

# KOMPAKTNÍ DIFERENCIÁLNÍ EVOLUCE

Mgr. Michal Král

*Katedra matematiky, Přírodovědecká fakulta, Ostravská univerzita v Ostravě,  
30. dubna 22, 701 03 Ostrava, 607 248 130, p11145@student.osu.cz*

## Abstrakt

Práce pojednává o kompaktní diferenciální evoluci a její možné implementaci v prostředích Matlab a GNU Octave. Tato varianta diferenciální evoluce je testována na sadě testovacích funkcí.

**Klíčová slova:** *Diferenciální evoluce; mutace; křížení; selekce; ořezané normální rozdělení*

## Úvod

Problém globální optimalizace se řeší v mnoha praktických úlohách. Definujme ho následovně. Pro danou účelovou funkci  $f : D \rightarrow \mathbb{R}$ ,  $D \subset \mathbb{R}^d$  hledáme bod globálního minima  $\mathbf{x}^* = \arg \min_{\mathbf{x} \in D} f(\mathbf{x})$  v souvislé oblasti  $D = \prod_{i=1}^d \langle a_i, b_i \rangle$ ,  $a_i < b_i$ ,  $i = 1, \dots, d$ . Samozřejmě za předpokladu, že pro  $\forall \mathbf{x} \in D$  umíme vyhodnotit účelovou funkci  $f(\mathbf{x})$  s požadovanou přesností.

Jelikož neexistuje deterministický algoritmus obecně řešící tento problém (jedná se o NP-obtížný problém), nastal rozvoj stochastických algoritmů. Ty jsou velmi často schopny nalézt prakticky použitelné řešení v rozumném čase. Jedním z těchto algoritmů je diferenciální evoluce (DE), která se stala velmi populární pro svou jednoduchost a dosažené výsledky při řešení mnoha různých problémů z praxe.

DE náleží do třídy stochastických algoritmů nazvané evoluční algoritmy. Ty pracují s populací jedinců (bodů) reprezentujících možná řešení problému v oblasti  $D$  a využívající evoluční operátory, kterými jsou mutace, křížení a selekce. Principem DE je pohybovat populaci v oblasti směrem k nejlepšímu řešení za pomoci evolučních operátorů. Algoritmus DE vytváří nové generace jedinců tak, že každému jedinci ze staré generace vytvoří jeho konkurenta a do nové generace je začleněn lepší z této dvojice podle hodnoty účelové funkce. Více informací o DE viz [4].

DE uchovává neustále v paměti celou svou populaci jedinců. Doporučuje se volit populaci o velikosti  $10d$ , což s rostoucí dimenzí řešeného problému je pro slabší hardware limitujícím faktorem pro paměťové nároky či výpočetní výkon. Proto byla navržena kompaktní diferenciální evoluce (KDE) [1], která i přes tato omezení je schopna provést optimalizační proces.

KDE je v jistém smyslu odlehčenou verzí DE, jelikož nepracuje s celou populací jedinců. Když je nutné získat jedince, protože si ho žádají evoluční operátory, dojde k jeho postupnému vygenerování po jednotlivých souřadnicích  $x_i$ . Souřadnice jsou popsány pomocí hustot pravděpodobností s parametry středních hodnot  $\mu_i$  a směrodatných odchylek  $\sigma_i$ . Principem KDE je adaptace parametrů  $\mu_i$  a  $\sigma_i$  proměnných  $x_i$ . Algoritmus se snaží hodnotami  $\sigma_i$  přiblížit k nule a hodnotami  $\mu_i$  k nejlepšímu řešení. Tedy v paměti stačí uchovávat pouze  $2d$  hodnot.

## Generování jedince

Autoři článku [1] bez újmy na obecnosti vychází ze vzorce pro ořezanou hustotu pravděpodobnosti (truncated Gaussian PDF) pro  $i$ -tou souřadnici  $x_i \in \langle -1, 1 \rangle$  bodu  $\mathbf{x}$ . Výsledný vztah pro její vygenerování je ve tvaru

$$x_i = \text{CDF}^{-1}(\text{rand}(0, 1)),$$

kde  $\text{CDF}^{-1}$  je inverzní funkce (kvantilová funkce) k distribuční funkci CDF (cumulative distribution function) pro hustotu PDF a  $\text{rand}(0, 1)$  je náhodné číslo z rovnoměrného rozdělení na

intervalu  $\langle 0, 1 \rangle$ . Je nutné dodat, že pokud by se jednalo o obecný interval  $\langle a_i, b_i \rangle$ , musela by se provést transformace souřadnice  $x_i$  do tohoto intervalu.

Výhodnější je zvolit pro ořezanou hustotu pravděpodobnosti  $i$ -té souřadnice  $x_i \in \langle a_i, b_i \rangle$  vztah (1), viz [3]. Souřadnice se netransformují a prostředí Matlab či GNU Octave obsahují již implementované potřebné funkce pro její výpočet.

$$\text{PDF}(x_i | \mu_i, \sigma_i) = \frac{e^{-\frac{(x_i - \mu_i)^2}{2\sigma_i^2}}}{\sqrt{2\pi}\sigma_i \left( \Phi\left(\frac{b_i - \mu_i}{\sigma_i}\right) - \Phi\left(\frac{a_i - \mu_i}{\sigma_i}\right) \right)} \quad (1)$$

Tedy výsledný vztah pro vygenerování  $i$ -té souřadnice  $x_i$  bodu  $\mathbf{x}$  je ve tvaru

$$x_i = \sigma_i \Phi^{-1} \left[ \left( \Phi\left(\frac{b_i - \mu_i}{\sigma_i}\right) - \Phi\left(\frac{a_i - \mu_i}{\sigma_i}\right) \right) \text{rand}(0, 1) + \Phi\left(\frac{a_i - \mu_i}{\sigma_i}\right) \right] + \mu_i, \quad (2)$$

kde funkce  $\Phi(\alpha) := \text{normcdf}(\alpha)$  a  $\Phi^{-1}(\alpha) := \text{norminv}(\alpha)$  jsou distribuční a kvantilovou funkcí pro hodnotu  $\alpha$  z normovaného normálního rozdělení s parametry  $\mu = 0$  a  $\sigma^2 = 1$ .

## Popis algoritmu

Algoritmus KDE se skládá z pěti důležitých částí zvýrazněných podtržením v pseudokódu níže, které budou postupně vyloženy. Popisovaná verze se označuje pe-cDE/rand/1/bin, viz [1]. Jedná se o tzv. trvale elitářskou verzi. To znamená, že na začátku algoritmu se vygeneruje náhodně bod **elite** reprezentující nejlepší řešení, který je pak v každém cyklu porovnáván se svým konkurentem  $\mathbf{x}_{off}$ , který vzniká pomocí operátorů mutace a křížení. Vyrovná-li se mu hodnotou účelové funkce nebo jej předčí, stane se  $\mathbf{x}_{off}$  novým **elite**.

t=0

Inicializace parametrů rozdělení

generuj **elite** (nejlepší řešení) pomocí parametrů rozdělení

**while** (nesplněná ukončovací podmínka) **do**

Mutace

Křížení

Selekce

Adaptace parametrů rozdělení

t=t+1

**end while**

Existuje i verze KDE nazvaná ne-cDE/rand/1/bin. Tato verze je opakem elitářské verze, tedy **elite** je po pevně zvoleném nepřerušeném počtu vítězných iterací  $\eta$  nahrazen aktuálním  $\mathbf{x}_{off}$ .

## Inicializace parametrů rozdělení

Inicializují se hodnoty středních hodnot  $\mu_i$  a směrodatných odchylek  $\sigma_i$  jednotlivých souřadnic  $x_i$  popsaných svými hustotami. Střední hodnoty se nastavují na nulovou hodnotu a hodnoty směrodatných odchylek na nějaké velké kladné číslo  $\lambda$ . Volba tohoto parametru závisí na zadané optimalizační úloze.

## Mutace

Užitá mutace se označuje jako rand/1. Vygenerují se tři různé body  $\mathbf{x}_r$ ,  $\mathbf{x}_s$  a  $\mathbf{x}_t$ , ze kterých podle vztahu (3) dostaneme bod  $\mathbf{x}'_{off}$ ,

$$\mathbf{x}'_{off} = \mathbf{x}_t + F(\mathbf{x}_r - \mathbf{x}_s). \quad (3)$$

Parametr  $F \in \langle 0, 2 \rangle$  se nazývá mutační konstanta a doporučuje se volit její hodnotu v rozmezí 0,3 – 0,9.

## Křížení

Použito je binomické křížení. Křížením bodů  $\mathbf{x}'_{off}$  s **elite** vzniká nový bod (konkurent)  $\mathbf{x}_{off}$  a to tak, že každá jeho souřadnice  $elite_i$  je nahrazena souřadnicí  $x'_{off_i}$  s pravděpodobností CR. Pokud žádná souřadnice bodu **elite** nebyla nahrazena souřadnicí bodu  $\mathbf{x}'_{off}$  nebo nastali případ volby CR = 0, pak se vybere náhodně jedna souřadnice  $x'_{off_j}$ ,  $j \in \{1, \dots, d\}$ , která nahradí  $elite_j$ . Parametr CR  $\in \langle 0, 1 \rangle$  se nazývá práh křížení a je doporučeno jej volit v rozmezí 0,8 – 0,9. Binomické křížení je schématicky znázorněno níže.

$$x_{off_i} = \begin{cases} x'_{off_i}, & \text{if } \text{rand}(0, 1) \leq \text{CR} \vee i = j \\ elite_i, & \text{if } \text{rand}(0, 1) > \text{CR} \wedge i \neq j \end{cases}$$

## Selekce

Zde se porovnají body  $\mathbf{x}_{off}$  a **elite**. Podle hodnoty jejich účelové funkce se určí vítěz a poražený. Pokud zvítězí  $\mathbf{x}_{off}$ , stane se novým **elite**. Selektce je schématicky znázorněna níže.

$$\mathbf{elite} = \begin{cases} \mathbf{x}_{off}, & \text{if } \underbrace{f(\mathbf{x}_{off})}_{winner} \leq \underbrace{f(\mathbf{elite})}_{loser} \\ \mathbf{elite}, & \text{if } \underbrace{f(\mathbf{x}_{off})}_{loser} > \underbrace{f(\mathbf{elite})}_{winner} \end{cases}$$

## Adaptace parametrů rozdělení

V této části algoritmu se adaptují parametry  $\mu_i^t$  a  $\sigma_i^t$ . Vystupuje zde nový parametr  $N_p$ , který udává počet jedinců naší virtuální populace. Adaptivní vztahy jsou:

$$\mu_i^{t+1} = \mu_i^t + \frac{1}{N_p} (winner_i - loser_i), \quad (4)$$

$$\sigma_i^{t+1} = \sqrt{(\sigma_i^t)^2 + (\mu_i^t)^2 - (\mu_i^{t+1})^2 + \frac{1}{N_p} (winner_i^2 - loser_i^2)}. \quad (5)$$

Nastane-li případ, že parametr  $\mu_i^{t+1}$  v (4) nabude hodnoty mimo interval  $\langle a_i, b_i \rangle$ , pak máme různé možnosti, jak nastalou událost řešit. Můžeme např.  $\mu_i^{t+1}$  náhodně vygenerovat z intervalu  $\langle a_i, b_i \rangle$ , lze použít zrcadlení a nebo můžeme tento stav ignorovat. Zvolme možnost zrcadlení.

Rozveďme dále adaptivní vztah (5). Aby výraz pod odmocninou měl smysl, společně s podmínkou plynoucí pro  $\sigma_i^{t+1}$  z (2) musí platit, že  $|(\mu_i^t)^2 - (\mu_i^{t+1})^2 + \frac{1}{N_p} (winner_i^2 - loser_i^2)| < (\sigma_i^t)^2$ . Pak lze vždy provést adaptaci parametrů  $\sigma_i^t$  a vztah (5) lze přepsat do pseudokódu:

```

if  $|(\mu_i^t)^2 - (\mu_i^{t+1})^2 + \frac{1}{N_p} (winner_i^2 - loser_i^2)| < (\sigma_i^t)^2$  then
     $(\sigma_i^{t+1})^2 = (\sigma_i^t)^2 + (\mu_i^t)^2 - (\mu_i^{t+1})^2 + \frac{1}{N_p} (winner_i^2 - loser_i^2)$ 
else
    neadaptuj  $\sigma_i^t$ 
end if

```

## Experimentální výsledky

Pro testovací účely byla vybrána šestice různě obtížných funkcí pro hledání globálního minima, včetně zvolených oblastí z [2]. Dimenze testovacích úloh byly zvoleny  $d = 5$  a  $d = 10$ . Parametry byly zvoleny  $F = 0,9$ ,  $CR = 0,9$  a  $N_p = 2d$ . Parametr  $\lambda$  byl volen na základě

Tabulka 1. Experimentální výsledky

$\varepsilon$	funkce	d=5		d=10	
		pr. rel. ch. $\pm$ sm. odch.	$f_{best}$	pr. rel. ch. $\pm$ sm. odch.	$f_{best}$
$\varepsilon_1$	Ackley	2.00e-03 $\pm$ 3.50e-03	1.05e-04	3.52e+00 $\pm$ 6.74e+00	3.29e-05
	Dejong1	4.05e-06 $\pm$ 9.43e-06	1.49e-09	2.29e-07 $\pm$ 4.09e-07	1.15e-09
	Griewank	1.75e-01 $\pm$ 1.28e-01	1.23e-02	1.31e-01 $\pm$ 2.70e-02	9.16e-02
	Rastrigin	4.98e-01 $\pm$ 7.4e-01	4.10e-07	9.95e-01 $\pm$ 7.71e-01	7.21e-06
	Rosenbrock	1.42e+00 $\pm$ 1.10e+00	2.01e-02	8.76e+00 $\pm$ 14.22e+00	9.50e-03
	Schwefel	-8.92e-02 $\pm$ 7.71e-02	-2.10e+03	-1.40e-01 $\pm$ 8.29e-02	-4.19e+03
$\varepsilon_2$	Ackley	3.10e-04 $\pm$ 8.47e-04	7.19e-08	8.91e-01 $\pm$ 3.88e+00	1.06e-07
	Dejong1	2.21e-07 $\pm$ 7.16e-07	1.40e-14	1.98e-12 $\pm$ 4.54e-12	1.56e-16
	Griewank	1.19e-01 $\pm$ 7.90e-02	9.90e-03	1.24e-01 $\pm$ 8.05e-02	2.46e-02
	Rastrigin	5.97e-01 $\pm$ 9.12e-01	3.77e-13	4.98e-01 $\pm$ 5.89e-01	6.68e-13
	Rosenbrock	1.05e+00 $\pm$ 1.12e+00	6.01e-04	5.97e+00 $\pm$ 5.46e+00	4.70e-02
	Schwefel	-9.11e-02 $\pm$ 7.07e-02	-2.10e+03	-1.15e-01 $\pm$ 8.31e-02	-4.19e+03

konkrétní úlohy. Pro všechny zadané oblasti platí  $b_i = -a_i$  a proto  $\lambda_i = 2\lceil b_1 \rceil$ . Ukončovací podmínka byla sestavena jako výraz  $(\max(\sigma_1^{t+1}, \dots, \sigma_d^{t+1}) < \varepsilon \wedge t < 5000d)$ , kde  $\varepsilon_1 = 1,0 \times 10^{-3}$  a  $\varepsilon_2 = 1,0 \times 10^{-6}$ . Pro každou vybranou funkci za daných parametrů, dimenze a ukončovací podmínky bylo provedeno 20 spuštění programu. Experimentální výsledky zobrazuje tabulka 1, kde jsou uvedeny průměry relativních chyb (pr. rel. ch.) s jejich směrodatnou odchylkou (sm. odch.) a hodnoty účelové funkce  $f_{best}$  nejlepšího nalezeného minima.

## Závěr

KDE vždy našla použitelné řešení vyjma Rosenbrockovy a Griewankovy funkce, kde je nutné snížit  $\varepsilon$  a navýšit maximální počet cyklů k nalezení lepšího řešení. Experimentální výsledky na testovacích úlohách potvrdily, že volbou menšího  $\varepsilon$  se dosáhne lepších řešení.

## Poděkování

Rád bych poděkoval doc. Ing. Josefu Tvrđíkovi, CSc. za cenné připomínky a neutuchající zásobu pozitivní energie ke studiu KDE.

## Literatura

- [1] Mininno, E., Neri, F., Cupertino, F., Naso, D. *Compact differential evolution*, IEEE Transactions on Evolutionary Computation, vol. 15, no. 1, February 2011, pp. 32-54
- [2] Molga, M., Smutnicki, C. *Test functions for optimization needs* [online]. May 2005 [cit. 10. dubna 2012]. Dostupné na World Wide Web: <http://www.zsd.ict.pwr.wroc.pl/files/docs/functions.pdf>
- [3] *Truncated normal distribution* [online]. 2012 [cit. 10. dubna 2012]. Dostupné na World Wide Web: <http://www.nrand.com/truncated-normal-distribution/>
- [4] Zelinka, I., Oplatková, Z., Šeda, M., Ošmera, P., Včelař, P. *Evoluční výpočetní techniky-principy a aplikace*. 1. vydání. Praha: BEN-Technická literatura, 2009, kap. 11, str. 235-245. ISBN 978-80-7300-218-3

## Abstract

The work deals with the compact differential evolution and its possible implementation in environment Matlab and GNU Octave. This variant of differential evolution is tested on benchmark test functions.