atveju, skaičiuojame  $f(Y^k)$ .

**3 žingsnis.** Naudojame Metropolio kriterijų naujam iteracijos taškui  $X^{k+1}$  parinkti, t.y. generuojame atsitiktinį skaičių  $\eta$  tolygiai pasiskirsčiusi intervale  $(0, 1)$ , ir tikimybę  $P(Y^k, X^k, T_k)$ . Jei  $\eta \leq P(Y^k, X^k, T_k)$ , tada  $X^{k+1} = Y^k$  ir  $f(X^{k+1}) = f(Y^k)$ , kitu atveju paliekame  $X^{k+1} = X^k$  ir  $f(X^{k+1}) = f(X^k)$ ; čia

$$P(Y^k, X^k, T_k) = \min \{1, \exp\{[f(X^k) - f(Y^k)]/T_k\}\}. \quad (3)$$

**4 žingsnis.** Jei iš anksto numatyta sostojimo sąlyga (pvz. nurodytas iteracijų skaičius) yra patenkinta, tada sustoti. Kitu atveju atnaujiname temperatūrą naudodami temperatūros atnaujinimo funkciją ir grįztame prie 2 žingsnio.

Aprašytas metodas yra nagrinėtas teoriškai [2,3,4,6], tačiau išsamiau skaičiuojamujų tyrimų dar nėra padaryta. Šiame darbe daugiausia remiamasi R.L. Yang straipsniu [2], kuriame nustatytos SA algoritmo sąlygos. Šios sąlygos nustato temperatūros atnaujinimo funkcijos pavidalą, parametrus bei teigiamų skaičių sekos  $\{\rho_j; j \geq 0\}$  parinkimą, garantuojantį modeliuojamojo atkaitinimo algoritmo konvergavimą į tikslą funkcijos globalū minimumą tiriamoje srityje. Teigiamų skaičių seka  $\{\rho_j; j \geq 0\}$  kiekvienoje iteracijoje nustato mažiausią ribą, kurią turi viršyti generuojamo vektoriaus  $Z^k$  koordinatės.

Teoremos išvadose (pasekmėse) tvirtinama, kad temperatūros atnaujinimo funkcija  $T_k$  bei teigiamų skaičių sekos  $\{\rho_j; j \geq 0\}$  turi būti suderintos su generavimo tikimybiniu tankio funkcija [2]. Straipsnyje išnagrinėti keli generavimo skirtiniai, pasižymintys Pareto savybe (Pareto tipo modeliai pasižymi „sunkiomis uodegomis“. Pagrindinis šių modelių parametras –  $\alpha$ , kuris reiškia „uodegos sunkumo“ laipsnį. Tiriamame modelyje (b)  $\alpha = 1/m$ ) (1 lentelė).

Darbe naudojami šie žymėjimai:  $0 < \rho_0 < \min_{1 \leq i \leq n} r_i$ , čia  $r \in R^n$ ,  $r_i = \max_{x,y \in \Xi} |x_i - y_i|$ ,  $1 \leq i \leq n$ ,  $0 \leq \gamma \leq 1/n$ ,  $\{T_k; k \geq 0\}$  – temperatūrų seka,  $m \geq 1$  – sveikas skaičius,  $\lambda > 1$ ,  $0 < \gamma < \min\{\lambda, m/n\}$ . Remiantis 1 lentele, buvo gautos taisyklės dydžiams  $Z_k$  antrajame algoritmo žingsnyje modeliuoti.

## Algoritmų testavimo metodika

Globalinės optimizacijos uždavinuose taikant įvairius optimizavimo algoritmus reikia patikrinti algoritmų ir metodų patikimumą, efektyvumą. Tam naudojamos įvairios testinės funkcijos, kurių optimumo taškai iš anksto žinomi. Yra specialiai sukonstruojamos įvairios funkcijos, kurios turi vieną ar kelius globalius minimumus, taip pat gali turėti ir lokalių minimumų. Šių funkcijų pagalba mes galime patikrinti, ar mūsų naudojamas algoritmas „neužstringa“ lokaliame minimume, galime stebėti konvergavimo greitį, tikslumą

1 lentelė. Generavimo skirstiniai ir atitinkamos SA algoritmo charakteristikos

Tankis	Tikimybė $F(z) = P(Z < z)$	$\rho_k, T_k$
(a) $p(z, T_k) = \frac{T_k}{\pi(z^2 + T_k^2)}$	$P(Z < z, T_k)$ $= \frac{1}{\pi}(\arctg(\frac{z}{T_k}) + \frac{\pi}{2})$	$\rho_k = \rho_0/k^{\gamma/4n}$ $T_k = T_0/k^{1/n}$
(b) $p(z, T_k)$ $= \frac{T_k^{1/m}}{2m[ z +T_k]^{(m+1)/m}}$	$P(Z < z, T_k)$ $= \frac{1}{2\left(1-\frac{z}{T_k}\right)^{1/m}}, z < 0$ $P(Z < z, T_k)$ $= 1 - \frac{1}{2\left(\frac{z}{T_k}+1\right)^{1/m}}, z > 0$	$\rho_k = \rho_0/k^{\gamma m/\lambda(m+1)n}$ $T_k = T_0/k^{m/n}$

ir kitus parametrus. Padarę tinkamas išvadas, parinkę tinkamus parametrus, algoritmus ir metodus galime taikyti ir kitoms funkcijoms, kitiems optimizavimo uždaviniams spręsti. Buvo naudojamos šios testinės funkcijos: *Branino* (turi 3 globalius ekstremumus), *Rastrigino* (maždaug 50 lokalinių ekstremumų ir vienas globalus), *Goldšteino–Praiso* (4 lokalūs ekstremumai ir vienas globalus) [5].

Buvo tiriamos šios algoritmo efektyvumo charakteristikos: minimizuojamos funkcijos reikšmė bei globalaus optimumo radimo tikimybė po tam tikro iteracijų skaičiaus. Šios charakteristikos buvo vertinamos Monte–Karlio metodu, atliekant  $N$  nusileidimų po  $K$  iteracijų ( $N = 1000$ , kai  $K \leq 3000$ ,  $N = 500$ , kai  $3000 < K \leq 10000$  ir  $N = 100$ , kai  $K > 10000$ ). Efektyvumo charakteristikų pasikliautinieji intervalai buvo nustatomi remiantis normaline aproksimacija. Globalaus optimumo radimo tikimybė buvo vertinama apskaičiuojant optimizavimo taško patekimo dažnumą į globalaus optimumo aplinką:  $|f_k - f^*| < \varepsilon$ . Pradinis taškas buvo parenkamas atsitiktinai.

Modeliuojant SA algoritmą testinėms funkcijoms su dviem skirtiniais bei manipuliujant įvairiais leidžiamais keisti parametrais, buvo siekiama išsiaiškinti:

- kuris iš duotų skirstinių užtikrina spartesnį konvergavimą į globalų minimumą pagal funkcijos reikšmę;
- kokios yra „nusileidimo“ į globalų minimumą tikimybės ir kaip jas gali paveikti tam tikrų parametrų keitimas;
- koks reikalingas iteracijų skaičius, kad surasti globalų minimumą su reikalinga tikimybe.

Tyrimų metu naudotos konkrečios parametru reikšmės:  $\lambda = 2$ ,  $\gamma = 0,3$  (a),  $\gamma = 0,9$  (b),  $\rho_0 = 0,01$  (Goldšteino–Praiso ir Rastrigino funkcijoms),  $\rho_0 = 0,1$  (Branino funkcijai),  $T_0 = 10$ . (Jie buvo keičiami, bet su šiomis reikšmėmis gauta pastebimai gerų rezultatų.)

## Modeliavimo rezultatai

Modeliavimo rezultatai pateikti lentelėse. Matyti, jog naudojant (b) skirstinį konvergavimas į globalų minimumą pagal funkcijos reikšmę yra spartesnis (2 lentelė). Buvo

2 lentelė. Konvergavimas į globalų minimumą pagal funkcijos reikšmę  $F_k$ 

Iteracijų skaičius	$F_k$ reikšmės					
	Branino f-ja		Goldšteino–Praiso f-ja		Rastringo f-ja	
	(a) skirst.	(b) skirst.	(a) skirst.	(b) skirst.	(a) skirst.	(b) skirst.
100	1,41265	0,052039	13,45722	9,87812	-0,40869	-1,67522
500	0,83006	0,417289	3,75233	5,53644	-1,20333	-1,94236
1000	0,68788	0,406829	3,36933	4,73926	-1,32400	-1,98219
3000	0,54042	0,401299	3,16755	3,78732	-1,64010	-1,99647
10000	0,48771	0,39878	3,10922	3,00125	-1,79196	-1,99814
30000	0,44670	0,39828	3,05393	3,00038	-1,90625	-1,99957
Glob. min.	0,397887		3,0		-2,0	

3 lentelė. Patekimo į globalųjį minimumą tikimybės Goldšteino–Praiso funkcijai ( $\varepsilon = 0.01$ )

Iteracijų skaičius	Patekimo į globalųjį minimumą tikimybės		
	m = 2	m = 3	m = 4
100	0,025 ± 0,008	0,160 ± 0,019	0,248 ± 0,023
200	0,145 ± 0,018	0,482 ± 0,026	0,427 ± 0,026
300	0,261 ± 0,023	0,598 ± 0,026	0,495 ± 0,026
500	0,485 ± 0,026	0,627 ± 0,025	0,527 ± 0,026
1000	0,764 ± 0,022	0,658 ± 0,025	0,530 ± 0,026

nagrinėjama parametru  $m$  įtaka konvergavimo greičiui (3 lentelė).

Patekimo į globalųjį minimumą tikimybės Goldšteino–Praiso funkcijai:

1) Kai  $m = 2$ . Garantuoja didesnes patekimo į globalųjį minimumą tikimybes nei su kitomis parametru  $m$  reikšmėmis, ypač, jei norime didesnio tikslumo. Ši parametru reikšmė rekomenduojama, kai iteracijų skaičius didelis. Tikimybės, esant mažam iteracijų skaičiui, auga lėčiau nei prie didesnių  $m$  reikšmių.

2) Kai  $m = 3$ . Garantuoja didesnes patekimo į globalųjį minimumą tikimybes, kai iteracijų skaičius nedidelis. Didinant iteracijų skaičių, tikimybės auga lėtai. Kai iteracijų skaičius yra 1000 ir daugiau, rekomenduojama parametru reikšmę  $m = 2$ .

3) Kai  $m = 4$ . Garantuoja dar didesnę globalaus minimumo suradimo tikimybę nei atvejais  $m = 2$  ir  $m = 3$ , kai iteracijų skaičius mažas (100).

Iš šių trijų atvejų akivaizdu, kad  $m = 3$  ir  $m = 4$  atvejais konvergavimas yra greitesnis, bet su „bloga“ tikimybe, tuo tarpu  $m = 2$  atveju konvergavimas lėtesnis, bet tikimybė gana didelė.

Goldšteino–Praiso funkcijai modeliavimo būdu buvo nustatytos patekimo į lokaliuosius minimumus ir į globalųjį minimumą tikimybės. Buvo naudojamas (b) skirstinys, kuris užtikrina spartesnį konvergavimą (4 lentelė).

Kaip matyti iš šio tyrimo, algoritmas praktiškai niekada „neužstringa“ 1-ame ir 4-ame lokaliame minimume. „Užstrigimo“ kituose dviejuose lokaliuose minimumuose ti-

4 lentelė. Patekimo į lokaliuosius minimumus ir globalųjį minimumą tikimybės Goldšteino–Praiso funkcijai ( $m = 2$ ,  $\varepsilon = 0,1$ , iki 1000 realizacijų)

Iteracijų skaičius	Patekimo į globalųjį minimumą tikimybės				
	Į lok. min. $F(1, 2; 0, 8)$ = 840	Į lok. min. $F(1, 8; 0, 2)$ = 84	Į lok. min. $F(-0, 6; -0, 4)$ = 30	Į lok. min. $F(-0, 4; -0, 6)$ = 35	Į glob. min. $F(0; -1) = 3$
	100	0	0,003	0,005	0,111 ± 0,016
300	0	0,011	0,012	0	0,799 ± 0,021
500	0	0,016	0,016	0	0,948 ± 0,012
1000	0	0,017	0,009	0	0,973 ± 0,008
3000	0	0,007	0,003	0	0,984 ± 0,007
5000	0	0,002	0	0	0,993 ± 0,004
10000	0	0	0	0	1

5 lentelė. Globalaus minimumo, kai  $\varepsilon = 0,001$  suradimo tikimybės Goldšteino–Praiso funkcijai

Iteracijų skaičius	Tikimybė
1000	0,09 ± 0,047
5000	0,32 ± 0,077
10000	0,55 ± 0,082
20000	0,79 ± 0,067
30000	0,93 ± 0,042
50000	0,97 ± 0,028

kimybės taip pat mažos, bet sąlyginai yra didžiausios, kai iteracijų skaičius nedidelis (300–1000). Esant dideliam iteracijų skaičiui, algoritmas su tikimybe artima vienetui nurodytu tikslumu patenka į globalų minimumą.

Ištirta ir globalaus minimumo suradimo su dideliu tikslumu tikimybė Goldšteino–Praiso funkcijai. Parinktos parametru reikšmės  $\varepsilon = 0.001$ ,  $m = 2$ . Atlikta 100 realizacijų kiekvienam atvejui. Kaip matyti iš tyrimo rezultatų, iteracijų skaičių parinkus 30000 ir didesnį, tikslaus minimumo suradimo tikimybės gana didelės (artimos vienetui) (5 lentelė).

**Pastaba.** 3, 4 ir 5 lentelėse pasikliautinieji intervalai buvo nustatyti remiantis normaline aproksimacija.

## Išvados

Galima išitikinti, kad Pareto tipo modeliai su „sunkių uodegų“ savybe garantuoja didesnę globalaus optimimo suradimo tikimybę. Todėl šių modelių taikymas suteikia galimybę pagerinti euristinių algoritmų efektyvumą.

Reikia remtis teoriniais rezultatais ([2]), kad īvairiems skirtiniams modeliams turime parinkti tam tikras atitinkamas  $\rho_k$  ir  $T_k$  sekų atnaujinimo funkcijas.

Algoritmo efektyvumui padidinti, pirmiausia (kai iteracijų skaičius yra mažas) reiktu parinkti mažą parametru  $\alpha$  reikšmę, vėliau (didėjant iteracijų skaičiui) parametru  $\alpha$  reikšmę rekomenduojame didinti.

## Literatūra

- [1] A. Janicki, A. Weron, *Simulation and Chaotic Behavior of Stable Processes*, Marcell Dekker, N.Y. (1994).
- [2] R.L. Yang, Convergence of the simulated annealing algorithm for continuous global optimization, *Journal of Optimization Theory and Applications*, **104**(3), 691–716 (2000).
- [3] M. Locatelli, Simulated annealing algorithms for continuous global optimization: convergence conditions, *Journal of Optimization Theory and Applications*, **104**(1), 121–133 (2000).
- [4] M. Lundy, A. Mees, Convergence of an annealing algorithm, *Mathematical Programming*, North-Holland, **34**, 111–124 (1986).
- [5] A. Čilinskas, *Global optimization*, Vilnius, Mokslas (1986) (in Russian).
- [6] G. Dzemyda, E. Senkienė, Convergence of the parameter clustering based on the simulated annealing, *Informatica*, **8**(4), 465–476 (1997).
- [7] L. Sakalauskas, Non-linear stochastic programming by Monte-Carlo estimators, *European Journal on Operational Research*, **137**, 558–573 (2002).

## Parrett's type models in simulated annealing algorithms

G. Felinskas, L. Sakalauskas

In this paper a simulated annealing algorithm for continuous global optimization is considered. There are a lot of theoretical research and very few computer modeling of efficiency of this algorithm. Modeling results, recommendations for efficiency and accuracy of the SA algorithm are given in the paper.