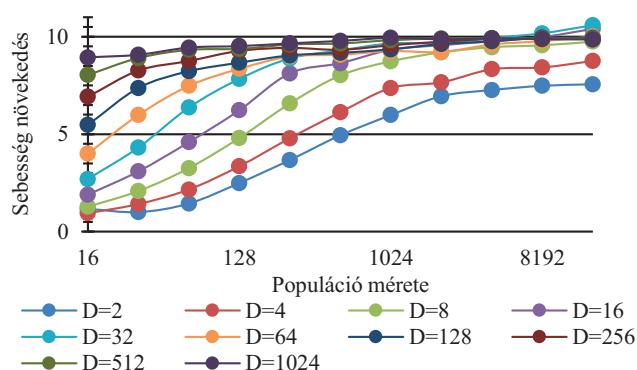
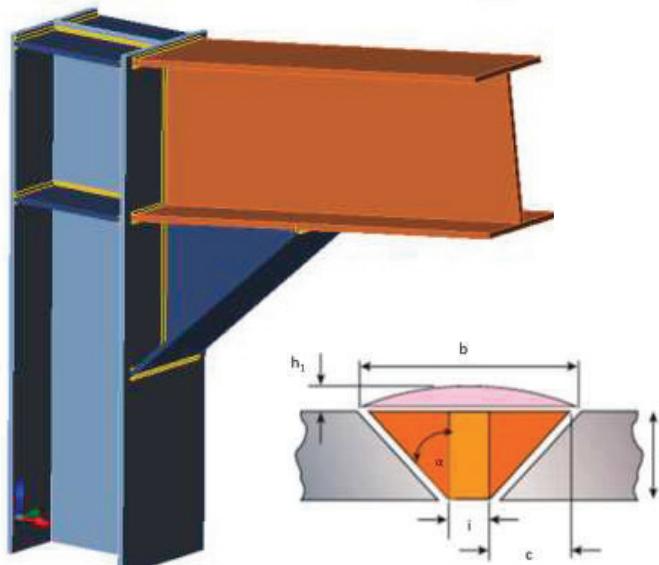
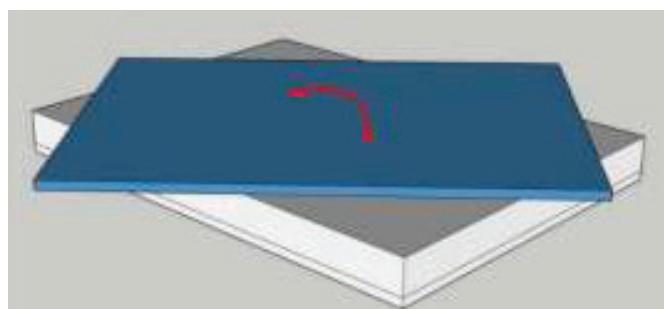
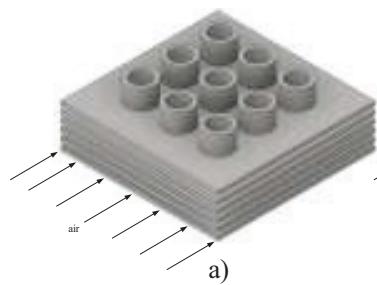
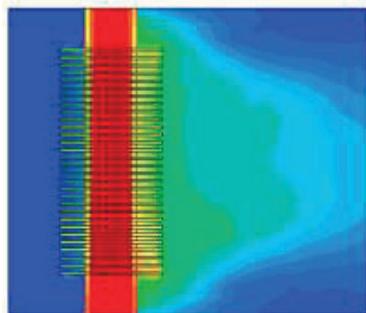


## A GÉPIPARI TUDOMÁNYOS EGYESÜLET MŰSZAKI FOLYÓIRATA



# TARTALOM

<b>1. Hazim Nasir Ghafil, Dr. Jármai Károly</b> <b>A RÉSZECSKE CSOPORT ÉS A MESTERSÉGES MÉHCSALÁD MÓDSZEREK ÖSSZEHASONLÍTÓ VIZSGÁLATA ..... 5</b> <i>Ebben a munkában a részecske csoport optimálás és a méhcsalád algoritmusai közötti összehasonlítást mutatjuk be különböző vizsgálati módszerekkel. minden algoritmust részletesen ismertetünk, és bemutatjuk a matematikai modelljüket. Megállapítást nyert, hogy a részecske csoport optimálás jobb, mint a mesterséges méhcsalád, módszer és egy speciális tesztfüggvény esetében a mesterséges méhcsalád nem tudott megfelelő megoldást találni.</i>	<b>5. Petrik Máté, Dr. Szepesi Gábor; Dr. Jármai Károly</b> <b>BORDÁSCSÖVES HŐCSERÉLŐ HŐÁTADÁSI FOLYAMATÁNAK VIZSGÁLATA CFD-VEL ..... 27</b> <i>Ez a tanulmány a kompakt autó hűtők áramlás dinamikája számításával (CFD) foglalkozik és az ezzel történő hőteljesítményének paraméteres elemzését célozza meg. Az elemzést különböző levegősebességeken hajtottuk végre különböző hűtőbordák modellezésével, mint például valódi hűtőbordák és porózus közegek alkalmazása. A vizsgálathoz használt CFD szoftver SC-Tetra volt.</i>
<b>2. Erdős Antal, Dr. Jármai Károly</b> <b>NYOMÁSTARTÓ EDÉNY HEGESZTÉSI KÖLTSÉG SZÁMÍTÁSA ..... 9</b> <i>A nyomástartó edények manapság fontos szerepet töltnek be a mérnöki tevékenységben. Ezért a hozzájuk kapcsolódó költségek minimálása kulcsfontosságú lehet a termelési költségek vagy a működési költségek szempontjából. Ezeket a szerkezeteket általában hegesztik. Ezért a helyes hegesztési technológia és a töltőanyag kiválasztása fontos szempont a költségek megtakarításában. Működési oldalról a karbantartás költsége és a ciklusok száma fontos, mert fáradás adódhat a szerkezetnél.</i>	<b>6. Kászonyi Gábor – Dr. Jármai Károly</b> <b>HEGESZTETT CSARNOKKERET OPTIMÁLÁSA TÖMEGRE ÉS KIHASZNÁLTSÁGRA ..... 32</b> <i>Ebben a tanulmányban az optimálást egy hegesztett I-szelvénnyű elemekből álló keretszerkezeten mutatjuk be. Figyelembe vettük a szerkezeti feszültséget, a stabilitási korlátokat, a keret erősséget és a teherbíró képességeket. A szerkezet teherbíró képességét maximalizáltuk - a szimulációhoz egy VEM (Végeelem módszert) AXIS csmagot használva. Kimutattuk, hogy jelentős tömegmegtakarítás érhető el optimálással.</i>
<b>3. Nagy Szilárd, Dr. Jármai Károly</b> <b>FPA ALGORITMUS IMPLEMENTÁLÁSA MASSZÍVAN PÁRHAZAMOS ARCHITEKTÚRÁRA ..... 16</b> <i>Az evolúciós algoritmusok hatékony eszközök a nemlineáris, többdimenziós optimálási problémák megoldására. A nagyméretű problémák megoldása gyakran időigényes. A GPU-k (grafikus feldolgozó egység) evolúciója az elmúlt években lehetővé teszi számukra, hogy általános célú számításokra használják őket. Ebben a tanulmányban bemutatjuk az FPA (Virág megporzás algoritmus) algoritmusának GPU-n való megvalósítását és az elérő eredményeket.</i>	<b>7. Alaa Al-Fatlawi, Dr. Jármai Károly, Dr. Kovács György</b> <b>MÉHSEJTVÁZAS KOMPOZIT PANELEK TERVEZÉSE ÉS MÉRÉSE ALKALMAZÁSSAL ..... 36</b> <i>E tanulmány célja új méhsejtvázas szendvics kompozit szerkezetek kidolgozása volt. A könnyű panelek óriási megtakarítást biztosítanak a tömeg vonatkozásában, és így csökkentik az üzemanyag-fogyasztást vagy növelik a légi járművek forgalmát a hagyományos konténerekhez képest. A Nemzetközi Légi Közlekedési Szövetség (IATA) számításai szerint az 1 kg-os többlettömeg óránkénti szállításához szükséges üzemanyag súlya 0,04 kg.</i>
<b>4. Szűcs Renáta, Galambos József, Dr. Virág Zoltán és Dr. Jármai Károly</b> <b>EMELŐASZTAL TERVEZÉSE, BASIC ENGINEERING ..... 20</b> <i>Ebben a munkában az emelőasztal-konstrukciók csoportjában bemutattuk az alaptechnikát. Ezeket az asztalokat kisebb vagy nagyobb tömegek emelésére használják. A platform hossza és szélessége nagyon eltérő lehet. A függőleges vagy vízszintes irányban az ollók száma nagyban befolyásolja az alkalmazhatóságot és a terhelést. A vizsgálat azt mutatja, hogy a minimális tömegű, vagy kölcsű szerkezet kialakítása érdekében végzett innovatív tervezés nem könnyű, sok variáns lehet.</i>	

# A RÉSZECSKE CSOPORT ÉS A MESTERSÉGES MÉHCSALÁD MÓDSZEREK ÖSSZEHASONLÍTÓ VIZSGÁLATA

## COMPARATIVE STUDY OF PARTICLE SWARM OPTIMIZATION AND ARTIFICIAL BEE COLONY ALGORITHMS

Hazim Nasir Ghafil\*, Dr. Jármai Károly\*\*

### ÖSSZEFOGLALÁS

Ebben a munkában a részecske csoport optimálás és a méhcsalád algoritmusai közötti összehasonlítást mutatjuk be különböző vizsgálati módszerekkel. minden algoritmust részletesen ismertetünk, és bemutatjuk a matematikai modelljüket. Megállapítást nyert, hogy a részecske csoport optimálás jobb, mint a mesterséges méhcsalád, módszer és egy speciális tesztfüggvény esetében a mesterséges méhcsalád nem tudott megfelelő megoldást találni.

### ABSTRACT

In this work greedy comparison between particle swarm optimization and artificial bee colony algorithms was made using different test functions. Each algorithm was explained in detail, and the mathematical model behind the algorithms has been presented. It is found that particle swarm optimization is better than artificial bee colony and for a specific test function, artificial bee had failed to find a feasible solution.

### 1. BEVEZETÉS

A PSO egy csoport intelligencián alapuló optimáló algoritmus; az optimáló algoritmusok egy osztályába tartozik, amelyet meta-heurisztikusnak neveznek. A PSO utánozza az állatok, mint a halak és a madarak csoport viselkedését, és ez egy egyszerű, hatékony optimáló módszerhez vezet. Sikeresen alkalmazták a tudomány különböző területein, mint például a gépi tanulásban, a képfeldolgozásban, az adatbányászatban, a robotikában és sok más területen. A PSO-t 1995-ben Russell Eberhart és James Kennedy vezette be [1]. Egy olyan modell kidolgozásával, amely leírja az állatok csoport viselkedését, mint a madarak és a halak raja. 1995 óta a PSO az egyik leghatékonyabb és legnépszerűbb algoritmus lett a különböző területek különböző optimálási problémáinak megoldására. Ennek a csoport

intelligenciának a legfontosabb pontja az egyedek közötti együttműködés. Az egyéni intelligencia hatékonyabbá válik, ha együttműködik egy másik egyeddel [2]. 2005-ben [3] bevezetésre került a mesterséges méhcsalád ABC nevű csoport intelligencia optimáló algoritmus. Ez szintén egy metauriszтикus algoritmus, amellyel hatékonyan lehet megoldani a többdimenziós optimalizálási problémákat. A mézelő méh kolónia táplálkozási magatartását utánozza a [4] által javasolt modell alapján. Mesterséges méh kolónia úgy működik, hogy vannak méhek (egyedek), akik gazdag élelmiszerforrást keresnek (legjobb megoldás) a kaptár szomszédságában (keresési hely). minden egyed egy lehetséges megoldás, és csak egy konkrét megoldáshoz kapcsolódik a keresési térből.

### 2. A PSO ALGORITMUS

Tekintsük az 1. ábrát, amely a PSO mögötti matematikai modellt mutatja. Hasonlóképpen hivatkozhatunk az csoport egyedeire és a csoport egészére, mivel minden részecske a megoldandó optimalizálási probléma egy potenciális megoldása. A keresési terület korlátozza az összes lehetséges megoldást a problémára, és a részecskéknek a legjobb helyzetbe kell kerülniük (a legjobb megoldás az optimálási problémára) a térből. Egy adott részecske pozícióját és sebességét a következők jelölik.

$$x_k(t) \in x$$

$$v_k(t) \in x$$

ahol  $k$  a részecske indexe a csoportban, és  $x$  a keresési térfelület, míg  $(t)$  egy diszkrét időszakasz, és az algoritmus iterációs számát mutatja. A sebesség- és pozícióvektorok ugyanabban a térből vannak, ugyanolyan dimenzióval. Tekintsük az 1. ábrán látható rendszert, amely egy egyszerű matematikai modellt mutat be, amely leírja a PSO-t. Ahol  $x_k(t)$  a

\* PhD hallgató, Miskolci Egyetem, Miskolc, H-3515 Miskolc, Egyetemváros, vegyhn@uni-miskolc.hu

\*\* Professzor Dr., Miskolci Egyetem, Miskolc, H-3515 Miskolc, Egyetemváros

részecske aktuális helyzete, és az új pozícióba kell eljutnia  $x_k(t+1)$ . minden részecske rendelkezik saját tapasztalattal és saját memóriával a legjobb helyzetére vonatkozólag, ezt nevezzük a saját legjobb pozíciójának a  $k$ -adik részecskénél  $p_k(t)$ . A részecske elmozdul a jelenlegi helyzetéből  $v_k(t)$  sebességgel és irányával. A részecskék nem egyedülállóak, egymással kommunikálnak és egymással kölcsönhatásba lépnek, és megosztják személyes tapasztalataikat, hogy megismerjék és eldöntsék, mi a legjobb pozíció a többi egyed tapasztalatai alapján, vagyis amit globális legjobbnak nevezünk és  $G(t)$ -vel jelölünk. Az alábbi mennyiségek azonosíthatók az 1. ábrán:

Az aktuális helyet és a személyes legjobbat összekötő vektor értéke:

$$p_x = p_k(t) - x_k(t) \quad \dots\dots(1)$$

Továbbá, az aktuális helyet a globális legjobbhoz kapcsoló vektor értéke:

$$g_x = G(t) - x_k(t) \quad (2)$$

A részecskének az új pozícióba történő mozgását a következő egyenletek adják meg:

$$x_k(t+1) = x_k(t) + v_k(t+1) \quad (3)$$

$$v_k(t+1) = w^* v_k(t) + C_1(p_k(t) - x_k(t)) + C_2(G(t) - x_k(t)) \quad (4)$$

A (4) egyenletben a  $v_k(t+1)$  vektor a három részmozgás  $m_1$ ,  $m_2$  és  $m_3$  összegzése, melyel a részecske mozog  $v_k(t)$ , a  $px$  és a  $gx$  vektorok irányában:

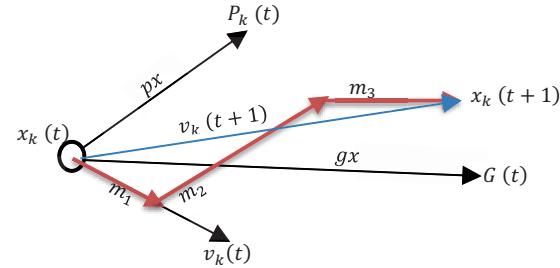
$$v_k(t+1) = m_1 + m_2 + m_3 \quad (5)$$

ahol

$$m_1 = w^* v_k(t) \quad (6)$$

$$m_2 = C_1 px = C_1(p_k(t) - x_k(t)) \quad (7)$$

$$m_3 = C_2 gx = C_2(G(t) - x_k(t)) \quad (8)$$



1. ábra. A PSO matematikai modelljét ábrázoló vázlatos diagram

A (3) és (4) egyenletek teljesen leírják a PSO matematikai modelljét. Ezek az egyenletek azonban egyszerű matematikai modellek a standard PSO mögött, és néhány feltétel szükséges az egyenletek teljesítéséhez. A standard PSO a következő:

$$x_{kj}(t+1) = x_{kj}(t) + v_{kj}(t+1) \quad (9)$$

$$v_{kj}(t+1) = w^* v_{kj}(t) + r_1 C_1(p_{kj}(t) - x_{kj}(t)) + r_2 C_2(G_j(t) - x_{kj}(t)) \quad (10)$$

$v_{kj}(t+1)$ : jelöli a  $k$ -dik részecske  $j$ -irányú sebesség komponensét a  $(t+1)$  időlépésben,

$r_1$ ,  $r_2$ : véletlen számok, egyenletesen elosztva a 0 -1 intervallumon,

$C_1$ ,  $C_2$ : gyorsulási együtthatók,

$w^* v_{kj}(t)$ : inercia kifejezés,

$w$ : inercia együttható,

$r_1 C_1(p_{kj}(t) - x_{kj}(t))$ : kognitív komponens,

$r_2 C_2(G_j(t) - x_{kj}(t))$ : szociális komponens.

A (9) és (10) egyenlet az a két szabály, amelyeket minden részecskének követnie kell a csoportban, és ez a csoportintelligencia pontos jelentése. Ezen szabályoknak a meghatározásával a PSO minden iterációja során, az egyes részecskék sebessége és helyzete ezen egyszerű mechanizmus szerint frissül.

### 3. MESTERSÉGES MÉHCSALÁD

Az algoritmus általános szerkezete a következő:

Cserkész méhek fázisa (inicializálás),  
Ismétlés

Foglalkoztatott méhek,

Kereső méhek,

Cserkész méhek,

Tárolja a legjobb megoldást az aktuális nyomvonában,

Amíg (konvergencia feltétel, a ciklusok maximális száma),

Az algoritmus minden egyes részének saját alacsony szintű szerkezete van, és ezek a globális szintet befolyásolják egymás közötti kölcsönhatásukkal. Kezdetben minden méh cserkész és véletlenszerűen új megoldásokat keres. Tegyük fel, hogy  $x$  a véletlenszerű megoldások vektora, amelyet eredetileg a cserkész méhek adtak vissza.

$$x = (x_1, x_2, x_i, \dots, x_{n-1}, x_n) \quad (11)$$

ahol  $n \in R^n$ ,  $i=1 \dots n$

### 3.1 Foglalkoztatott méhek szekció

A foglalkoztatott méhek kiaknázzák az élelmiszerforrást, és visszaadják az információt, és elhagyják a kimerült forrást. Az ABC-nél ezt véletlenszerűen kell tennünk. [5] a következő képletet javasolta:

$$v_i = x_i + \phi_i(x_i - x_k) \quad (12)$$

ahol  $v_i$  az új megoldás vektor,  $\phi_i$  véletlen szám  $[-1,1]$  között.  $k$  szintén véletlen szám, ami a megoldás vektor különböző véletlen sorrendjét képviseli.

### 3.2 Kereső méhek szekció

A böngésző méhek a valószínűséget használják, amely a fitnesz érték függvénye, a legjobb megoldás kiválasztásához. Rulett kerék kiválasztási módszert

1. táblázat. Teszt függvények az optimáló algoritmusokhoz

Teszt függvény	Képlete	Megengedett tartomány, globális optimum
Sphere függvény	$f(x) = \sum_{i=1}^n x_i^2$	$-5.12 \leq x_i \leq 5.12$ $x_i = 0, i = 1, \dots, n$ $f(x)=0$
Rosenbrock's valley függvény	$f(x) = \sum_{i=1}^{n-1} [100 \times (x_{i+1} - x_i^2)^2 + (1 - x_i)^2]$	$-2.048 \leq x_i \leq 2.048$ $x_i = 1, i = 1, \dots, n$ $f(x)=0$
Rastrigin's függvény	$f(x) = 10 \times n + \sum_{i=1}^n [x_i^2 - 10 \times \cos(2\pi x_i)]$	$-5.12 \leq x_i \leq 5.12$ $x_i = 0, i = 1, \dots, n$ $f(x)=0$
Schwefel's függvény	$f(x) = 0,5 + \frac{\sin^2(x_1^2 - x_2^2) - 0,5}{[1 + 0,001 \times (x_1^2 + x_2^2)]^2}$	$-10 \leq x_i \leq 10$ $x_i = 0, i = 1, 2$ $f(x)=0$
Griewangk's függvény	$f(x) = \frac{1}{4000} \times \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	$-600 \leq x_i \leq 600$ $x_i = 0, i = 1, \dots, n$ $f(x)=0$

alkalmazza [6], amely fitnesz érték alapú kiválasztási technika. A megoldás valószínűsége ( $P_i$ ) a következő értékű:

$$P_i = \frac{f_i}{\sum_{i=1}^{pop} f_i} \quad (13)$$

$$f_i = \begin{cases} \frac{1}{1+O_i} & O_i \geq 0 \\ 1+abs(O_i) & O_i < 0 \end{cases} \quad (14)$$

ahol  $f_i$  a fitnesz értéke az  $O_i$  célfüggvénynek.

### 3.3 Cserkész méhek szekció

Az algoritmus elején az összes méh cserkész, majd programfutás közben átalakul a foglalkoztatottra, vagy keresőre. A foglalkoztatott méheknek, akiknek a pozíciója (megoldása) nem változik egy adott időpont után, el kell hagynia pozícióját és át kell alakítania azt a cserkészeknek. Az elhagyási kritérium, amelyet határellenőrzésnek nevezünk, nagyon fontos a helyi minimumból való kiugráshoz, és továbbra is keresni kell az optimálási probléma globális minimumát.

2. táblázat. PSO és ABC algoritmusok futási eredményei különböző teszt függvényeknél

Teszt függvény	Globális megoldás	Algoritmus	Legjobb megoldás	Fő érték	Szórás
Sphere függvény	0	PSO	0	0.0030	0.0365
		ABC	0	0.0112	0.0763
Rosenbrock's valley függvény	0	PSO	0	0.0166	0.0621
		ABC	0	0.0252	0.0453
Rastrigin függvény	0	PSO	0	0.1556	1.0164
		ABC	0	0.3091	1.5653
Schwefel függvény	-837.9658	PSO	-719.5274	-717.7633	12.9889
		ABC	-7.86*10 <sup>83</sup>	-6.89*10 <sup>81</sup>	6.06*10 <sup>82</sup>
Griewangk függvény	0	PSO	0.0049	0.0347	0.1426
		ABC	0.0025	0.0592	0.1973

#### 4. TESZT FÜGGVÉNYEK

Különböző vizsgálati függvényeket alkalmaztunk a részecske csoport optimálás és a mesterséges méh kolónia összehasonlítására (1. táblázat). A 2. táblázat a két algoritmus összehasonlítását mutatja be az öt különböző tesztfüggvényen [7]. A populációszám költségei és a költségek szórása egyértelműen azt mutatja, hogy az előny a PSO algoritmusánál van. Azt is megállapítottuk, hogy az ABC algoritmus nem közelíti meg a megoldást a Schwefel függvény használatakor.

#### 5. ÖSSZEFOGLALÁS

Az optimalizálási technikák fontos szerepet játszanak abban, hogy számos alternatívából megtalálják a legjobb megoldást. Számos optimálási technika áll rendelkezésre. Napjainkban a metaheurisztikus algoritmusok népszerűek. Kiválasztottuk a részecske csoport PSO és a Bee kolónia algoritmusokat. Mindkettő a csoport intelligenciát használja. Összehasonlításunkban azt találtuk, hogy a részecske csoport algoritmus jobb alkalmazhatósággal bír, minden esetben jó megoldást adott.

#### KÖSZÖNETNYILVÁNÍTÁS

A cikkben ismertetett kutató munka az EFOP-3.6.1-16-2016-00011 jelű „Fiatalodó és Megújuló Egyetem – Innovatív Tudásváros – a Miskolci Egyetem intelligens szakosodást szolgáló intézményi fejlesztése” projekt részeként – a Széchenyi 2020 keretében – az Európai Unió támogatásával, az Európai Szociális Alap társfinanszírozásával valósul meg.

#### IRODALOM

- [1] Eberhart R, Kennedy J (1995) A new optimizer using particle swarm theory. In: Micro Machine and Human Science, 1995. MHS'95., Proceedings

of the Sixth International Symposium on, IEEE, pp. 39-43.

- [2] Beni G, Wang J (1993) Swarm intelligence in cellular robotic systems. In: Robots and Biological Systems: Towards a New Bionics? Springer, pp. 703-712.
- [3] Karaboga D (2005) An idea based on honey bee swarm for numerical optimization. Technical report-tr06, Erciyes university, engineering faculty, computer engineering department,
- [4] Tereshko V, Loengarov A (2005) Collective decision making in honey-bee foraging dynamics. Computing and Information Systems 9 (3):1
- [5] Karaboga D (2010) Artificial bee colony algorithm. Scholarpedia 5: 6915
- [6] Goldberg DE, Holland JH (1988) Genetic algorithms and machine learning. Machine learning 3 (2): 95-99.
- [7] Marcin Molga, Czesław Smutnicki (2005) Test functions for optimization needs, 43 p. <http://www.robertmarks.org/Classes/ENGR5358/Papers/functions.pdf> (accessed 14 Aug.2018)