

Uroš Ocepek, Irena Nančovska Šerbec, Jože Rugelj, Zoran Bosnić

PRILAGODLJIVI RAČUNALNIŠKI SISTEM ZA PRIPOROČANJE UČNIH OBJEKTOV V KONSTRUKTIVISTIČNEM UČNEM OKOLJU – ALECA

POVZETEK

Dandanes se pojavlja vse več učnih sistemov, ki podpirajo aktivno učenje in upoštevajo učenčeve učne lastnosti, značilnosti in aktivnosti. V prispevku predstavljamo zasnovo učnega priporočilnega sistema, ki združuje znanja pedagogike in računalniških priporočilnih algoritmov. Proučujemo, kako združevanje modelov učnih stilov vpliva na izbiro različnih tipov večpredstavnih učnih gradiv. Rezultati kažejo, da študentje za učenje najpogosteje uporabljajo dobro strukturirana učna gradiva, ki vsebujejo barvno diskriminacijo, in da je hemisferični model učnih stilov najpomembnejši odločitveni kriterij. V nadaljevanju opisujemo postopek za reševanje t. i. problema hladnega zagona, s katerim je mogoče izboljšati točnost sistema za priporočanje učnih gradiv v okoljih, kjer o učencih nimamo predhodnih podatkov. Namen prispevka je predstaviti idejno zasnovo prilagodljivega učnega sistema z analizo njegovih predvidenih učinkov na učno prakso.

Ključne besede: *učni stili, večpredstavnostni tipi, vstavljanje manjkajočih vrednosti, problem novega uporabnika, priporočilni sistemi*

AN ADAPTIVE SYSTEM FOR RECOMMENDING LEARNING OBJECTS IN A CONSTRUCTIVIST LEARNING ENVIRONMENT – ALECA - ABSTRACT

Today there are increasingly more learning environments which support active learning, taking into account student characteristics, preferences and activities. In this paper, we present a concept of a learning recommender system, which combines knowledge from pedagogy and recommending systems. We analyse the influence of combining different learning styles models on preferred types of multimedia

Dr. Uroš Ocepek, *Srednja tehniška in poklicna šola Trbovlje in Fakulteta za računalništvo in informatiko Univerze v Ljubljani, uros.ocepek@gmail.com*

Doc. dr. Irena Nančovska Šerbec, *Pedagoška fakulteta Univerze v Ljubljani, Irena.Nancovska@pef.uni-lj.si*

Izr. prof. dr. Jože Rugelj, *Pedagoška fakulteta Univerze v Ljubljani, Joze.Rugelj@pef.uni-lj.si*

Izr. prof. dr. Zoran Bosnić, *Fakulteta za računalništvo in informatiko Univerze v Ljubljani, zoran.bosnic@fri.uni-lj.si*

materials. The results reveal that students prefer well-structured learning texts with color discrimination, and that the hemispheric learning style model is the most important criterion in determining student preferences for different multimedia learning materials. In the second part of our research, we describe an approach to alleviating the new user problem in terms of better recommendation accuracy of the system for recommending learning materials in environments where the system has no prior information about learners. Our findings present the concept of an adaptive learning system, with an analysis of its possible effects in learning practice.

Keywords: *learning styles, multimedia types, imputing missing values, new user problem, recommender systems*

UVOD

Prilagodljivost učnih računalniških okolij je ena izmed aktualnejših raziskovalnih tem današnjega časa na področju računalniško podprtega učenja. Eden izmed ciljev prilagodljivih učnih okolij je zagotoviti navideznega mentorja, ki »pozna« učenca in ga usmerja v procesu učenja, ter ustvariti možnost, da ima vsak učenec¹ svojega učitelja oziroma skupino učiteljev (Ocepek, Nančovska Šerbec in Rugelj, 2011). To stališče zagovarja konstruktivistična teorija o učenju, ki predpostavlja, da učenec sam konstruira znanje, učitelj pa je mentor, ki ga usmerja in mu daje povratne informacije. Gradnja znanja ne poteka pri vseh enako, ker so učenci med seboj različni in imajo različno predznanje. To pomeni, da mora učitelj dobro poznati svoje učence – njihove učne karakteristike in potrebe (Vogel-Walcutt, Gebirim, Bowers, Carper in Nicholson, 2011). Ker želimo narediti sistem, ki bi do neke mere posnemal učitelja v konstruktivističnem učnem okolju, to pomeni, da mora učno okolje spremljati učenca in pridobiti o njem podatke, ki so pomembni za ugotavljanje njegovih lastnosti, ki vplivajo na učenje. Učenčeve lastnosti lahko razvrstimo v dve skupini: zunanje, kot so pisava, govor, obrazna mimika in govorna telesa, ter notranje, kamor sodijo kognitivne, metakognitivne in afektivne lastnosti (Arroyo, Woolf, Burelson, Muldner, Rai in Tai, 2014). Med notranje lastnosti uvrščamo učni stil, učenčevo (pred)znanje, preferenčne multimedijske predstavitve učnih vsebin, njegov odnos do učenja in način učenja. S temi podatki o učencu je mogoče zgraditi njegov model, ki se uporablja za priporočanje ustreznih učnih vsebin (Woolf, 2009). Tovrstno modeliranje učenca se uporablja pri inteligentnih tutorskih sistemih, kognitivnih tutorjih in adaptivnih učnih okoljih, ki so sinonimi za moderne učne sisteme, med katere sodi tudi sistem, ki ga opisujemo v prispevku.

Konstruktivistična teorija učenja temelji na načelu, da učenec samostojno raziskuje in išče želene podatke ter z reševanjem nalog in učnih problemov gradi novo znanje. Načrtovanje in implementacija spletnega konstruktivističnega učnega okolja sta kompleksni nalogi, ker je treba upoštevati možnost, da ima lahko vsak učenec svoj učni scenarij in svoj prevladujoči način učenja, ki se lahko razlikuje od pristopov preostalih učencev. To je razlog, da v praksi spletna učna okolja, ki bi bila namenjena izključno konstruktivističnemu

1 Z besedo učenec označujemo učečega se posameznika v različnih starostnih obdobjih.

učenju, ne obstajajo. Po Jonassenu (1999) bi torej morali upoštevati preveč stvari, če bi želeli povsem pokriti in zagotoviti učno situacijo, kot jo predvideva konstruktivizem.

Hernández-Leo in sodelavci (2006) so pred desetletjem razvili orodje COLLAGE, ki pomaga učitelju pri načrtovanju, organizaciji in izvedbi sodelovalnega dela v skupinah. Orodje omogoča prikaz učnih gradiv in izvajanje učnih aktivnosti, ki jih pripravijo učitelji. Učitelj tako izbere samo eno izmed oblik sodelovalnega dela ter pripravi ustrezna gradiva in aktivnosti. Cho, Gay, Davidson in Ingraffea (2007) so še dodatno proučevali, kako lahko povežejo podobne uporabnike v družabnih omrežjih. Ugotovili so, da obstaja korelacija med tvorjenjem družbenih mrež in komunikacijskim stilom in da lahko podobne uporabnike uvrščajo v skupine glede na komunikacijske stile in učne dosežke. Študentje, ki nimajo težav pri izražanju svojega mnenja in so komunikativni, bistveno lažje spletajo nova virtualna prijateljstva in sodelujejo z neznanci.

Shaw je oblikoval spletno učno okolje, pri katerem je raziskal odvisnosti med učnimi stili, sodelovalnimi tipi (načini sodelovanja znotraj spletnega foruma) in učnim dosežkom. Pokazal je, da sta sodelovalni tip in učni stil povezana z učnim dosežkom (Shaw, 2012). Vsi naštet primeri temeljijo na teoretični zasnovi spletnih učnih okolij za podporo sodelovalnemu učenju (angl. *collaborative learning*). Zelo malo izmed njih je bilo realiziranih, saj gre za kompleksnejše sisteme.

Na področju konstruktivističnih spletnih učnih okolij je neraziskano vprašanje prilagajanja predstavitev učnih vsebin v konstruktivizmu. V literaturi se za to uporablja poimenovanje prilagodljivi hipermedijski sistemi. Idejno zasnovo takšnega sistema povzemamo v pričujočem članku. V okviru interdisciplinarnega raziskovalnega dela smo želeli oblikovati koncept novega prilagodljivega računalniškega učnega okolja ALECA (*Adaptive Learning Environment with Constructivist Approach*) (Ocepek idr., 2012) s priporočanjem učnih objektov za poučevanje računalništva in informatike v srednjih šolah. Prilagajanje učnih objektov, ki jih sistem priporoča, temelji na učenčevih karakteristikah in konstruktivistični teoriji učenja (Ocepek, Nančovska Šerbec in Rugelj, 2012).

METODOLOGIJA

Modeliranje učenca za priporočanje ustreznih večpredstavnostnih gradiv

Za uporabo v priporočilnem sistemu smo izbrali štiri modele učnih stilov. S pomočjo prevedenih vprašalnikov smo dobili informacijo o učenčevemu pristopu k reševanju problemov (Kolbov model (Kolb, 1984; Marentič-Požarnik in Peklaj, 1995)), načinu spoznavanja (Rancourtov model (Rancourt, 1988; Marentič-Požarnik, 1995)), načinu razmišljanja (model hemisferne dominantnosti (Reynolds, Kaltsounis in Torrance, 1979; Peklaj, 1995)) in prevladujočem načinu sprejemanja informacij (model VAK (Rose, 1987; Stražičar, 2004)).

Kolbov model učnih stilov temelji na konceptu aktivnega učenja in vključuje naslednje učne stile: asimilativni, konvergentni, akomodativni in divergentni stil (Kolb, 1984; Kolb

in Kolb, 2005). Asimilativni posamezniki dajejo poudarek teoretičnim vsebinam z logičnim in praktičnim vidikom; konvergentni ljudje dajejo ključno vlogo praktičnemu vidiku v učnih vsebinah; posamezniki z akomodativnim stilom se osredotočajo na uporabo različnih pristopov/metod za doseg učnih ciljev; divergentni ljudje pa so pozorni na zaznavanje različnih vidikov konkretne situacije (Mos in Royce, 1980).

Rancourtov model učnih stilov opisuje značilne načine uresničevanja spoznavnega in/ali čustvenega pojava (Rancourt, 1988; Mos in Royce, 1980). Rancourtovi učni stili so racionalni stil, ki temelji predvsem na logičnem sklepanju in argumentiranju, empirični stil, ki temelji na opazovanju/izbiranju informacij iz okolja, in noetični stil, ki temelji na subjektivnih spoznanjih.

Hemisferna dominantnost je pomemben element v učenju, saj obstaja med možganskima hemisferama glede načina razmišljanja in pristopanja k problemom bistvena razlika (Reynolds idr., 1979). Glede na hemisferno dominantnost govorimo o treh učnih stilih: levohemisferičnem, desnohemisferičnem in integrativnem učnem stilu. Učenci z levohemisfernim stilom raje analizirajo, uporabljajo dejstva, logično sklepajo in operirajo s števili. Njihovo nasprotje so desnohemisferni učenci, ki imajo raje eksperimentiranje, intuitivno sklepanje in kreativno razmišljanje. Učenci, ki se lahko identificirajo z obema stiloma, ustrezajo integrativnemu učnemu stilu.

Model učnih stilov VAK temelji na senzoričnih poteh, prek katerih sprejemamo informacije iz okolja. Učni stili so: vizualni, slušni in kinestetični (Fleming in Mills, 1992). Učenci z vizualnim stilom se lažje učijo, če imajo učno vsebino predstavljeno slikovno namesto besedilno. Slušni učenci se raje učijo predvsem prek poslušanja predavanj in drugih avdioposnetkov. Kinestetični učenci pa imajo rajši praktično učenje prek gibanja in simulacij.

Povezava med učnimi stili in tipi učnih gradiv

S podatki o ustreznosti povezav učnih stilov z različnimi multimedijskimi tipi bi lahko študentom na bolj ustrezen način izbrali predstavitev učnih vsebin. V raziskavo smo vključili 272 dodiplomskih študentov Univerze v Ljubljani z naslednjih smeri: matematika (57), računalništvo (37), razredni pouk (75), naravoslovje (51) in družboslovje (52).

Slika 1 prikazuje porazdelitev študentov glede na različne stile znotraj modelov učnih stilov. Študente, ki jim ni bilo možno enolično določiti primarnega učnega stila (ker sta dva enako izrazita), smo razvrstili v skupino NA (angl. *Not Available*).

Kolbov model učnih stilov	Rancourtov model učnih stilov	Hemisferični model učnih stilov	Model učnih stilov VAK
Akomodativni (N = 82) Divergentni (N = 79) Konvergentni (N = 64) Asimilativni (N = 47)	Empirični (N = 83) Racionalni (N = 81) Noetični (N = 71) NA (N = 37)	Desnohemisf. (N = 109) Integrativni (N = 82) Levohemisf. (N = 41) NA (N = 40)	Slušni (N = 67) Vizualni (N = 62) Kinestetični (N = 38) NA (N = 105)

Slika 1: Porazdelitev študentov glede na posamezne učne stile

Modeliranje z večciljnim regresijskim drevesom

Za analizo povezanosti smo zgradili napovedni model, za katerega smo uporabili naslednje vhodne podatke (attribute):

- KLS: oznaka Kolbovega učnega stila (divergentni, konvergentni, asimilativni in akomodativni stil),
- RLS: oznaka Rancourtovega učnega stila (racionalni, noetični in empirični),
- HLS: oznaka hemisfernega učnega stila (levohemisferni, desnohemisferni in integrativni stil),
- VLS: oznaka učnega stila VAK (vizualni, slušni in kinestetični stil).

Ciljne spremenljivke za modeliranje opisujejo različne vrste multimedijskih gradiv in so:

- 1) animacije in videoposnetki (spremenljivka M1);
- 2) simulacije in izobraževalne igre (spremenljivka M2);
- 3) besedila z barvno diskriminacijo, kjer so ključni deli besedila označeni z drugačno barvo kot preostalo besedilo (spremenljivka M3);
- 4) strukturirana učna gradiva, v katerih so elementi v logičnem vrstnem redu (spremenljivka M4);
- 5) avdioposnetki (spremenljivka M5).

Ciljne spremenljivke zavzemajo celoštevilске vrednosti od 1 do 4, ki označujejo, kako pogosto študent uporablja posamezen multimedijski tip (1 – nikoli, 2 – redko, 3 – pogosto in 4 – vedno).

Večciljno regresijsko drevo je napovedni model s področja umetne inteligence, ki se uporablja za modeliranje povezav med vhodnimi in ciljnimi spremenljivkami. Podobno je običajnemu odločitvenemu (regresijskemu) drevesu z eno ciljno vrednostjo, le da listi večciljnega drevesa vključujejo več ciljnih spremenljivk (Struyf in Džeroski, 2006; Kocev, Džeroski, White, Newell in Griffioen, 2009). Metoda deluje tako, da začetno populacijo študentov deli v manjše podvzorke, upoštevajoč statistično najboljšo izbiro atributa v notranjih vozliščih drevesa (Kocev idr., 2009). V raziskavi smo uporabili orodje CLUS (Blockeel in Struyf, 2003).

Večciljna drevesa je možno interpretirati tako, da sledimo poti od korena (vrha) do listov in spremljamo, kako različne kombinacije učnih stilov vplivajo na pogostost uporabe vseh petih multimedijskih tipov hkrati.

Priporočanje učnih objektov za učence in problem hladnega zagona

Zgrajeni model za izbor ustrezne predstavitve učne vsebine pomaga sistemu izbrati najprimernejši večpredstavnostni tip učnih gradiv. Cilj pa je implementirati priporočilni sistem, ki priporoča tudi posamezne učne vsebine (Ocepek, 2015). Priporočilni sistemi izvajajo napovedovanje ocen objektov, ki jih uporabnik še ni ocenil. Uporabljajo se na primer v spletnih trgovinah, kjer uporabniku priporočajo izdelke, ki so jih kupili njemu podobni uporabniki. Ta mehanizem lahko izkoristimo tudi pri implementaciji učnega sistema, saj lahko učencu priporočamo učna gradiva, ki so jih uporabili njemu podobni učenci. Na

področju priporočilnih sistemov se pogosto srečujemo s problemom obravnave novega uporabnika (v našem primeru novega učenca), saj zanj nimamo začetnih podatkov (njegovih lastnosti, na podlagi katerih bi ga primerjali z drugimi), ki bi nam pomagali pri priporočanju ustreznih objektov. Tej situaciji pravimo *problem hladnega zagona* oz. *problem novega uporabnika*.

V prejšnjih raziskavah smo prikazali nov pristop k reševanju problema hladnega zagona (Ocepek, Rugelj in Bosnić, 2015; Ocepek, 2015), ki deluje brez dodatnega začetnega poizvedovanja o novem uporabniku. Omenjena rešitev temelji na ideji avtomatskega dopolnjevanja vhodne matrike znanih ocen (na podlagi katere deluje priporočilni sistem), tako da za uporabnike v hladnem zagonu smiselno vstavi nekaj začetnih manjkajočih vrednosti in nato izvede običajen algoritem za priporočanje. Postopek sestavljajo naslednji ključni koraki:

- 1) uporabniku v hladnem zagonu poiščemo N-število podobnih uporabnikov,
- 2) znotraj množice podobnih uporabnikov določimo attribute/objekte, ki jim bomo dopolnili manjkajočo vrednost;
- 3) izbranim atributom izračunamo oz. vstavimo manjkajočo oceno;
- 4) uporabimo prvotno zeleno matrično faktorizacijo nad vsemi uporabniki.


Pristop je podoben delu Chena in sodelujočih, ki so pokazali, da z gradnjo omrežij podobnih uporabnikov lahko objekte uspešno priporočimo uporabnikom v hladnem zagonu (Chen, Wan, Chung in Sun, 2013). Razširitev uporabnikovega profila z objekti, ki so podobni že ocenjenim objektom, pa je tudi ključno za izboljšanje priporočanja uporabnikom v hladnem zagonu (Formoso, Fernández, Cacheda in Carneiro, 2013).

REZULTATI

Model učenca za priporočanje ustreznih večpredstavnostnih gradiv

Slika 2 (Ocepek, Bosnić, Nančovska Šerbec in Rugelj, 2013) prikazuje zgrajeni model drevesa, ki vsebuje sedem listov (vozlišč na dnu drevesa). Zgrajeno večciljno regresijsko drevo ima v korenu hemisferni model učni stilov, kar pomeni, da ga je model ocenil kot najpomembnejši atribut. Če pogledamo vrednosti v listih levega in desnega poddrevesa, vidimo, da korensko vozlišče razdeli študente glede na večjo (vozlišče {b}) in manjšo rabo multimedijskih gradiv (vozlišče {c}). To pomeni, da desnohemisferni študentje pogosteje uporabljajo različne multimedijske tipe gradiv kot študentje z levohemisfernim oz. integrativnim ucnim stilom. Glede na vozlišče {b} študentje, ki so desnohemisferni in asimilativni, redkeje uporabljajo animacije (M1), simulacije (M2), besedila z barvno diskriminacijo (M3) in avdiomaterial (M5). Ta ugotovitev podpira izhodišče, da se asimilatorji osredotočajo na študij besedilnih ucnih virov in na analitično raziskovanje različnih modelov. Zato dajejo večji poudarek teoretičnim in besedilnim razlagam. Študentje, ki so desnohemisferni, empirični in niso asimilatorji (list {2}), v povprečju pogosteje uporabljajo vse multimedijske tipe kakor študentje, ki so desnohemisferni, a niso empirični in niso asimilatorji. Tudi ta ugotovitev podpira teoretično razlago, da empirični ljudje dajejo

večji poudarek zaznavanju okolja pri učenju, zato je smiselno, da se jim ponudijo raznovrstne multimedijske predstavitve.



Slika 2: Večciljno regresijsko drevo za napovedovanje pogostosti uporabe multimedijskih tipov gradiv glede na študentove učne stile: višja ko je vrednost pri oznaki multimedijskega tipa (M1–M5) v listu, pogostejše študentje uporabljajo ta multimedijski tip

Poglejmo še, kaj velja za študente, ki niso desnohemisferni. Glede na drevo študentje, ki so vizualni in divergentni, a niso desnohemisferni (list {4}), pogostejše uporabljajo multimedijske tipe M1, M3 in M4, kar ponovno potrjuje teoretično razlago, da se študentje z vizualnim in divergentnim učenjskim stilom pri učenju opirajo predvsem na informacije, ki so jih zaznali prek vida. Zato so zanje primernejše vizualne predstavitve učne snovi, kot so animacije, videoposnetki in besedila, ki so barvno diskriminirana.


Glede na drevo lahko torej sklepamo, da študentje v povprečju najpogostejše uporabljajo besedila, ki so dobro strukturirana in vsebujejo barvno diskriminacijo. Eden izmed

ključnih razlogov za to je, da so študentje vajeni klasičnega učenja ob knjigah in učbenikih; po drugi strani pa smo navajeni vsakodnevno spremljati filme s podnapisi, kar se kaže v tem, da se raje učijo z besedilnim materialom (Lapuh Bele in Rugelj, 2009).

Poglejmo na primeru, kako lahko uporabimo zgrajeni model za priporočanje ustreznih predstavitev učnih vsebin. Denimo, da imamo študenta, ki je akomodativen, racionalen, desno-hemisferen in vizualen. Študent želi poiskati alternativo besedilni predstavitvi delu učne snovi. Model bi študenta razvrstil v list {3}, kar pomeni, da bi mu priporočil animacije in videogradiva za izbrani del učne vsebine. Odločitev je povsem smiselna, saj ima študent vizualni učni stil. Hkrati pa je študent tudi desnohemisferen in racionalen, kar pomeni, da daje poudarek zaznavanju informacij iz okolja, te pa smiselno analitično in teoretično ovrednoti.

Uspešnost priporočanja za učence v hladnem zagonu

Evalvacija pristopa na eni umetni in dveh realnih podatkovnih množicah za testiranje priporočanja (Goldberg, Roeder, Gupta in Perkins, 2001) in PEF base (Ocepek idr., 2013) je pokazala, da z opisanim pristopom dosežemo večjo točnost priporočanja pri uporabljenih faktorizacijah: nenegativna matrična faktorizacija s stohastičnim gradientnim spustom (NG) (Koren, Bell in Volinsky, 2009; Funk, 2011), nenegativna matrična faktorizacija z izmenjujočimi se najmanjšimi kvadrati (NS) (Bell in Koren, 2007; Takács in Tikk, 2012), polnenegativna matrična faktorizacija z manjkajočimi vrednostmi (SN) (Ding, Li in Jordan, 2010; Mo in Draper, 2012) in matrična faktorizacija z zlivanjem podatkov (DF) (Žitnik in Zupan, 2013; Žitnik in Zupan, 2015). Slika 3 prikazuje evalvacijo na dveh realnih domenah, na katerih smo testirali poleg običajnih metod matričnih faktorizacij še tri metode, ki smo jih oblikovali glede na naš predlagani pristop. Izbrali smo tri dobro delujoče metode, ki jih označujemo z *metoda 1*, *metoda 2* in *metoda 3* ter njihove rezultate prikazujemo na Sliki 3. Evalvacija je pokazala, da smo z našim pristopom izboljšali priporočanje (zmanjšali povprečno napako) pri matričnih faktorizacijah NG, NS in SN ter s tem izboljšali delovanje priporočilnega sistema.




Slika 3: Evalvacija našega pristopa – predlaganih kombinacij v primerjavi z golimi matričnimi faktorizacijami; evalvacija izbranih kombinacij metod je potekala na dveh realnih podatkovnih množicah (Ocepek, 2015); nižji ko je stolpec, manjša je povprečna napaka priporočilnega sistema (RRSE)

Zasnova prilagodljivega učnega sistema

Na podlagi ugotovitev iz razdelkov »Model učenca za priporočanje ustreznih večpredstavnostnih gradiv« in »Uspešnost priporočanja za učence v hladnem zagonu« je mogoče zasnovati učni sistem, ki temelji na dejstvu, da priporočanje učnih objektov in izbiranje ustreznih multimedijskih tipov učnih gradiv pripomoreta k učinkovitejšemu (samostojnemu) učenju. S priporočanjem tipa predstavitve učne vsebine (razdelek »Model učenca za priporočanje ustreznih večpredstavnostnih gradiv«) za priporočene učne objekte (razdelek »Uspešnost priporočanja za učence v hladnem zagonu«) želimo učencu olajšati iskanje ustreznih učnih gradiv in s tem zmanjšati možnost kognitivne preobremenitve. Naše izhodišče je, da poljubne učne snovi ne moremo predstaviti vedno na enak način – torej z istim multimedijskim tipom, čeprav ugotovljene korelacije med učnimi stili in multimedijskimi tipi veljajo. V razdelku »Model učenca za priporočanje ustreznih večpredstavnostnih gradiv« smo pokazali, da se učenci pogosteje učijo z besedilnimi učnimi objekti, kar je po svoje razumljivo, saj gre za naučene vedenjske vzorce učenja. Hkrati pa se tudi zavedamo, da vseeno obstajajo pristopi, po katerih se učenci lažje in učinkoviteje učijo.

Zasnova našega učnega sistema temelji na empiričnih modelih študentov, s katerimi lahko napovedujemo študentovo vedenje in njegov način gradnje znanja. Z upoštevanjem modelov lahko sistem posnema mentorjeve pedagoške poteze z namenom, da študentom svetuje in pomaga pri napredku v smeri pridobivanja (novega) znanja in obvladanja področja učenja (Arroyo idr., 2014). Idejna zasnova sistema (Slika 4) temelji na spremljanju ocenjevanja uporabnosti učnih objektov s strani učencev. Podatek o uporabnosti nam pove, kateri učni objekti se zdijo učencem najuporabnejši za učenje neke učne snovi. Priporočanje tipa predstavitve učnih objektov temelji na iskanju podobnosti med učenci, za kar lahko uporabljamo priporočilni sistem. Znotraj sistema iščemo našemu uporabniku (učencu) podobne uporabnike, saj trdimo, da se učenci s podobnimi učnimi preferencami učijo na podoben način. Če sta dva učenca podobno ocenila učne objekte v preteklosti, je verjetno, da bosta podobno ocenila tudi tiste učne objekte, ki jih doslej še nista ocenila. V učnem procesu je ključno, da učenec dobi nasvete oz. priporočila, katere učne objekte in katere njihove predstavitve naj izbere, da bo z njihovo pomočjo dosegel operativne učne cilje. Doseganje operativnih učnih ciljev pa preverjamo v fazi sprotnega in končnega preverjanja znanja.



Slika 4: Koncept učnega sistema ALECA – prilagodljivi učni sistem za priporočanje učnih gradiv v konstruktivističnem učnem okolju

Slika 4 je poenostavljen shematski prikaz predlaganega učnega sistema, ki smo ga poimenovali ALECA. Ko se učenec prijavi v sistem, izpolni vprašalnike o učnih stilih. Tako sistem pridobi začetne podatke o učencu. Ko učenec začne sistem uporabljati, mu ta priporoči učne objekte. Sistem uporabi pristop priporočilni sistemov (Slika 4, pravokotnik desno zgoraj), ki glede na preostale uporabnike/učence našemu učencu priporoči zanj najprimernejše učne objekte. Ko učenec izbere ustrezno učno temo (učni objekt), mu jo sistem prikaže. Za izbor ustrezne multimedijske predstavitve izbrane teme uporabi model, ki smo ga predstavili v razdelku »Model učenca za priporočanje ustreznih večpredstavnostnih gradiv«. Glede na učenčeve učne stile sistem izbere zanj najprimernejšo predstavitev učnega objekta. Ko učenec konča učenje/obravnavo učnega objekta, oceni uporabnost učnega objekta. S tem dobi sistem povratno informacijo o primernosti učnega gradiva. Po drugi strani pa vsak učni objekt vključuje krajšo nalogo (sprotno/formativno preverjanje znanja), s katero sistem prejme povratno informacijo tudi o tem, ali učenec dosega posamezne učne cilje, hkrati pa na tak način sistem lahko ugotovi, katerih delov snovi učenec še ne obvlada, in to upošteva pri izbiri nove učne snovi. Posledično učni sistem iz modela učenca in učnih ciljev, ki jih je določil učitelj na začetku procesa učenja, zgradi oziroma dopolni množico učnih vsebin, ki jih lahko naš učni sistem priporoči učencu.

DISKUSIJA IN UGOTOVITVE

Priporočilni učni sistemi spadajo na interdisciplinarno področje, ki povezuje didaktične znanosti ter računalništvo in informatiko. V okviru raziskave smo oblikovali model učnega sistema, ki temelji na prilagodljivih učnih sistemih in priporočilnih sistemih za podporo konstruktivističnim pristopom k učenju. Predlagani model učnega sistema lahko učencu predlaga, kateri učni objekti so zanj primeri, da bo dosegel vnaprej zastavljane učne cilje. Za izbrane učne objekte sistem izbere ustrezno predstavitev glede na učenčeve učne značilnosti in preference.

V prispevku smo najprej predstavili zgrajeni odločitveni model za izbiranje primernih predstavitev učne vsebine. V modelu smo združili štiri različne modele učnih stilov (Kolbov model, Rancourtov model, model hemisferne dominantnosti in model VAK) – za lažji izbor najprimernejše multimedijske predstavitve učne vsebine. Z zgrajenim modelom smo potrdili, da je pri izbiranju/priporočanju različnih tipov multimedijskih gradiv smiselno kombinirati različne modele učnih stilov. Zgrajeni model je pokazal, da je hemisferni model učnih stilov najbolj vpliven/pomemben odločitveni atribut; Kolbov model učnih stilov in model VAK sta druga najpomembnejša odločitvena atributa. Raziskava je pokazala, da študentje za učenje najpogosteje uporabljajo besedila, ki so dobro strukturirana in imajo barvno diskriminacijo. Poleg besedil pogosto uporabljajo tudi animacije in videoposnetke.

Predlagani sistem je primeren za uporabo v poljubnem spletnem oz. računalniškem učnem okolju. Model lahko učitelj uporabi tudi v razredu, saj lahko glede na učenčeve uvrstitve v posamezni učni stil prilagodi razlago učne teme oz. mu poda učno razlago s priporočenimi multimedijskimi predstavitvami. S tem lahko prejme povratno informacijo o učnih karakteristikah in priporočljivih multimedijskih predstavitvah učne vsebine za učenca v posameznem oddelku.

V prihodnje se bomo osredotočili na gradnjo splošnega priporočilnega sistema za podporo učenju, pri katerem bomo izdelali različna učna gradiva (učne objekte) in tako zagotovili zadostno število učnih objektov. Učni sistem bo zastavljen splošno, tako da ga bo možno uporabiti za poučevanje različnih vsebin oz. predmete poučevanja.

LITERATURA

- Arroyo, I., Woolf, B. P., Burelson, W., Muldner, K., Rai, D. in Tai, M. (2014). A multimedia adaptive tutoring system for mathematics that addresses cognition, metacognition and affect. *International Journal of Artificial Intelligence in Education*, 24(4), 387–426.
- Bell, R. M. in Koren, Y. (2007). Scalable Collaborative Filtering with Jointly Derived Neighborhood Interpolation Weights. V *Data Mining, 2007. ICDM 2007. Seventh IEEE International Conference on Data Mining (ICDM 2007)* (str. 43–52). Omaha: IEEE.
- Blockeel, H. in Struyf, J. (2003). Efficient algorithms for decision tree cross-validation. *The Journal of Machine Learning Research*, 3, 621–650.
- Chen, C. C., Wan, Y. H., Chung, M. C. in Sun, Y. C. (2013). An effective recommendation method for cold start new users using trust and distrust networks. *Information Sciences*, 224, 19–36.

- Cho, H., Gay, G., Davidson, B. in Ingrassia, A. (2007). Social networks, communication styles, and learning performance in a CSCL community. *Computers & Education*, 49.
- Ding, C., Li, T. in Jordan, M. I. (2010). Convex and semi-nonnegative matrix factorizations. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 32(1), 45–55.
- Fleming, N. D. in Mills, C. (1992). Not another inventory, rather a catalyst for reflection. *To Improve the Academy*, 11.
- Formoso, V., Fernández, D., Cacheda, F. in Carneiro, V. (2013). Using profile expansion techniques to alleviate the new user problem. *Information Processing & Management*, 49(3), 659–672.
- Funk, S. (2011). Netflix update: *Try this at home, 2006*. Pridobljeno s <http://sifter.org/~simon/journal/20061211.html>.
- Goldberg, K., Roeder, T., Gupta, D. in Perkins, C. (2001). Eigentaste: A constant time collaborative filtering algorithm. *Information Retrieval*, 4(2), 133–151.
- Hernández-Leo, D., Villasclaras-Fernández, E., Jorrín-Abellán, I., Asensio-Pérez, J., Dimitriadis, Y., Ruiz-Requies, I. in Rubia-Avi, B. (2006). COLLAGE, a collaborative learning design editor based on patterns. *Journal of Educational Technology and Society*, 9.
- Jonassen, D. (1999). Activity theory as a framework for designing constructivist learning environments. *Educational Technology Research and Development*, 47(1), 61–79.
- Kocev, D., Džeroski, S., White, M. D., Newell, G. R. in Griffioen, P. (2009). Using single- and multi-target regression trees and ensembles to model a compound index of vegetation condition. *Ecological Modelling*, 220(8), 1159–1168.
- Kolb, A. Y. in Kolb, D. A. (2005). Learning Styles and Learning Spaces: Enhancing Experiential Learning in Higher Education. *Academy of management learning & education*, 4(2), 193–212.
- Kolb, D. A. (1984). *Experiential learning: Experience as the source of learning and development*, 1. Englewood Cliffs: Prentice-Hall.
- Koren, Y., Bell, R. in Volinsky, C. (2009). Matrix factorization techniques for recommender systems. *Computer*, 8, 30–37.
- Lapuh Bele, J. in Rugelj, J. (2009). Comparing Efficiency of Web Based Learning Contents on Different Media. *International Journal of Emerging Technologies in Learning*, 4(SI3).
- Marentič-Požarnik, B. (1995). Vprašalnik načinov in stilov spoznavanja po Rancourt. V B. Marentič-Požarnik, L. Magajna in C. Peklaj, *Izzivi raznolikosti. Stili spoznavanja, učenja, mišljenja* (str. 117). Nova Gorica: Educa.
- Marentič-Požarnik, B. in Peklaj, C. (1995). Kolbov vprašalnik o učnih stilih. V B. Marentič-Požarnik, L. Magajna in C. Peklaj, *Izzivi raznolikosti. Stili spoznavanja, učenja, mišljenja* (104). Nova Gorica: Educa.
- Mo, Q. in Draper, B. A. (2012). Semi-nonnegative matrix factorization for motion segmentation with missing data. V *Computer Vision--ECCV 2012* (str. 402–415). Berlin, Heidelberg: Springer.
- Mos, L. in Royce, J. (1980). *Manual, Psycho-epistemological Profile*. Edmonton: Center for Advanced Study in Theoretical Psychology, University of Alberta.
- Ocepek, U. (2015). *Model adaptivnega sistema za priporočanje učnih objektov v konstruktivističnem učnem okolju. (Doktorska disertacija)*. Ljubljana: Univerza v Ljubljani, Fakulteta za računalništvo in informatiko.
- Ocepek, U., Bosnić, Z., Nančovska Šerbec, I. in Rugelj, J. (2013). Exploring the relation between learning style models and preferred multimedia types. *Computers & Education*, 69, 343–355.
- Ocepek, U., Nančovska Šerbec, I. in Rugelj, J. (2011). Prilagodljivo učno okolje ALECA. *Dvajseta mednarodna Elektrotehniška in računalniška konferenca ERK 2011* (str. 445–448). Ljubljana: IEEE Region 8, Slovenska sekcija IEEE.

- Ocepek, U., Nančovska Šerbec, I. in Rugelj, J. (2012). Računalniški sistem ALECA za podporo konstruktivističnemu učenju. V *Zbornik vseh prispevkov* (str. 1313–1318). Ljubljana: Miška.
- Ocepek, U., Rugelj, J. in Bosnić, Z. (2015). Improving matrix factorization recommendations for examples in cold start. *Expert Systems With Applications*, 42(19), 6784–6794.
- Pekljaj, C. (1995). Vprašalnik: Tvoj stil učenja in razmišljanja. V B. Marentič-Požarnik, L. Magajna in C. Pekljaj, *Izzivi raznolikosti. Stili spoznavanja, učenja, mišljenja* (str. 179). Nova Gorica: Educa.
- Rancourt, R. (1988). *K.A.M.I.: Consultant's manual to style interpretation*. Ontario: Impact Inc.
- Reynolds, C. R., Kaltounis, B. in Torrance, E. P. (1979). A Children's Form of Your Style of Learning and Thinking: Preliminary Norms and Technical Data. *Gifted Child Quarterly*, 23(4), 757–767.
- Rose, C. (1987). *Accelerated learning*. Aylesbury, Bucks: Accelerated Learning Systems Limited.
- Shaw, R.-S. (2012). A study of the relationships among learning styles, participation types, and performance in programming language learning supported by online forums. *Computers & Education*, 58, 111–120.
- Stražičar, M. (2004). Učenje in pomnjenje: predelava podatkov za dolgotrajno pomnjenje. V M. Stražičar, *Psihologija: spoznanja in dileme* (str. 112). Ljubljana: DZS.
- Struyf, J. in Džeroski, S. (2006). Constraint Based Induction of Multi-objective Regression Trees. *4th Int'l Workshop on Knowledge Discovery in Inductive Databases: Revised Selected and Invited Papers*. Porto: Springer.
- Takács, G. in Tikk, D. (2012). Alternating least squares for personalized ranking. V *Proceedings of the sixth ACM conference on Recommender systems – RecSys, 12* (str. 83–90). Dublin: ACM.
- Vogel-Walcutt, J. J., Gebrim, J., Bowers, C., Carper, T. in Nicholson, D. (2011). Cognitive load theory vs. constructivist approaches: which best leads to efficient, deep learning? *Journal of Computer Assisted Learning*, 27, 133–145.
- Woolf, B. P. (2009). *Building intelligent interactive tutors*. Burlington: Elsevier Inc.
- Žitnik, M. in Zupan, B. (2013). Matrix factorization-based data fusion for gene function prediction in baker's yeast and slime mold. *Pacific Symposium on Biocomputing. Pacific Symposium on Biocomputing*, 19 (str. 400). Fairmont Orchid: World Scientific.
- Žitnik, M. in Zupan, B. (2015). Data Fusion by Matrix Factorization. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 37(1), 41–53.