

doi:10.15199/48.2015.12.13

Agresywna kolonia chwastów jako biomimetyczna metoda optymalizacji globalnej

Streszczenie. W pracy przedstawiono niedawno zaproponowany algorytm optymalizacji globalnej zainspirowany rozprzestrzenianiem się kolonii chwastów. Opisany algorytm jest zbliżony koncepcyjnie do innych współczesnych metaheurystyk, tj. roju cząstek czy algorytmów genetycznych. Jego cechy charakterystyczne to m.in. iteracyjny sposób działania, losowy dobór populacji początkowej, selekcja najbardziej optymalnych osobników. Działanie algorytmu przetestowano na wybranych problemach testowych.

Abstract. In the paper a recently developed algorithm of global optimization, inspired with spreading of weed colonies, is presented. The discussed algorithm is conceptually close to other contemporary metaheuristics, e.g. particle swarm or genetic algorithms. Its characteristic features are, among others, iterative mode of operation, random choice of initial population, selection of most prospective individuals. The action of the algorithm is tested using chosen benchmark problems. (**Invasive Weed Colonization as a biomimetic method of global optimization**)

Słowa kluczowe: Agresywna Kolonia Chwastów, biomimetyka, optymalizacja, zadania testowe.

Keywords: Invasive Weed Colonization, biomimetics, optimization, benchmarks.

Wprowadzenie

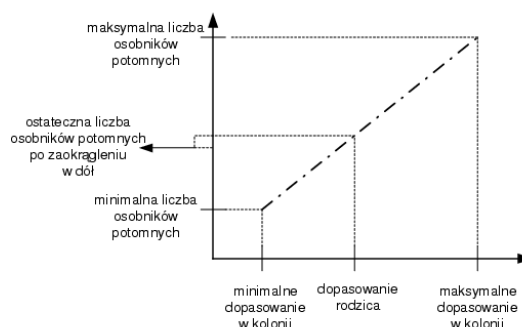
Przyroda od dawna stanowiła źródło inspiracji dla badaczy. Współcześnie obserwuje się wiele udanych prób stworzenia nowych jakościowo produktów czy urządzeń, imitujących rozwiązania stworzone przez Matkę Naturę [1]. Nowoczesne algorytmy optymalizacji są często inspirowane przez obserwacje ze świata flory i fauny [2-4]. W pracy przedstawiono niedawno zaproponowany algorytm optymalizacji globalnej IWO (ang. *invasive weed optimization*) [5]. W rolnictwie rozprzestrzenianie się chwastów stanowi poważny problem [6]. Metody plenięcia się tych roślin stanowiły podstawę do opracowania algorytmu, który zdaniem jego twórców przewyższa efektywnością zarówno inne biomimetyczne metody, takie jak algorytmy genetyczne, memetyczne, optymalizacja rojem cząstek, jak też modyfikacje techniki symulowanego wyżarzania. Optymalizacja techniką IWO została wykorzystana m.in. do rozwiązywania zagadnień z teorii sterowania [7] i chaosu [8], praktycznych zagadnień z zakresu telekomunikacji [9,10] oraz elektroenergetyki [11]. Spośród ciekawszych zastosowań tej metody można wymienić zarządzanie zasobami bezzalogowych obiektów latających (dronów) [12].

Zasada działania algorytmu

Rozważany algorytm jest zbliżony koncepcyjnie do innych algorytmów meta heurystycznych np. ewolucyjnych. Aby zasymulować plenięcie się chwastów wprowadza się do modelu następujące cechy charakterystyczne kolonii tych roślin:

- skończoną populację zarodków umieszcza się w sposób losowy w przestrzeni n -wymiarowej (inicjalizacja populacji),
- każdy z zarodków roślinie aż do osiągnięcia dojrzałości i produkuje następne zarodki w ilości zależnej od poziomu swojego dopasowania (reprodukcja),
- wytworzone nasiona są losowo rozpraszane w rozważanej n -wymiarowej przestrzeni i rosną aż do osiągnięcia dojrzałości (rozprzestrzenianie się w przestrzeni),
- proces opisany w punktach poprzednich powtarza się dopóki nie zostanie osiągnięta maksymalna liczba roślin; od tego momentu jedynie chwasty o najlepszym przystosowaniu mogą się rozmnażać i tworzyć potomstwo, pozostałe osobniki są eliminowane (wykluczanie w wyniku współzawodnictwa).

W drugim kroku, oznaczonym jako b , liczba wygenerowanych osobników potomnych jest zależna od wartości funkcji dopasowania rodzica, zgodnie ze schematem przedstawionym na rysunku 1:



Rys.1. Wyznaczanie liczby osobników potomnych

W trzecim kroku, oznaczonym jako c , położenie osobników potomnych w przestrzeni n -wymiarowej jest losowo wyznaczone na podstawie położenia rodzica. Losowość zapewniona jest poprzez wprowadzenie do opisu funkcji odległości w postaci rozkładu normalnego o średniej równej zeru i modulowanej w kolejnych iteracjach wartości odchylenia standardowego, zgodnie z zależnością

$$(1) \quad \sigma_{\text{iter}} = \frac{(\text{iter}_{\text{maks}} - \text{iter})^m}{\text{iter}_{\text{maks}}^m} (\sigma_{\text{pocz}} - \sigma_{\text{końc}}) + \sigma_{\text{końc}}$$

gdzie $\text{iter}_{\text{maks}}$ oznacza maksymalną liczbę iteracji, iter to numer aktualnej iteracji, m jest czynnikiem modulacji, natomiast σ_{pocz} i $\sigma_{\text{końc}}$ oznaczają odpowiednio wartość odchylenia standardowego dla początku i końca cyklu iteracyjnego. Wprowadzenie nieliniowej modulacji danej powyższym wzorem sprawia, że w trakcie kolejnych iteracji maleje prawdopodobieństwo pojawienia się osobnika potomnego w odległym obszarze rozważanej przestrzeni n -wymiarowej (odpowiada to mniej więcej zmniejszaniu się ruchliwości osobników w metodzie roju cząstek (Particle Swarm Optimization), por. [13,14]).

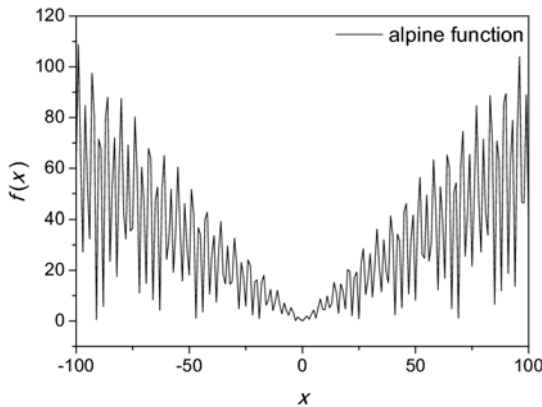
Istotną rolę w algorytmie IWO pełnią dwa mechanizmy selekcji:

- *r*-selekcja („żyj szybko, rozmnażaj się szybko, umieraj młodo”) – tego typu mechanizm jest niezbędny, aby zapewnić przekazywanie korzystnych cech osobniczych potomstwu w niestabilnych i nieprzewidywalnych warunkach,
- *k*-selekcja („żyj powoli, rozmnażaj się powoli, umieraj staro”) – jest niezbędna, aby cechy były przekazywane w stabilnych, dobrze zdefiniowanych środowiskach, w których jest bardzo prawdopodobna rywalizacja o ograniczoną liczbę zasobów pomiędzy osobnikami dobrze przystosowanymi do tego, aby podjąć między sobą walkę oraz w sytuacjach, kiedy rozmiar populacji jest już zbliżony do maksymalnego.

Wybrane zadania testowe

Istnieje wiele zestawów zadań testowych do oceny efektywności działania algorytmów optymalizacji, por. przykładowo [15-18]. W pracy przedstawiono wybrane przykłady o różnym poziomie złożoności.

- Funkcja „alpejska”




Rys.2. Funkcja testowa *alpine*

$$f(x) = |x \sin x + 0,1x|$$

Dziedzina funkcji $x \in \langle -100; 100 \rangle$. Minimum globalne $f(0) = 0$. Na podstawie wykresu funkcji (rys. 2) można stwierdzić, że przebieg funkcji cechuje się występowaniem wielu minimum lokalnych.

Wywołanie skryptu:

`iw0_1_1('alpine', 4, 500, 1, 4, 6, 1, 3.8, 10, 0.1, 100, -100, 'off')`.



Rys.3. Uzyskane wartości funkcji celu

Parametry funkcji oznaczają kolejno: nazwę funkcji, którą należy optymalizować, początkową liczbę roślin-rodziców, wymiar przeszukiwanej przestrzeni, maksymalna liczbę roślin-rodziców, maksymalną i minimalną liczbę nasion (generowanych osobników potomnych), wartość

czynnika modulującego (por. wyrażenie (1)), początkową i końcową wartość odchylenia standardowego, maksymalną i minimalną wartość zmiennej niezależnej, włączenie/wyłączenie wizualizacji działania algorytmu.


Algorytm IWO wywołano 50 razy, wykorzystując podany powyżej zestaw parametrów. Wyniki przedstawiono na rysunku 3. W 29 przypadkach wyznaczona wartość funkcji celu wynosiła poniżej 10^{-4} , natomiast w 12 przypadkach – poniżej 10^{-5} . Najmniejsza wyznaczona wartość funkcji celu wyniosła $9,4178 \cdot 10^{-8}$, natomiast największa (najgorszy przypadek) - 0,051.

- Multimodalna funkcja *bird*:

$$f(x_1, x_2) = \sin x_1 \exp(1 - \cos x_2)^2 + \cos x_2 \exp(1 - \sin x_1)^2 + \dots + (x_1 - x_2)^2$$

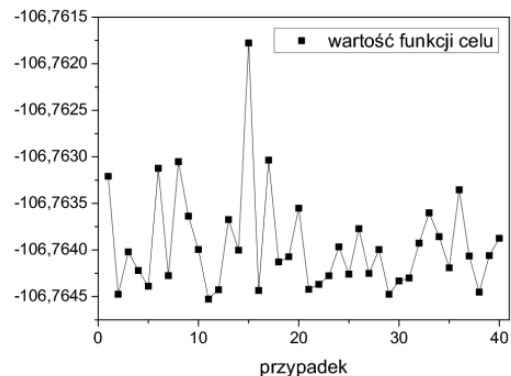
Dziedzina funkcji $x_1, x_2 \in \langle -2\pi, 2\pi \rangle$. Minimum globalne

$$f(4,7011; 3,1530) = f(-1,5821; -3,1303) = -106,7645.$$



Rys.4. Funkcja testowa *bird*

Algorytm uruchomiono w trybie wsadowym 40 razy, za każdym razem reinicjując zarodek generatora liczb pseudolosowych wykorzystując aktualną datę systemową (`rand('seed', now)`), aby uniknąć ewentualnych problemów związanych z niedoskonałością generatora. We wszystkich przypadkach wartość funkcji celu znaleziona przez algorytm przyjęła wartość poniżej $-106,7615$, co stanowi stosunkowo dobre przybliżenie rzeczywistego minimum globalnego. Norma euklidesowa wyznaczona dla współrzędnych znalezionych punktów i najbliższych im współrzędnych minimum globalnych (podanych wyżej) nie przekraczała $4,5 \cdot 10^{-3}$.

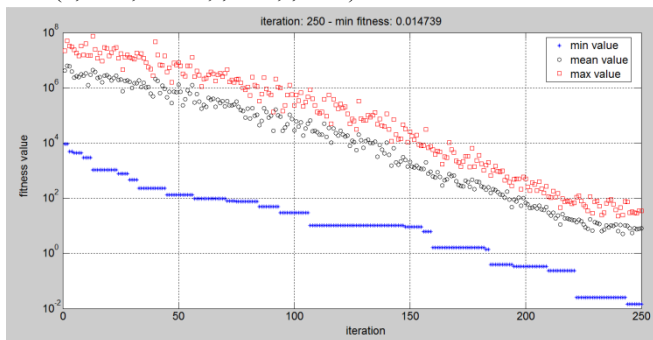


Rys.5. Wartości funkcji celu podczas kolejnych uruchomień

- Rozszerzona funkcja Rosenbrocka

$$f(X) = \sum_{i=1}^{n-1} [100(x_i^2 - x_{i+1})^2 + (x_i - 1)^2]$$

Dziedzina funkcji $x_i \in \langle -5; 10 \rangle$. Minimum globalne $f(1,1,\dots,1) = 0$. Przetestowano działanie algorytmu dla różnych wartości wymiaru przeszukiwanej przestrzeni. Na rysunku przedstawiono przykładowe działanie algorytmu dla $n = 4$. W symulacjach przyjęto, że odchylenie standardowe zmienia się nieliniowo zgodnie ze wzorem (1), gdzie $\sigma_{\text{pocz}} = 10$, $\sigma_{\text{końc}} = 0,1$ natomiast $m = 2,5$. Założona liczba iteracji wynosiła 250. Współrzędne zlokalizowanego minimum globalnego wynosiły w przypadku przedstawionym na rysunku $X = (0,8949; 0,8049; 1,0111; 1,0268)$.



Rys.6. Zmiany wartości funkcji dopasowania dla funkcji Rosenbrocka, $n = 4$.

Podsumowanie

W pracy scharakteryzowano jeden z biomimetycznych algorytmów optymalizacji globalnej, oparty na emulacji rozprzestrzeniania się kolonii chwastów. Algorytm jest nieco zbliżony koncepcyjnie do innych współczesnych metaheurystyk, np. roju cząstek czy algorytmów genetycznych. Działanie algorytmu przetestowano na wybranych zadaniach testowych.

LITERATURA

- [1] Bhushan B., Biomimetics: lessons from nature – an overview, *Phil. Trans. R. Soc. A*, 367 (2009), 1445-1486
- [2] Wang Lei, Kang Qi, Wu Qi-Di, Nature-inspired computation - Effective realization of Artificial Intelligence, *Syst. Eng. Theor. Pract.*, 27 (2007), 126-134
- [3] Xiaolei Wang, Hybrid nature-inspired computation methods for optimization, PhD Thesis, Helsinki University of Technology, Finland, 2009

- [4] Hongnian Zang, Shujun Zhang, K. Hapeshi, A review of nature-inspired algorithms, *J. Bionic Eng.*, 7 Suppl. (2010), S232-S237
- [5] Mehrabian, A. R., Lucas C., A novel numerical optimization algorithm inspired from weed colonization, *Ecolog. Inf.*, 1 (2006), 355-366
- [6] Radosevich St. R., Holt J. S., Ghersa Cl. M., Ecology of weeds and invasive plants, John Wiley & Sons, Hoboken, USA, 2007
- [7] Borzabadi A. H., Heidari M., Comparison of some evolutionary algorithms for approximate solutions of optimal control systems, *Austral. J. Bas. Appl. Sci.*, 4 (2010), 3366-3382
- [8] Ahmadi M., Mojallali H., Chaotic invasive weed optimization algorithm with application to parameter estimation of chaotic systems, *Chaos, Solit. Fract.*, 45 (2012), 1108-1120
- [9] Karimkashi S., Kishk A. A., Invasive Weed Optimization and its features in electromagnetics, *IEEE Trans. Antennas Prop.*, 58 (2010), 1269-1278
- [10] Zdunek R., Ignor T., UMTS base station location planning with Invasive Weed Optimization, *Lect. Not. Artif. Intell.*, 6114 (2010), 698-705
- [11] Sahraei-Ardakani M., Roshanaei M., Rahimi-Kian A., Lucas C., A study of electricity market dynamics using invasive weed colonization optimization, *Proc. 2008 IEEE Symposium on Computational Intelligence and Games (CIG'08)*, (2008) 276-282
- [12] Ghalenoiei M. R., Hajimirsadeghi H., Lucas C., Discrete Invasive Weed Optimization algorithm: application to cooperative multiple task management of UAVs, *Proc. Joint IEEE Conf. Decision and Control and 28th Chinese Control Conference*, (2009), 1665-1670
- [13] Yang X.-S., Nature-inspired metaheuristic algorithms, Luniver Press, Frome, UK, 2010
- [14] Jevtić A., Swarm intelligence: novel tools for optimization, feature extraction, and multi-agent system modeling, PhD Thesis, Universidad Politécnica de Madrid, Spain, 2011
- [15] Floudas C.A., Pardalos P.M., A collection of test problems for constrained global optimization algorithms, *Lecture Notes in Computer Science* 455, Springer-Verlag (1990)
- [16] Hedar A., 2005, http://www-optima.amp.i.kyoto-u.ac.jp/member/student/hedar/Hedar_files/TestGO.htm
- [17] Oldenhuis R., Many testfunctions for global optimizers, <http://www.mathworks.com/matlabcentral/fileexchange/23147-many-testfunctions-for-global-optimizers>
- [18] Weise T., 2009, Global optimization algorithms. Theory and applications. Web book, <http://www.it-weise.de>

Autor: dr hab. inż. Krzysztof Chwastek, prof. PCz, Politechnika Częstochowska, Instytut Elektroenergetyki, Al. Armii Krajowej 17, 42-201 Częstochowa, E-mail: krzych@el.pcz.czyst.pl.