

# POUŽITÍ NAVÁDĚNÉHO EVOLUČNÍHO ALGORITMU K OPTIMALIZACI PARAMETRŮ PSD REGULÁTORŮ (USE OF GUIDING EVOLUTIONARY ALGORITHM FOR OPTIMIZATION OF PSD REGULATOR PARAMETERS)

Petr Siblík<sup>1</sup>

<sup>1</sup> Ústav přístrojové a řídicí techniky, fakulta strojní, ČVUT v Praze, siblpetr@gmail.com

*Abstrakt: Článek nejprve představuje „naváděný evoluční algoritmus“ („guiding evolutionary algorithm“, GEA) určený pro řešení problémů globální optimalizace. Dále je představeno využití tohoto algoritmu pro optimalizaci parametrů diskrétních regulátorů. Následně je prostřednictvím simulovaných soustav otestována funkčnost a spolehlivost vytvořené optimalizační metody. V poslední části je algoritmus otestován také na reálné experimentální úloze.*

*Klíčová slova: naváděný evoluční algoritmus, GEA, Optimalizace řízení, PSD regulace*

## 1. Úvod

V dnešní době je nemožné si představit výrobu bez automatizovaných procesů. Mezi stěžejní úseky automatizace patří převážně vhodné nastavení regulátoru příslušného řízeného procesu. V praxi je využívána široká škála nastavovacích metod, které každá skrývá jisté úskalí. Například experimentální metody mohou vést k nebezpečnému poškození soustavy, zatímco analytické zase potřebují přesnou matematicko-fyzikální analýzu systému, což může být pro některé systémy velmi složitý úkol. Velmi často se také využívají metody kombinující oba zmíněné přístupy, čímž eliminují jejich negativa.

Bezpečné seřízení regulátoru u neznámých (matematicko-fyzikálně nepopsaných) soustav je velice lákavá myšlenka. Velkou pomocí v této oblasti představují nejrůznější optimalizační algoritmy, které prostřednictvím simulovaných běhů regulované soustavy naleznou optimální nastavení regulátoru pro danou soustavu.

Cílem této práce je využití optimalizační metody „naváděný evoluční algoritmus (Guiding Evolutionary Algorithm, GEA) na hledání optimálních parametrů vybraných regulátorů. Schopnost nalezení optimálního nastavení regulátorů je nejprve testována na simulovaných soustavách. Optimalizační simulace jsou prováděny na aproximacích zmíněných soustav. Nepřesnost mezi původní soustavou a její aproximací simuluje reálné využití v praxi, kdy model soustavy, na kterém je prováděna optimalizace, také dokonale neodpovídá reálné soustavě. Na závěr je optimalizace otestována na reálné experimentální úloze.

## 2. Naváděný evoluční algoritmus

Guiding Evolutionary Algorithm with Greedy Strategy [1] (GEA) byla představena týmem Cao, Xu & Goodman v roce 2016 pro řešení globálních optimalizačních problémů. Jedná se o metaheuristický algoritmus založený na dvou dříve vytvořených optimalizačních metodách: Netopýří algoritmus (Bat Algorithm, Yang, 2010) [2] a Optimalizace hejnem částic (Particle Swarm Optimization, Kennedy & Eberhart, 1995) [3]. Kombinací těchto algoritmů získává GEA výhody každého z nich a zároveň ještě vylepšuje schopnost konvergence ke globálnímu optimu.

Stejně jako jiné evoluční algoritmy pracuje GEA s populací  $n$  jedinců, jenž reprezentují  $d$  optimalizovaných parametrů ve formě vektoru.

$$x_i (i = 1, 2, \dots, n) = (x_{i1}, x_{i2}, \dots, x_{id}) \quad (1)$$

Kvalita či vhodnost jedince je posuzována prostřednictvím kritériální funkce (2). Hledání globálního optima – řešení optimalizační úlohy pak probíhá skrze minimalizaci nebo maximalizaci této funkce.

$$f(x), x = (x_1, x_2, \dots, x_d) \quad (2)$$

Jedinec s nejlepší kritériální funkcí v populaci je označován jako nejlepší jedinec  $x^*$ .

Optimalizace, hledání nejlepšího řešení, probíhá postupnou aplikací tří po sobě následujících operací (křížení, mutace a lokální hledání), které modifikují optimalizované parametry jedinců.

## 2.1 Křížení

Křížení je operace zahajující modifikaci jedince. V rámci naváděného evolučního algoritmu zprostředkovává hlavní mechanismus optimalizace a je realizováno podle následujícího výrazu:

$$x_i^t = x_i^{t-1} + (x_* - x_i^{t-1}) \cdot \beta, \quad (3)$$

kde  $x_i^t$  je nový jedinec,  $x_i^{t-1}$  je modifikovaný jedinec  $x_i$  v předchozí generaci,  $x_*$  je aktuální nejlepší jedinec a  $\beta$  je délka kroku přírůstku parametrů – náhodná hodnota ze zadaného rozsahu s uniformním rozdělením. Aktuální nejlepší jedinec  $x^*$  je zkombinován s aktuálně modifikovaným jedincem  $x_i^{t-1}$  za vzniku nového jedince  $x_i^t$ . Efektivnost této operace spočívá v tom, že se jedinci v každé iteraci „pohybují“ směrem k aktuálnímu nejlepšímu jedinci, přičemž dlouhodobě společně putují ke globálnímu/lokálnímu optimu.

## 2.2 Mutace

Přestože je křížení velmi účinný optimalizační nástroj, jeho nevýhodou je jeho velká pravděpodobnost uvíznutí v lokálním optimu. Z toho důvodu je do algoritmu zařazena mutace daná vzorcem (4). Náhodná změna parametrů jedince zvyšuje rozmanitost populace a tím zprostředkovává únik z lokálního optima.

$$x_i^t = x_i^t + \epsilon M, \quad (4)$$


kde  $x_i^t$  je jedinec po křížení,  $\epsilon$  je náhodné číslo s uniformním rozdělením  $[-1,1]$  a  $M$  je vektor určující rozsah mutace. Za předpokladu, že rozsah  $j$ -té dimenze jedince  $x$  je  $[a, b]$  pak:

$$M_j = \max(x_{ij}^t - a, b - x_{ij}^t), j = (1, 2, \dots, d) \quad (5)$$

Nebezpečí uvíznutí v lokálním optimu prostřednictvím křížení hrozí převážně v pozdějších generacích optimalizace. Proto je výhodné mutaci aplikovat až v těchto pozdějších iteracích algoritmu. Z toho důvodu je mutace jedince zatížena pravděpodobností  $p$  která se s přibývajícimi generacemi zvyšuje. Procentuální pravděpodobnost mutace  $p$  je dána vztahem:

$$p = c \cdot \ln\left(\frac{T_{max}}{T_{max}-t}\right) \quad (6)$$

kde  $c$  je limitující parametr,  $T_{max}$  je celkový počet generací,  $t$  je aktuální generace. Za předpokladu, že  $T_{max} = 50$  a  $c = 0.2$ , pak se pravděpodobnost  $p$  zvyšuje v průběhu generací podle Obr. 1.



Obr. 1. Pravděpodobnost mutace

### 2.3 Lokální hledání

Funkce lokálního hledání spočívá v důkladném prozkoumání blízkého okolí nejlepšího jedince. Značně přínosná je v momentě, kdy je již nalezeno okolí globálního optima a pomáhá tak nalézt to skutečně nejlepší řešení. Z toho důvodu je opět vhodné aplikovat lokální hledání až v pozdějších generacích, a proto je také spjato s pravděpodobností  $p$ . Předpis lokálního hledání je definován rovnicí:

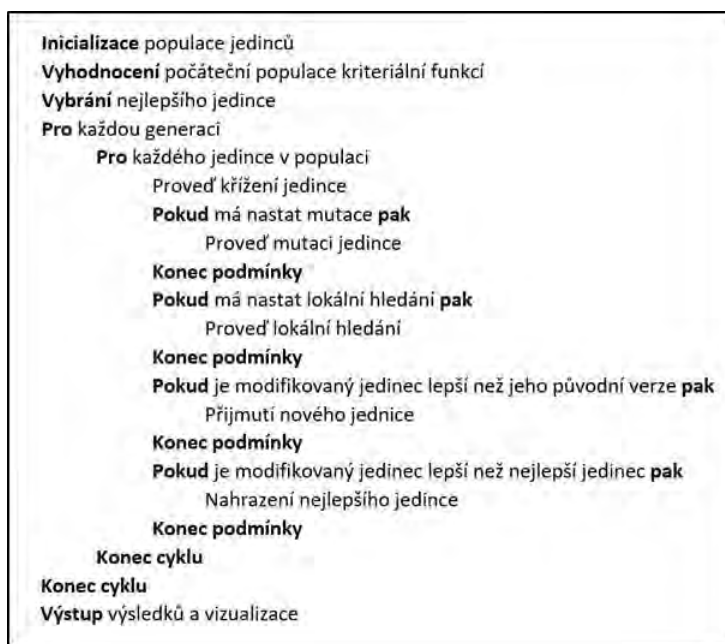
$$x_i^t = x_* + \epsilon L, \quad (7)$$

Kde  $x_*$  je aktuální nejlepší jedinec,  $\epsilon$  je náhodné číslo s uniformním rozdělením  $[-1,1]$  a  $L$  je vektor určující rozsah náhodného pohybu. Za stálého předpokladu, že rozsah  $j$ -té dimenze jedince  $x$  je  $[a, b]$  pak:

$$L_j = l \cdot (b - a) \quad (8)$$

Kde  $l$  je koeficient rozsahu náhodného pohybu.

Následně dojde k výše zmíněnému ohodnocení modifikovaného jedince pomocí kritériální funkce  $f(x)$ . Nové parametry jsou přijmuty pouze v případě, že je modifikovaný jedinec, z hlediska kritériální funkce, v opačném případě jsou jeho parametry navráceny do původního stavu před modifikací. Je-li přijatý jedinec lepší než dosavadní nejlepší jedinec, převezme nový jedinec titul nejlepšího jedince. Následně začne naváděný evoluční algoritmus upravovat dalšího jedince v pořadí, dokud tímto způsobem neprojde celou populací čímž vytvoří novou generaci. Popsaný optimalizační cyklus se iterativně opakuje do té doby, dokud nedojde splnění některé z ukončovacích podmínek (např. dosažení požadované kvality řešení, počet proběhlých generací nebo nalezení nejlepšího možného jedince). Pseudokód naváděného evolučního algoritmu (Guiding Evolutionary Algorithm with Greedy Strategy) je vidět na obrázku 2.



Obr. 2. Pseudokód naváděného evolučního algoritmu

### 3. Aplikace naváděného evolučního algoritmu na optimalizaci diskretních regulátorů

Cílem této práce byla optimalizace parametrů diskretních regulátorů. Konkrétně normálního PSD regulátoru a dvou jeho modifikací PS-D a S-PD, které jsou blíže popsány v [4] (kapitola 4.3). Naváděný evoluční algoritmus byl vytvořen v prostředí programu Matlab. Jedinec  $x$  v této konkrétní aplikaci reprezentuje vektor jednotlivých nastavitelných parametrů regulátoru  $r_0$ ,  $r_i$  a  $r_d$ .

$$x = (r_p, r_i, r_d) \quad (9)$$

Hodnocení jedinců pomocí kritériální funkce je realizováno v prostředí programu Matlab – Simulink. Při hodnocení je provedena simulace reakce regulačního obvodu na jednotkový skok akční veličiny. Kritériální funkce pak hodnotí jak „vhodný“ byl získaný regulační pochod. V této práci bylo využito modifikované kritérium ITAE doplněné o členy minimalizující akční zásah a postihující velké změny akčních veličiny. Předpis této použité kritériální funkce je dán rovnicí (10).

$$f(x) = \int_0^t (C_e \cdot t \cdot |e(t)| + C_u \cdot u(t)^2 + C_{du} \cdot \Delta u) dt, \quad (10)$$

kde  $e(t)$  je regulační odchylka,  $u(t)$  je akční zásah,  $\Delta u$  je diference akčního zásahu,  $t$  je čas simulace,  $C_e$  je váhový koeficient regulační odchylky,  $C_u$  je váhový koeficient akčního zásahu a  $C_{du}$  je váhový koeficient diference akčního zásahu. Správné nastavení koeficientů  $C_e$ ,  $C_u$  a  $C_{du}$  je pro optimalizaci klíčové, jelikož značně ovlivňují výslednou kritériální funkci. Pro obdržení optimálního nastavení regulátoru tak, aby výsledný regulační obvod vyhovoval technologickým požadavkům, je nutné nalézt mezi těmito váhovými koeficienty správnou rovnováhu.

#### 4. Testy na simulovaných soustavách

Testování bylo provedeno na 5 soustavách různých vlastností běžně používaných v praxi pro testování regulátorů. Pro tyto soustavy byla získána aproximace modelem druhého řádu s dopravním zpožděním (SOPTD). Pro získané aproximace bylo prostřednictvím naváděného evolučního algoritmu získáno optimální nastavení parametrů regulátorů. Tyto regulátory byly následně aplikovány na původní systémy. Nepřesnosti mezi původní soustavou a její aproximací simulují reálné využití algoritmu, kdy model využitý pro optimalizaci také nebude dokonale reprezentovat reálnou soustavu.

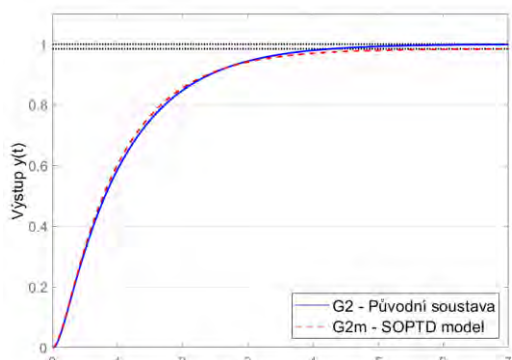
V tomto článku je uveden jeden příklad využití simulované soustavy.

##### 4.1 Systém s dominantním náběhem

Pro soustavu s přenosem (11) byla získána aproximace SOPTD modelem ve tvaru (12). Přechodová charakteristika obou soustav je vidět na obrázku (3). Pro aproximační model  $G_{1m}$  bylo pro každý regulátor provedeno deset optimalizačních běhů. Průměrné hodnoty obdržných parametrů a jejich směrodatné odchylky jsou zaznamenány v tabulce (1).

$$G_1(s) = \frac{1}{(s+1) \cdot (0.1s+1) \cdot (0.01s+1) \cdot (0.001s+1)} \quad (11)$$

$$G_{1m}(s) = \frac{0.9843}{0.1095s^2 + 1.038s + 1} \quad (12)$$




Obr. 3 Porovnání přechodových charakteristik  $G_1$  a  $G_{1m}$


Regulátor	$r_0$	$r_i$	$r_d$	$f_{min}$
PSD	$2.08 \pm 0.17$	$2.00 \pm 0.14$	$0.20 \pm 0.03$	$1.926 \pm 0.017$
PS-D	$1.90 \pm 0.03$	$2.17 \pm 0.03$	$0.00 \pm 0.00$	$1.785 \pm 0.001$
S-PD	$5.54 \pm 0.71$	$13.27 \pm 1.64$	$0.47 \pm 0.14$	$1.829 \pm 0.003$

Tab. 1: Optimalizované parametry regulátorů PSD, PS-D a S-PD pro soustavu  $G_1$

Z hodnot v tabulce (1) je patrné, že optimalizační běhy vedly u každého z regulátorů ke stabilním výsledkům, což je patrné z velmi malých směrodatných odchylek. Pro každý regulátor (PSD, PS-D, S-PD) bylo vybráno nejlepší nastavení parametrů regulátorů a tento regulátor byl použit pro regulaci původní soustavy  $G_1$ . Na obrázku (4) je vidět reakce soustavy na jednotkový skok a na obrázku (5) jsou znázorněny akční zásahy jednotlivých regulátorů.




Obr. 4 Reakce regulované soustavy  $G_2$  na jednotkový skok



Obr. 5 Porovnání akčních zásahů pro systém s dominantním náběhem

## 5. Testy na reálné experimentální úloze

Pro experimentální ověření funkčnosti optimalizačního algoritmu na reálné soustavě byla použita úloha jejíž schéma je na obrázku (6). Cílem byla regulace výšky hladiny pomocí čerpadla P1a. Výška hladiny byla snímána tlakovým senzorem a posílána prostřednictvím řídicí jednotky WinCon do počítače, kde byly v prostředí programu Matlab – Simulink realizované jednotlivé regulátory využité pro regulaci výšky hladiny. Pro reálnou soustavu byla opět získána aproximace modelem druhého řádu s dopravním zpožděním (13), který byl následně využit pro optimalizační simulace.



Obr. 6. Schéma experimentální úlohy

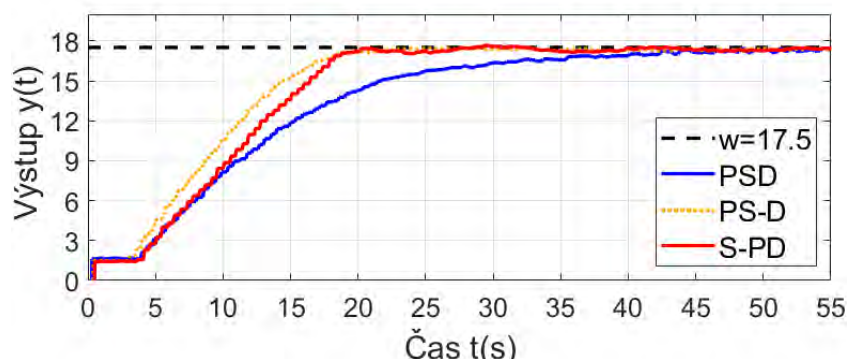
$$G_m(s) = \frac{15,1304}{28,7667s^2 + 119,6823s + 1} \cdot e^{-2,0847s} \quad (13)$$

V tabulce (2) jsou uvedeny průměrné hodnoty a jejich směrodatné odchylky optimalizovaných parametrů získaných v rámci deseti optimalizačních běhů pro každý regulátor. Podle vysoké směrodatné odchylky u parametrů regulátoru i u kritériální funkce jde usoudit, že optimalizační běhy pro PSD a PS-D regulátory podávali nekonzistentní, a tedy neuspokojivé výsledky. To může být způsobeno použitím nevhodných parametrů kritériální funkce pro danou kombinaci regulované soustavy a regulátoru. Oproti tomu výsledky obdržené pro S-PD regulátor se vykazují velkou konzistencí.


Regulátor	$r_0$	$r_i$	$r_d$	$f_{min}$
PSD	$1,57 \pm 0,16$	$0,11 \pm 0,039$	$1,52 \pm 0,66$	$48,853 \pm 21,915$
PS-D	$1,94 \pm 0,32$	$0,10 \pm 0,07$	$2,02 \pm 0,1,59$	$47,208 \pm 22,309$
S-PD	$3,34 \pm 0,05$	$0,53 \pm 0,01$	$2,91 \pm 0,02$	$31,183 \pm 0,215$

Tab. 2: Optimalizované parametry regulátorů PSD, PS-D a S-PD pro aproximační soustavu  $G_m$ 

Pro každý regulátor bylo vybráno nejlepší optimalizované nastavení parametrů a vzniklé regulátory byly použity k regulaci reální experimentální úlohy. Na obrázku (7) jsou vidět obdržené regulační pochody. Na obrázku (8) jsou pak vyobrazeny příslušné průběhy akční veličiny. Přechodové pochody regulátorů PS-D a S-PD jsou si velmi podobné, zatímco regulátor PSD reguluje soustavu nejpomaleji.



Obr. 7. Regule experimentální soustavy pomocí optimalizovaných regulátorů PSD, PS-D a S-PD



Obr. 8. Porovnání akčních zásahů pro regulaci experimentální úlohy

## 6. Závěr

V rámci této práce byl v prostředí MATLAB vytvořen naváděný evoluční algoritmus pro optimalizaci parametrů diskretních regulátorů (PSD, PS-D a S-PD). Taktéž byla vytvořena modifikovatelná kritériální funkce, umožňující respektující technologické požadavky na regulovanou soustavu. Ze simulačních testů této optimalizační metody lze usoudit, že podává velmi konzistentní a stabilní výsledky. Z experimentálního testování je patrné, že optimalizace parametrů PSD a PS-D regulátorů podávala neuspokojivé a nekonzistentní výsledky. Tato skutečnost byla nejspíše způsobena nevodným nastavením váhových koeficientů kritériální funkce. Oproti tomu pro S-PD regulátor byly výsledky velmi konzistentní.

Z výsledků provedených simulací a experimentu na reálné soustavě lze usoudit, že použití naváděného evolučního algoritmu k optimalizaci parametrů regulátorů je díky své snadné použitelnosti a adaptabilitě pro případné využití v praxi lukrativní.

## Poděkování

Tato práce byla podpořena grantem Studentské grantové soutěže ČVUT č. SGS19/158/OHK2/3T/12.

## Literatura

- [1] CAO, Leilei, Lihong XU a Erik D. GOODMAN. *A Guiding Evolutionary Algorithm with Greedy Strategy for Global Optimization Problems*. Computational Intelligence and Neuroscience [online]. 2016, 2016, 1-10 [cit. 2021-9-14]. ISSN 1687-5265. Dostupné z: <https://www.hindawi.com/journals/cin/2016/2565809/>; doi:10.1155/2016/2565809
- [2] EBERHART, R. a J. KENNEDY. *A new optimizer using particle swarm theory*. In: MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science [online]. Nagoya, Japan: IEEE, 1995, s. 39-43 [cit. 2021-4-25]. ISBN 0-7803-2676-8. Dostupné z: <https://ieeexplore.ieee.org/document/494215> . doi:10.1109/MHS.1995.494215



- [3] YANG, Xin-She. *A New Metaheuristic Bat-Inspired Algorithm*. GONZÁLEZ, Juan R., David Alejandro PELTA, Carlos CRUZ, Germán TERRAZAS a Natalio KRASNOGOR, ed. Nature Inspired Cooperative Strategies for Optimization (NICSO 2010) [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010, 2010, s. 65-74 [cit. 2021-4-25]. Studies in Computational Intelligence. ISBN 978-3-642-12537-9. Dostupné z: [https://www.researchgate.net/publication/45913690\\_A\\_New\\_Metaheuristic\\_Bat-Inspired\\_Algorithm](https://www.researchgate.net/publication/45913690_A_New_Metaheuristic_Bat-Inspired_Algorithm). doi:10.1007/978-3-642-12538-6\_6
- [4] SIBLÍK, Petr. *OPTIMALIZACE PARAMETRŮ VYBRANÝCH REGULÁTORŮ POUŽITÍM GEA*. Praha, 2021. Diplomová práce. ČVUT v Praze, Strojní fakulta. Vedoucí práce Hofreiter Milan.
- [5] SALDANHA, Adrian. *Relay feedback identification using GEA for PID control*. Praha, 2020. Diplomová práce. České vysoké učení technické Praha, Fakulta strojní. Vedoucí práce Hofreiter M.
- [6] HOFREITER, Milan. *Základy automatického řízení*. V Praze: České vysoké učení technické, 2012. ISBN 978-80-01-05007-1.
- [7] CHUROVÁ, Vendula. *Optimalizační algoritmy inspirované živou přírodou* [online]. Brno, 2015 [cit. 2021-08-12]. Dostupné z: <https://theses.cz/id/7zc4m1/>. Bakalářská práce. Masarykova univerzita, Přírodovědecká fakulta. Vedoucí práce Mgr. et Mgr. Petr Dluhoš.





**Selected article from**

**Tento dokument byl publikován ve sborníku**

**Nové metody a postupy v oblasti přístrojové  
techniky, automatického řízení a informatiky 2021  
New Methods and Practices in the Instrumentation,  
Automatic Control and Informatics 2021  
15. 9. – 17. 9. 2021, Žatec**

**ISBN 978-80-01-06889-2**

Web page of the original document:

<http://iat.fs.cvut.cz/nmp/2021.pdf>

Obsah čísla/individual articles:

<http://iat.fs.cvut.cz/nmp/2021/>

Ústav přístrojové a řídicí techniky, FS ČVUT v Praze, Technická 4, Praha 6