

# Mokomojo scenarijaus personalizavimas taikant kolektyvinės intelektikos metodus

Inga Žilinskienė<sup>1</sup>, Svetlana Kubilinskienė<sup>2</sup>

<sup>1</sup> *Vilniaus Universitetas, Matematikos ir informatikos institutas*  
Akademijos g. 4, LT-08663 Vilnius

<sup>2</sup> *Švietimo informacinių technologijų centras prie Švietimo ir mokslo ministerijos*  
Suvalkų g. 1, LT-03106 Vilnius  
E. paštas: inga.zilinskiene@mii.vu.lt, svetlana.kubilinskiene@itc.smm.lt

**Santrauka.** Viena iš elektroninio mokymosi tyrimų sričių yra mokomojo scenarijaus (santr. MS) personalizavimas. Straipsnyje glaustai pateikiama mokomojo scenarijaus samprata, parinkti personalizavimo kriterijai, esamų mokslinių tyrimų MS personalizuoti apžvalga. Šio straipsnio tikslas – pristatyti kolektyvinės intelektikos idėja grįstą metodą šiai problemai spręsti. Pasiūlytam metodui validuoti pateikiami realizuotu algoritmu atliktų eksperimentų rezultatai, kurie iliustruoja pasiūlyto metodo tinkamumą nagrinėjamai problemai spręsti bei aptariama skirtingų parametų parinkimo problema.

**Raktiniai žodžiai:** mokomasis scenarijus, personalizavimas, mokymosi stilius, kolektyvinės intelektikos metodai, elektroninis mokymasis.

## Įvadas

Mokomasis scenarijus (santr. MS) šiame straipsnyje nagrinėjamas kaip jį sudarančių mokymosi objektų (santr. MO) seka. MO suprantamas kaip „bet koks skaitmeninis išteklius skirtas mokymuisi“. Be to, kiekvienas MO apibrėžia ne tik turinį, bet ir duomenis aprašančius jį, t. y. metaduomenis, kurie panaudojami MO paieškai, mokymosi procesui sudaryti ir t. t. Metaduomenys, esami ryšiai tarp jų įgalina efektyvesnę MO panaudojimą, sudaro prielaidas adaptyviam mokymuisi, kai MO parenkami pagal besimokančiojo poreikius [14]. Besimokančiojo poreikiai gali būti nusakomi personalizavimo kriterijais. Pagal [17] personalizavimu siekiama pateikti vartotojams, ko jie nori ar jiems reikia, tačiau žinios apie jų poreikius yra neišreikštinės, t. y. tiesiogiai neišsakytos. Pedagoginiu požiūriu siekiama besimokančiajam pateikti tinkamą informaciją, paslaugą ir pan., o žvelgiant iš techninės pozicijos personalizavimas susijęs su objektų (pvz., MO) ir subjektų (besimokančiųjų) modeliavimu, kategorizavimu ir t. t. Literatūros analizė rodo, kad tam paprastai išskiriami personalizavimo kriterijai, kurie gali sudaryti skirtingų kriterijų aibę, jų poaibį ar pavienį kriterijų [9]. Šiame straipsnyje personalizavimas atliekamas tik vieno kriterijaus – mokymosi stiliaus (santr. MSt) – atžvilgiu. MSt yra apibrėžiamas kaip „būdas, kuriuo mokinys geriausiai sukaupia dėmesį, apdoroja, įsimena, suvokia ir pritaiko naują ir svarbią informaciją (mokomąją medžiagą)“ [4]. Taigi pagrindinė problema, kurią nagrinėja daugelis technologijomis grįsto mokymosi tyrėjų taikydami įvairius metodus yra ta, kaip parinkti mokymosi objektus, jų seką atsižvelgiant į besimokančiųjų preferencijas, t. y. besimokančiojo keliamą pirmenybę, pranašumą vienos mokymosi medžiagos, metodo ir pan. kitos medžiagos ir kt. atžvilgiu. Šiame straipsnyje pristatoma kolektyvinės intelek-


tikos metodo modifikacija MSt nusakomomis preferencijomis MS parinkimo problemai spręsti.

## 1 Esamų mokslinių tyrimų analizė

Literatūros analizė rodo, kad MS gali būti ne tik įvairiai vartojamas terminų atžvilgiu (pvz., mokymosi kelias [3], mokymosi veikla, mokymosi vienetas ir kt.), bet ir skirtingai apibrėžiamas struktūriškai (pvz., medis [9] pilnas grafas [12] ir kt.). Be to, taikomi įvairūs metodai mokomajam scenarijui personalizuoti: tikslo funkcijos radimas, daugiakriterinės sprendimų priėmimo metodų taikymas [16, 15, 9], pavienių originalių algoritmų sukūrimas [3, 13, 8] ontologijų taikymas [22, 19] ir kt. Pastaraisiais metais šiai problemai spręsti labai plačiai pradėti taikyti dirbtinio intelekto metodai: genetinių algoritmų [1], skruzdžių kolonijų [20, 22] ir kt. Išsami apžvalga apie evoliucinių algoritmų taikymą mokymosi scenarijui personalizuoti pateikiama [2] darbe, kuriame teigiama, kad jei MS parenkamas pagal konkrečias pavienio besimokančiojo preferencijas, jo patirtį ar remiantis tam tikros grupės preferencijomis ir patirtimi. Pirmuoju atveju labiau taikomi genetiniai algortimai ir jų atmainos, antruoju atveju – kolektyvinės intelektikos metodai. Remiantis šia įžvalga daroma prielaida, kad jei besimokantieji gali būti sukategorizuoti į skirtingas grupes pagal mokymosi stilius [18], tai kiekviena grupė besimokydama turi tokias pačias preferencijas ir įgyja panašią patirtį jų atžvilgiu, t. y. vieni MO gali būti labiau patrauklūs nei kiti, nes jie labiau atitinka to stiliaus preferencijas. Pvz., besimokantysis, kuris yra vizualas pagal Flemingo [10] VARK (skiriami 4 tipai: vizualas, kinestetikas, audialas, skaitytotojas) mokymosi stilių tipologiją labiau rinksis diagramas ir vizualią medžiagą nei audio medžiagą [11].

## 2 Kolektyvinės intelektikos metodo taikymas MS personalizuoti

Technologijomis grįsto mokymosi srityje kolektyvinės intelektikos (angl. swarm intelligence) metodai taikomi skirtingiems optimizavimo uždaviniams, pvz., ugdymo planavimui, intelektualių vertinimo priemonių generavimui, adaptyviam kompiuteriniam testavimui, studentų grupių formavimui, tvarkaraščiams sudaryti. [21] Pagrindinis principas, kuriuo remiasi minėti taikymai švietime yra besimokančiųjų mokymosi elgesio, mokymosi rezultatų stebėjimas ir gautos informacijos panaudojimas geresnei, kokybiškesnei veiklai arba pagal [5] pagrindinė kolektyvinės intelektikos savybė yra balansuoti tarp panaudojamumo (angl. exploitation) gero sprendinio ir tyrinėjimo (angl. exploration) dar nežinomų sprendinių. Kai personalizuojamas mokomasis scenarijus, geri sprendiniai, t. y. MO seka, yra tie, kurie atitinkdami besimokančiojo MSt gerina jo mokymosi rezultatus. Siekiant parinkti labiausiai besimokančiajam atitinkantį MS pagal jo MSt, šiame straipsnyje aprašomas tyrimas apima dvi dalis: 1) besimokantieji yra sukategorizuoti į grupes pagal jų mokymosi stilių bei žinoma, kuriam MSt kokie MO yra preferenciški (ši tyrimo dalis šiame straipsnyje yra ne-nagrinėjama), 2) pasitelkiamas vienas iš kolektyvinės intelektikos metodų – skruzdžių kolonijos optimizavimo (santr. SKO) [6] – ir jis autorių modifikuojamas nagrinėjamai problemai išspręsti. Originalaus SKO aprašą galima rasti [7]. Toliau pristatoma siūloma SKO modifikacija MS personalizuoti.



1 pav. Sprendinio konstravimas.

Originalus SKO algoritmas apima kelis etapus (sprendimo konstravimas, pradinių parametru inicializavimas; feromonų kelio atnaujinimas; lokali paieška), kurie aprašomi žemiau.

*Sprendimo konstravimas* – šio tyrimo ribose, MS yra konstruojamas kaip svartinis grafas, kur kelias sudarytas iš MO, kurie yra grafo viršūnės, o MO tarpusavyje jungiančios jungtys-briaunos. Kiekviena briauna turi savo svorį, kuris identifikuoja kelio svarbumą (naudingumą) atitinkamo MSt besimokančiajam. Tačiau kiekvienas MO priklauso tam tikrai temai ar paskaitai, kuri identifikuojama konkrečiu laiko momentu  $t$  (1 pav.)

*Euristinė informacija* – kadangi sprendinys konstruojamas pagal 1 pav. pateiktą schemą, euristinė informacija turi būti automatiškai išdėliojama ant briaunų. Tam, kad MO parinkimas vyktų nuosekliai pagal laiko momentus (mokymosi metu būtų rekomenduojamas MO parinkimas pagal temų nuoseklumą laiko atžvilgiu), parenkama funkcija priklausanti nuo laiko, ir kuri žymi euristinės informacijos reikšmę pereinant nuo vieno viršūnės  $r$  prie kitos  $s$ :

$$\eta = \frac{1}{e^{|\Delta t|}}, \quad \Delta t = t_{k+1} - t_k, \quad k - \text{laiko momentų kiekis.} \quad (1)$$

Tokiu būdu aprašyta euristinė informacija apibrėžia perėjimo prie kito MO tikimybę, kuri priklauso nuo reikšmės esančios ant briaunos.

*Feromonų kelio atnaujinimas* – feromonų atnaujinimo funkcija turi lemiamą įtaką kelio svarbumui žymėti, t. y. nuo jos priklauso kiek konkretus kelias bus svarbus vieno ar kito MSt besimokančiajam. Siūlomame modelyje daromos dvi prielaidos: 1) skruzdėlė paliks feromono tik tada, jei pabaigusi kelią ji gavo gerą įvertį, t. y.  $P(t) > P_{geras}(t)$ . Taip siekiama kaupti tik „kokybiškus“ feromonus, t. y. tik tie besimokantieji, kurie gauna gerus pažymius, turi galimybę palikti pėdsaką, užkertant kelią susiformuoti blogiems keliams, 2) kiekviena skruzdėlė palieka feromoną pažymėtą jos MSt pėdsaku (formulėse žymima indeksu  $l$ ,  $l = \{1\text{-vizualas}, 2\text{-kinestetikas}, 3\text{-audialas}, 4\text{-skaitytojas}\}$ ) pagal 1) prielaidą. Taigi feromonų atnaujinimo formulė, kurioje yra ir feromonų nykstanumo parametras  $\rho$ , besimokančijo MSt daugiklis  $w_l$  apibrėžiama taip:

$$\tau_{rs}^l(t) = \begin{cases} \rho \tau_{rs}^l(t-1) + \sum_{l=1}^4 w_l \Delta \tau_{rs}^l(t), \\ \Delta \tau_{rs}^l(t) = P(t) - P_{geras}(t), & \text{jei } P(t) \geq P_{geras}(t), \\ \rho \tau_{rs}^l(t-1), & \text{kitu atveju.} \end{cases} \quad (2)$$

*Lokali paieška* – kiekviename žingsnyje, kai reikia parinkti kitą MO, kiekviena skruzdėlė atlieka tikimybę grįžtą veiksmą, kurį kelią rinktis. Lokali paieškos rezultatas, t. y. pasirinktas kelias, priklauso nuo ant briaunos tarp  $n$  ir  $u$  MO esamo feromonų skaičiaus  $\tau_{nu}$ , nuo MSt įvertio dydžio  $w_l$ , nuo euristinės informacijos  $\eta_{nu}$ .

Skruzdėlės pasirinkimą pereiti nuo viršūnės  $n$  prie viršūnės  $s$  lemia sąlyga: jei  $q \leq q_0$  tai

$$p_{ns}^k = \begin{cases} 1, & \text{jei } s = \operatorname{argmax}_{u \in N_k(n)} \sum_{l=1}^4 w_l \tau_{nu}^l \eta_{mu}^\beta, \\ 0, & \text{kitu atveju,} \end{cases} \quad (3)$$

kitu atveju


$$p_{ns}^k = \frac{\sum_{l=1}^4 w_l |\tau_{ns}^l|^\alpha |\eta_{ms}|^\beta}{\sum_{\mu \in N_n^k} (\sum_{l=1}^4 w_l |\tau_{n\mu}^l|^\alpha |\eta_{n\mu}|^\beta)}, \quad \text{jei } s \in N_k(n). \quad (4)$$

### 3 Tyrimo rezultatai


Atliekant kompiuterinį simuliaciją anksčiau aprašytas modelis realizuotas konkrečiu algoritmu. Nagrinėjant aprašomą metodą, ypatingas vaidmuo atitenka parametų parinkimui, nes nuo jų priklauso sprendinio gerumas. Kompiuterinio eksperimento metu buvo nagrinėjamos šių parametų reikšmės:  $\alpha$ ,  $\beta$ ,  $q_0$ ,  $P_{geras}$ ,  $\rho$ . Parametras  $\alpha$  rodo, kiek stipriai atsižvelgiama į feromonų skaičių,  $\beta$  – euristinės informacijos įtaką,  $q_0$  – parenkama parametro reikšmė tiesiogiai lemianti lokalias paieškos elgseną,  $P_{geras}$  – pažymys, kuris gali būti parenkamas priklausomai nuo mokymosi konteksto, ir kuris lemia, kiek gerai besimokantys studentai galės palikti pėdsaką (feromonus) ant praeito mokymosi kelio,  $\rho$  – nykstamumo parametras, kurio reikšmė lemia, kaip greitai esantys feromonai ant briaunų nyks, kad nesudarytų lokalus sprendinys, t. y. vienas mokymosi scenarijus, bet galbūt ne pats geriausias. Žemiau pateikiamas algoritmo realizacijos pavyzdys (2 pav.): vienas kelias žymi vieno MST būdingą mokymosi scenarijų, o kitas – kito.

Remiantis atliktų eksperimentų rezultatais buvo parinktos parametų reikšmės:  $\alpha = 0.7$ ,  $\beta = 1.0$ ,  $q_0 = 0.09$ ,  $P_{geras} = 0.7$ ,  $\rho = 0.9$  Kadangi tikslas yra pasiekti efektyvesnio besimokančiųjų (skruzdėlių) mokymosi, tai yra aukštesnių įvertinimų (įvertinimo reikšmės kinta tarp 0 ir 1), kompiuteriniu simuliacijumu buvo tiriamas įvertinimo reikšmių kitimas (3 pav.)

Nagrinėjant SKO algoritmą mokymosi scenarijui parinkti kilo daug klausimų su parametų parinkimu. Parametų reikšmės buvo ieškomos bandymų ir klaidų metodu. Kyla klausimas, ar galimi kiti metodai parametų reikšmėms parinkti? Be to, pastebėta, kad tikimybiškai po skirtingo iteracijų skaičiaus reikšmės „stabilizuojasi“. Kaip galima būtų minimizuoti iteracijų skaičių, t. y. kad kuo mažesnis besimokančiųjų skaičius būtų reikalingas efektyvesnam MS personalizavimui?



2 pav. Skirtingi MS pagal skirtingus besimokančiojo MST.



**3 pav.** Skirtingų įvertinimų išsidėstymas kompiuterinio simuliacijos metu (a) atveju pakankamai geri pažymiai pradunami išgauti žymiai vėliau nei (b) atveju).

## 4 Išvados

Siekiant personalizuoti mokomąjį scenarijų straipsnyje pasirenkamas vienas kriterijus, besimokančiojo mokymosi stilius. Mokymosi stiliumi galima identifikuoti besimokančiojo nuostatas bei pirmenybes (preferencijas) mokomojo proceso atžvilgiu. Autoriai remiasi prielaida, kad skirtingi mokymosi stiliai skirtingai renkami mokomąją medžiagą, t. y. MO. Be to, dažniausiai besimokantysis turi ne vieną, išreikštą mokymosi stilių, bet visą aibę jų pasirinktos mokymosi stilių tipologijos atžvilgiu, galbūt kur vienas ar keli yra dominuojantys. Remiantis literatūros analize, pastebėta, kad elektroninio mokymo atstovai mokymosi stilių traktuoja kaip vieną dominuojantį faktorių ir nepaiso jo įverčio, todėl čia straipsnyje siūlomas modifikuotas SKO grįstas algoritmas, kuriame įvedamas naujas koeficientas, kuriuo siekiama personalizuojant mokomąjį scenarijų tiksliau atsižvelgti į besimokančiojo mokymosi stilių.

SKO algoritmo tinkamumas grindžiamas socialinio faktoriaus idėja: kai to paties mokymosi stiliaus besimokantieji renkami tuos pačius MO, taip identifikuodami, kurie MO jiems patinka, o kurie ne. Be to, SKO, plačiai taikytas keliaujančio pirklio uždaviniui spręsti, gali būti pritaikytas ir mokomojo scenarijaus personalizavimui kai keliamas tikslas - efektyvus besimokančiųjų mokymasis.

Nors SKO taikymas sprendžiamam uždaviniui kelia daug klausimų dėl parametrų parinkimo, tačiau kompiuterinis simuliacijos rodo, kad tinkamai parinkus feromonų skaičiavimo funkciją, parametrų reikšmes, mokomasis scenarijus taikant šį metodą, teoriškai gali būti taikomas. Tolesniuose tyrimuose bus tyrinėjamas ir vertinimas jo tinkamumas realioje taikymų plotmėje, t. y. elektroniniame mokymėsi.

## Literatūra

- [1] G. Acampora, M. Gaeta and et al. Hierarchical optimization of personalized experiences for e-Learning systems through evolutionary models. *Neural Comp. Appl.*, **20**(5):641–657, 2011.
- [2] S. Al-Muhaideb and M. E. Menai. Evolutionary computation approaches to the Curriculum Sequencing problem. *Nat. Comp.*, **10**(2):891–920, 2011.
- [3] M. Alian and R. Jabri. A shortest adaptive learning path in e-Learning systems: Mathematical view. *J. Amer. Sci.*, **5**(6):32–42, 2009.
- [4] S. Cassidy. Learning styles: an overview of theories, models and measures. *Educ. Psych.*, **24**(4):419–444, 2004.
- [5] C. Dagli and N. Kilicay. Understanding behavior of system of systems through computational intelligence techniques. In *Systems Conference 1st Annual IEEE*, 2007.
- [6] M. Dorigo and L. M. Gambardella. Ant colony system: a cooperative learning approach to the traveling salesman problem. *IEEE Trans. Evol. Comp.*, **1**(1):53–66, 1997.

- [7] M. Dorigo, V. Maniezzo and A. Coloni. Ant system: optimization by a colony of cooperating agents. *IEEE Trans. Syst., Man Cybern., Part B: Cybern.*, **26**(1):29–41, 1996.
- [8] V. Drasute, S. Drasutis and D. Baziuke. A method for rational provision of learning syllabus. *Inf. Educ.*, **10**(2):183–193, 2011.
- [9] F.L. Essalmi, J.B. Ayed and et al. A fully personalization strategy of E-learning scenarios. *Comp. Human Behav.*, **26**(4):581–591, 2010.
- [10] N. D. Fleming. *Teaching and learning styles: VARK strategies*. N.D. Fleming, Christchurch, New Zealand, 2006.
- [11] T. F. Hawk and A. J. Shah. Using learning style instruments to enhance student learning. *Dec. Sci. J. Inn. Educ.*, **5**(1):1–19, 2007.
- [12] G.-J. Hwang, F.-R. Kuo and et al. A heuristic algorithm for planning personalized learning paths for context-aware ubiquitous learning. *Comp. Educ.*, **54**(2):404–415, 2010.
- [13] A. Koziarkiewicz-Hetmaska and N. Nguyen. A method for learning scenario determination and modification in intelligent tutoring systems. *Int. J. Appl. Math. Comput. Sci.*, **21**(1):69–82, 2011.
- [14] S. Kubilinskienė ir I. Žilinskienė. Mokymo(si) objektų metaduomenų analizė: valdomų žodynų reikšmės. *Inform. moksl.*, **50**:95–100, 2009.
- [15] E. Kurilovas, I. Žilinskiene and N. Ignatova. Evaluation of quality of learning scenarios and their suitability to particular learners' profiles. In *ECEL 2011, Proceedings of the 10th European Conference on E-Learning*, Brighton: University of Brighton, 2011.
- [16] N. Manouselis and D. Sampson. Dynamic knowledge route selection for personalized learning environments using multiple criteria. In *International Symposium on Artificial Intelligence and Applications, 20th IASTED International Conference in Applied Informatics, Innsbruck, Austria, February, ACTA Press, 2002*.
- [17] M.D. Mulvenna, S.S. Anand and et al. Personalization on the net using web mining: introduction. *Commun. ACM*, **43**(8):122–125, 2000.
- [18] S. Preidys and I. Žilinskiene. Nuotolinio mokymosi kurso personalizavimo modelis mokymosi veiklų atžvilgiu. *Electr. Learn., Inform. Comm.: Theor. Pract.*, **1**:111–132, 2012.
- [19] E. Sangineto and et al. N. Capuano. Adaptive course generation through learning styles representation. *Univ. Access Infor. Soc.*, **7**(1):1–23, 2008.
- [20] T.-I. Wang, K.-T. Wang and et al. Using a style-based ant colony system for adaptive learning. *Expert Syst. Appl.*, **34**(4):2449–2464, 2008.
- [21] L.-H. Wong and C.-K. Looi. Swarm intelligence: new techniques for adaptive systems to provide learning support. *Interactive Learning Environments*, **20**(1):19–40, 2011.
- [22] Y.J. Yang and C. Wu. An attribute-based ant colony system for adaptive learning object recommendation. *Expert Syst. Appl.*, **36**(2):3034–3047, 2009.

## SUMMARY

### Application of swarm intelligence technique to learning scenario personalization

I. Žilinskienė, S. Kubilinskienė

The paper is aimed to analyse learning scenario personalization according to learning styles. In order to do that swarm intelligence technique is discussed and modified ant colony optimization method is suggested. Computer simulation is carried out to verify its suitability to the problem of learning scenario personalization. The results of the computer simulation is presented and parameters customization, long cold-start problems are discussed.

*Keywords:* learning scenario, personalization, learning style, swarm intelligence, e-learning.