

Darko Ščavničar

DOI: 10.2478/cmc-2023-0021

PODATKOVNA MOČ V VOJAŠKEM IZOBRAŽEVANJU: ZAVEDANJE IN RAZUMEVANJE UČNE ANALITIKE

DATA POWER IN MILITARY EDUCATION: AWARENESS AND UNDERSTANDING OF LEARNING ANALYTICS

Povzetek Količina ustvarjenih podatkov je danes zelo velika, temu pa sledi napredek pri zbiranju, obdelavi in analizi velikih količin podatkov za mnoge namene, kot so različne industrije, znanost, zdravstvo in tudi izobraževanje. Cilj podatkovne znanosti v vojaškem izobraževanju je bolje razumeti in izboljšati učne procese z vpogledi, ki temeljijo na podatkih. Učna analitika preučuje, kako uporabiti podatkovno rudarjenje, strojno učenje, obdelavo naravnega jezika, vizualizacijo in pristope interakcije med človekom in računalnikom, da bi učencem, izvajalcem izobraževanj ter vodjem institucij pomagali izboljšati učne procese in prakso poučevanja.

Ključne besede *Vojaško izobraževanje, učenje, analiza podatkov, učna analitika, podatkovna moč.*

Abstract The rapid development, use and availability of technology is creating new opportunities in all areas of human life. The amount of data generated is enormous, followed by advances in the collection, processing and analysis of big data for a variety of purposes, such as various industries, science, healthcare and even education. Data science in education aims to better understand and improve learning processes through data-driven insights. Learning analytics studies how to use data mining, machine learning, natural language processing, visualisation and human-computer interaction approaches to help learners, educators and institutional leaders improve learning processes and teaching practices.

Key words *Military education, learning, data analysis, learning analytics, data power.*

Uvod Učna analitika je navadno opredeljena kot zbiranje, merjenje, analiziranje in poročanje podatkov o izobraževalcih in njihovih okoliščinah za razumevanje in optimizacijo učenja in okolja, v katerem poteka. Kako natančna in široka bo uporaba učne analitike, je odvisno od zbranih podatkov in razvoja računalniških tehnik za analizo teh podatkov. Vključuje uporabo podatkov in statističnih metod za pridobivanje vpogleda v različne vidike učnega procesa, kot so vključenost, uspešnost in napredek izobraževalcev. Z učno analitiko lahko izobraževalci in institucije spremljajo ter merijo učinkovitost svojih učnih metod, ugotavljajo področja, na katerih učenci morda potrebujejo dodatno podporo, ter sprejemajo na podatkih temelječe odločitve za izboljšanje učnih izkušenj. Učna analitika lahko uporablja različne vire podatkov, vključno z ocenami, učnimi gradivi, spletnimi razpravami in demografskimi podatki izobraževalcev. Z uporabo teh podatkov lahko deležniki v izobraževanju bolje razumejo vedenje, preference in vzorce učenja učencev, kar na koncu vodi k bolj prilagojenemu in učinkovitemu poučevanju (Siemens in Long, 2011, str. 30).

Razcvet področja učne analitike je omogočil široko paleto tehnoloških rešitev, ki se lahko uporabljajo pri učenju in poučevanju. V ospredju so tudi podatki, ki se skladiščijo v različnih sistemih upravljanja učenja (angl. Learning Management System), kot je na primer Moodle.¹ Tovrstni podatki se v določenih primerih tujih praks kombinirajo tudi s tradicionalnejšimi viri podatkov, kot so demografski podatki izobraževalcev ali akademski uspeh (Jordaan in Van der Merwe, 2015, str. 55).

Zgodovina učne analitike sega torej v zgodnja leta 2000, ko so institucije začele uporabljati sisteme za upravljanje učenja (LMS) za izvajanje spletnih tečajev. Sistemi LMS so zagotavljali infrastrukturo za zbiranje podatkov o interakcijah študentov s študijskim gradivom, nalogami in ocenami. Leta 2011 je bilo ustanovljeno Društvo za raziskovanje učne analitike (angl. Society for Learning Analytics Research – SoLAR), kar je pomenilo uveljavitev učne analitike kot samostojne raziskovalne discipline. SoLAR je olajšala sodelovanje in izmenjavo znanja med raziskovalci, pedagogi in tehnologi, ki jih zanima učna analitika. Sčasoma se je učna analitika v izobraževalnih ustanovah po vsem svetu vse bolj uveljavljala. Razpoložljivost velikih količin podatkov in napredek v tehnologijah podatkovne analitike sta še dodatno spodbudila razvoj tega področja (Siemens in Long, 2011, str. 31–33).

Učna analitika ima razmeroma kratko, a hitro razvijajočo se zgodovino. Kot izraz se je pojavila v začetku leta 2000 in se nanaša na proces zbiranja, analiziranja in poročanja podatkov o učencih in njihovih učnih okoljih za izboljšanje izobraževalnih rezultatov. V prvih letih se je učna analitika osredotočala predvsem na zajemanje in analiziranje podatkov, pridobljenih prek sistemov za upravljanje učenja in drugih

¹ *Sistemi za upravljanje učenja so programi, namenjeni pripravi, upravljanju in posredovanju študijskih gradiv študentom. Večina sistemov temelji na spletnih tehnologijah, kar omogoča dostopnost uporabnikom kadar koli in kjer koli. V različnih virih naletimo na več mogočih poimenovanj tovrstnih sistemov: spletne učilnice, e-učilnice, učna e-okolja, virtualna učna okolja. Na Ministrstvu za obrambo in v Slovenski vojski se uporablja centralno učno e-okolje Moodle, ki je bilo uvedeno na podlagi izvedenega ciljnega raziskovalnega projekta Sistemi e-izobraževanja in usposabljanja Slovenske vojske (SV) ter raziskave in možnosti uvedbe daljinskega izobraževanja (Ščavničar, 2014, str. 67–69).*

spletnih učnih platform. Ti sistemi so zagotavljali dragocen vpogled v vključenost, uspešnost in vedenje učencev, ki jih je bilo mogoče uporabiti za prilagajanje poučevanja in pomoč učencem pri uspehu. Z razvojem tehnologije in večjo dostopnostjo izobraževalnih podatkov pa se je učna analitika razširila izven meja podatkov LMS. Raziskovalci in praktiki so začeli preučevati podatke iz širšega nabora virov, vključno s platformami družbenih medijev, digitalnimi učbeniki, spletnimi forumi in celo nosljivimi napravami. Ta širši pristop je omogočil celovitejše profile učencev ter globlje razumevanje učnih vzorcev in preferenc. John P. Campbell, Peter B. DeBlois in Diana G. Oblinger (2007, str. 48–55) so izjavili: »Analitika združuje velike nabore podatkov, statistične tehnike in napovedno modeliranje. Lahko bi si ga predstavljali kot prakso pridobivanja institucionalnih podatkov za proizvodnjo občutljivih obveščevalnih podatkov.«

Koncept učne analitike se je torej uveljavil, ko je tehnologija napredovala in so izobraževalne ustanove začele uporabljati sisteme za upravljanje učenja in spletne učne platforme. Okrog leta 2010 se je začelo bolj poudarjeno pojavljati področje učne analitike. Institucije in raziskovalci so začeli razvijati okvire in modele za usmerjanje izvajanja pobud za učno analitiko. Osredotočili so se tudi na oblikovanje analitičnih orodij in tehnik za pridobivanje uporabnih vpogledov iz izobraževalnih podatkov. Z razvojem področja je učna analitika pritegnila pozornost različnih zainteresiranih strani, vključno z izobraževalci, oblikovalci politik in ponudniki tehnologije. Izobraževalne ustanove so prepoznale potencial učne analitike za izboljšanje vključenosti, dosežkov in zadrževanja učencev (MacLure, 2010, str. 277–279).²

1 VOJAŠKO IZOBRAŽEVANJE IN UČNA ANALITIKA V SLOVENSKI VOJSKI

Slovenska vojska je edini nosilec razvoja vojaškega znanja, vojaških ved in s tem vojaškega poklica. Vojaško izobraževanje in usposabljanje (VIU) je poleg zagotavljanja specifičnega in specialističnega strokovnega znanja ter usposobljenosti posameznikov za opravljanje nalog v Slovenski vojski (SV) namenjeno tudi razvoju vojske in izboljševanju njene pripravljenosti za uspešno delovanje v miru, vojni in v kriznih razmerah, za sodelovanje z mednarodnimi silami v okviru mirovnih operacij in za pomoč drugim državnim organom (Kladnik, 2017, str. 97–98).

Globalizacija, družbeni mediji, vedno večja računalniška moč in širjenje naprednih tehnologij so ustvarili raven svetovne zapletenosti in hitrih sprememb, kakršnih še ni bilo. Živimo v sodobni družbi, v kateri je informacijska tehnologija bistveni del našega življenja. Tako sodobna informacijsko-komunikacijska tehnologija (IKT) vpliva na sodobno izobraževanje. Z napredkom razvoja IKT se elektronsko izobraževanje postavlja kot nova paradigma sodobnega izobraževanja. Elektronsko

² Prva mednarodna konferenca o učni analitiki in znanju (angl. *Learning Analytics & Knowledge – LAK*) je bila izvedena v Kanadi leta 2011 (MacLure, 2010).

izobraževanje je prilagodljiv učni model, ki temelji na interaktivnem dostopu do znanja – učnih virov prek spleta (Horvat, 2021, str. 1).

Slovenska vojska ne zaostaja na področju izobraževanja in informatizacije, vendar pa mora nenehno iskati nove načine oziroma rešitve izobraževalnega procesa, ki bodo vključevale večje naložbe v človeško razsežnost. Natančneje, trdimo, da vojaško osebje potrebuje več kompetenc ter višjo raven veščin, kot sta kritično mišljenje in čustvena inteligenca. Tako oblikovano vojaško učno okolje bo ustvarjalo spretno in operativno sposobne posameznike, ekipe ter organizacijske strukture. S pomočjo projekta je Slovenska vojska med prvimi v Sloveniji uspešno vpeljala sistem e-izobraževanja v obliki Centra za elektronsko izobraževanje, ki je danes nepogrešljiva zmogljivost Slovenske vojske, saj jo pri svojem delu uporabljajo skoraj vsi pripadniki Slovenske vojske in Ministrstva za obrambo. Pripadnikom olajša zahtevano redno izobraževanje oziroma izobraževanje na delovnem mestu, organizaciji in državi pa prihrani marsikateri proračunski evro. Glede na to, da se v procesu vojaškega izobraževanja že uporablja sistem e-izobraževanja, je logična posledica uvedba učne analitike v vojaško izobraževalno institucijo (Center vojaških šol). Uvedba učne analitike ima predvsem praktični vidik, usmerjen v izboljšanje uspešnosti udeležencev vojaškega izobraževanja in prilagajanje učnega okolja potrebam posameznika. Posledično rezultati vplivajo na ustvarjanje koristnih predlogov za vodstvo Slovenske vojske in Center vojaških šol kot izobraževalne institucije, ki oblikuje programe vojaškega izobraževanja. Učna analitika v Slovenski vojski se v praksi uporablja v spletni učilnici Centra za e-izobraževanje (CEI), kjer so na voljo različne kategorije učnih vsebin za samostojno in kombinirano učenje. Tako v spletni učilnici CEI potekajo zbiranje podatkov, analiza in prikaz podatkov. Zaradi spremljanja uporabnikov in njihovega dela v spletni učilnici se pripravljajo poročila, kot je na primer izvedena analiza uporabe spletne učilnice CEI med epidemijo covid-19 ter analiza uporabne vrednosti omenjene spletne učilnice (Ščavničar, 2023, str. 49–53; Horvat, 2021, str. 62–76). Seveda pa se moramo zavedati, da je uporaba učne analitike v Slovenski vojski šele na začetku svoje uporabe in zato bi radi v nadaljevanju prikazali uporabnost oziroma (z)možnost učne analitike pri izvajanju izobraževalnega procesa v vojaškem izobraževalnem procesu Slovenske vojske.

Rezultati učne analitike so koristni predvsem za obe neposredno vključeni strani v procesu izobraževanja, in sicer za:

- uporabnike, ki imajo boljši nadzor nad izobraževanjem, izboljša pa se tudi samorefleksija;
- učitelje, ki lažje načrtujejo podporne intervencije za uporabnike in skupine, prav tako pa na podlagi učne analitike lažje spreminjajo pristope k poučevanju (Didakt. UM, 2020, str. 5).

2 RAČUNALNIŠKE METODE ZA ANALIZO UČENJA

Računalniške ali algoritmične metode analize podatkov so sestavni del učne analitike. Poleg empirične analize učnih interakcij v tehnološko bogatih okoljih so del analize tudi posebni računalniški in matematični pristopi. Računalniški pristopi, ki se uporabljajo v učni analitiki, kot je prikazano na sliki 1, vključujejo analitiko (Hoppe idr., 2017, str. 25):

1. omrežne strukture, vključno z omrežji akterjev in predmetov,
2. procese z uporabo metod analize zaporedja,
3. vsebine z uporabo rudarjenja po besedilu ali drugih tehnik računalniške analize predmetov.

Slika 1:
Trojica
metodoloških
pristopov
(Hoppe idr.,
2017)



Mrežno-analitične metode, zlasti analiza socialnih omrežij, se osredotočajo na odnose, pri čemer akterje obravnavajo kot vozlišča v omrežju, ki je predstavljeno kot grafična struktura. Primeri različnih vrst povezav so pripadnost, prijateljstvo, poklicna, vedenjska interakcija ali izmenjava informacij. Metode analize omrežij prepoznavajo akterje in njihovo pomembnost ter odkrivajo grozde, v katerih so akterji povezani gosteje od povprečja. Velik del analize omrežij v učni analitiki je osredotočen na boljše razumevanje družbenih vidikov študentske izkušnje in njihovega pomena za učenje in uspeh študentov (Fortunato, 2010, str. 81–83).

Računalniška analiza učenčevih (med)dejanj na podlagi dnevniških datotek sistema ima tradicijo v računalniško podprtem sodelovalnem učenju. Obstajajo tudi splošnejše tehnike, ki jih je mogoče prilagoditi in uporabiti, kot na primer forum za upravljanje razširljivih platform (Fournier-Viger idr., 2014, str. 3569). V kontekstu učne analitike se forum za upravljanje razširljivih platform uporablja v paketu orodij LeMo³ za analizo dejavnosti na spletnih učnih platformah (Elkina, Fortenbacher in Merceron, 2013, str. 227–228).

Za pridobivanje semantičnih informacij iz predmetov se uporabljajo tehnike informacijskega rudarjenja. To je še posebej zanimivo v primeru predmetov (artefaktov), ki jih ustvarijo učenci. Analiza omrežij in besedil (angl. Network–Text Analysis) je tehnika za pridobivanje omrežij pojmov, ki se pojavljajo v besedilih v naravnem jeziku in so povezani z določeno mero bližine. Izvleček teh omrežij pogosto zahteva veliko domenskega znanja analitika, da se vnaprej določijo ustrezni pojmi. Oblikujejo se lahko večkodne mreže, v katerih so razmerja med pojmi omejena na določene medkategorijske tipe, kot sta lokacija–oseba ali oseba–domena–pojem (Hoppe idr., 2013, str. 3).

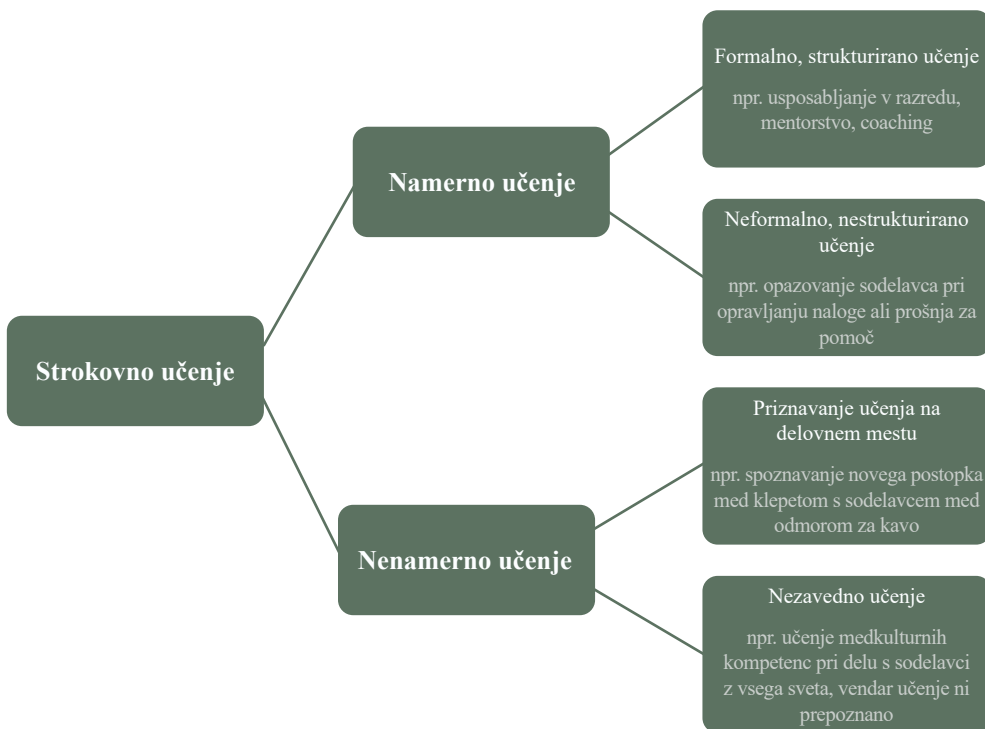
Eden glavnih ciljev izobraževanja je pomagati učencem, da razvijejo sposobnost učinkovitega učenja. Učenci morajo razviti več spretnosti, da lahko določijo cilje, spremljajo svoj napredek pri doseganju teh ciljev, popravijo izvedbo in ovrednotijo rezultat ter hkrati pridobijo sklepe za naslednjo izvedbo. Sami uravnavajo svoje učenje, dejavno raziskujejo, kaj počnejo in kako dobro so njihovi cilji doseženi z različnimi pristopi k učenju. Pomoč učencem, da razvijejo večšino za uravnavanje svojega učenja in učinkovito krmarjenje po vse bolj negotovih in protislovnih kanalih digitalnih informacij, je zelo pomembna za njihovo dolgoročno učenje, zlasti če upoštevamo, da vse več učencev preživi veliko časa v digitalnih okoljih, v katerih se samostojno učijo. Samoregulativno učenje vključuje štiri ohlapno zaporedne rekurzivne faze, ki potekajo v časovnem okviru priprave naloge oziroma časovnice. V prvi fazi učenec raziskuje vire in omejitve, ki bi lahko vplivali na delo,

³ Razvoj orodja za spremljanje učnega procesa (LeMo) je namenjen podpori učiteljem, raziskovalcem in ponudnikom e-učenja pri analizi podatkov o uporabi za njihove učne scenarije spletnega in mešanega učenja. LeMo omogoča ovrednotenje podatkov o prometu tako iz personaliziranih učnih platform, kot je na primer LMS Moodle. Orodje omogoča različne analize, kot so potek intenzivnosti aktivnosti skozi čas, povprečna uporaba ponudbe ob določenih urah v tednu, prepoznavanje skupnih poti, graf navigacije med različnimi učnimi objekti tečaja in pregled povprečnih rezultatov testa. Glavni poudarek pri razvoju orodja LeMo je prijaznost do uporabnika in dinamična vizualizacija rezultatov analize (Elkina, Fortenbacher in Merceron, 2013).

ter mogoče izide in posledice določenih dejanj. V drugi fazi učenec določi cilje in načrtuje, kako se jih bo lotil. V tretji fazi učenec začne delati nalogo, kar sčasoma ustvari povratne informacije in morebitne popravke. Faza štiri je faza, ko učenec ne sodeluje pri nalogi, spremlja rezultate ene ali več faz od 1 do 3 in se odloči za obsežno spremembo (Winne, 2011, str. 16–19).

Za podporo samoregulativnega učenja se učna analitika spoprijema z izzivom učinkovitega odkrivanja, kdaj se pojavljajo kritične faze tovrstnega učenja, ali se ustrezno razvijajo in kako »popraviti« učenca, če se ne. V ta namen bo morda treba vedenjske podatke, kot so kliki z miško, kombinirati z drugimi kazalniki (npr. uspešnost učencev pri kvizih) in jih zelo skrbno razlagati, da bodo uporabni za podporo samoregulativnega učenja. Bolj izpopolnjen pristop za odkrivanje vzorcev v učnem procesu je uporaba prilagodljivih učnih okolij. Ta okolja vključujejo vidike vedenja učencev z njihovimi odgovori na različna vprašanja in izzive, ki se pojavljajo med potjo skozi okolje. Takšni podatki se nato uporabijo za sprožitev intervencij za podporo samoregulativnega učenja. Poleg tega se lahko za ugotavljanje napredka učencev uporabljajo tudi afektivni kazalniki. Ti označevalci lahko s spremljanjem obraza ali psihofiziološkimi kazalniki določijo, kdaj je učenec zmeden ali frustriran. Na tem področju, imenovanem afektivno računalništvo in multimodalna učna analitika, se uporabljajo podobni označevalci za odkrivanje kazalnikov napredka učencev med učenjem. Primeri uporabe so prilagodljiva učna okolja, inteligentni tutorski sistemi in interaktivne simulacije. Učno analitiko je mogoče uporabiti kot podlago za zagotavljanje neposrednega posredovanja za pomoč učencem pri razvijanju samoregulativnega učenja v teh okoljih. Prav tako lahko podpira učitelje pri pomoči učencem pri izboljšanju njihove zmožnosti za samoregulativno učenje, saj jim zagotavlja podatke o tem, kako njihovi učenci napredujejo (Winne in Hadwin, 1998, str. 279–298). Strokovno učenje je ključni element stalnih izboljšav, inovacij in sprejemanja novih delovnih praks (Boud in Garrick, 1999, str. 2). Učenje za delo poteka v različnih oblikah, od formalnega usposabljanja do pogovorov s sodelavci in neformalnega učenja prek delovnih dejavnosti (Eraut, 2004, str. 247–248). V organizacijskih okoljih mora biti učenje usklajeno z organizacijskimi cilji. Usposabljanje ne velja za učinkovito, če se strokovnjaki naučijo novega procesa, nato pa naučenega ne uporabljajo, zato je pomembno, da se ljudem omogoči pridobivanje znanja, ko ga potrebujejo. To pomeni, da morajo biti strokovnjaki sposobni načrtovati in samoregulirati svoje učenje in razvoj ter spreminjati prioritete učenja glede na razvoj svojih delovnih nalog. Cilj učne analitike v strokovnih kontekstih je, da bi formalni in neformalni učni procesi postali sledljivi in bolj eksplicitni ter da bi vsakega strokovnjaka povezali z znanjem, ki ga potrebuje (Littlejohn, Milligan in Margaryan, 2012, str. 228–236).

Slika 2:
Tipologija
poklicnega
učenja po
Erautu (2000,
2004), v
Littlejohn, 2017



Zelo pomembno je, da so strokovnjaki sposobni samoregulirati svoje učenje. Prav tako mora biti učenje tesno povezano z delovnimi praksami, da se poveča njihova motivacija. Da bi to dosegli, so bili razviti različni pristopi, na primer:

- Pospeševanje učenja v pravem času

WEKIT (angl. Wearable Experience for Knowledge Intensive Training)⁴ uporablja pametno tehnologijo, da nezkušenim strokovnjakom omogoči dostop do podatkov, ko jih potrebujejo. Najprej se kartira razvoj neke spretnosti. Nato se razvijejo tehnološka orodja, nazadnje pa se navodila uporabniku posredujejo prek razširjenega vizualnega vmesnika.

⁴ *Wearable Experience for Knowledge Intensive Training (WEKIT) je ambiciozen evropski raziskovalni in inovacijski projekt, ki želi v treh letih razviti in preizkusiti nov način industrijskega usposabljanja, ki ga omogoča pametna nosljiva tehnologija. WEKIT bo zgradil revolucionarno industrijsko učno tehnološko platformo ter edinstveno metodologijo za zajemanje strokovnih izkušenj in njihovo deljenje. Tako bo WEKIT oživil učno vsebino in tehnično dokumentacijo prek razširjene resničnosti, prilagodne nalogam, s čimer bo industrijsko usposabljanje postalo učinkovitejše, cenovno dostopnejše in privlačnejše (Cordis EU research results, 2015).*

– Izkoriščanje organizacijskih omrežij

Učne plasti izkoriščajo omrežja in odnose na ravni posameznika, organizacije in med organizacijami za izboljšanje učinkovitosti. Drugi primer je odprta knjižnica za razvijalce, ki gosti orodja in kode, s katerimi lahko razvijalci delajo.

– Uporaba strokovnega znanja in izkušenj

Strokovnjak bi za dokončanje določene naloge uporabil kombinacijo orodij in virov. To kombinacijo orodij in virov je mogoče ponoviti in prilagoditi za podporo drugim strokovnjakom s podobnimi delovnimi in učnimi potrebami.

– Spodbujanje aktivnega učenja

LearnB in Mirror⁵ spodbujata strokovnjake k samoregulaciji učenja. Sistema prepoznata podobne učne cilje, kot jih imajo ljudje, in na podlagi učnih vzorcev drugih priporočata teme, ki bi lahko bile koristne (Littlejohn, 2017, str. 271–274).

Da bi v celoti izkoristili njen potencial, mora biti učna analitika del institucionalnih procesov in institucionalnih strategij za uspeh študentov. S pravilno uporabo praks učne analitike lahko spremenimo organizacijsko kulturo, zmogljivosti in kontekst, oblikujemo strategije za uspeh študentov ter izvajamo načrte upravljanja za uspeh študentov. Te prakse lahko bistveno pospešijo uspeh študentov na institucionalni ravni. Najpomembnejše sestavine transformativne moči učne analitike v institucionalnih sistemih vključujejo kombinacijo vodenja, aktivne strategije in upravljanja sprememb. Prakse učne analitike oblikujejo tudi novo generacijo akademske tehnološke infrastrukture. Vsak ponudnik sistemov za načrtovanje virov podjetja Enterprise Resource Planning⁶ (ERP) in sistemov za upravljanje učenja LMS⁷ vključuje analitiko v svoje izdelke in storitve (Little idr., 2015, str. 8).

⁵ MIRROR je raziskovalni projekt, katerega cilj je ustvariti boljše razumevanje o tem, kako ljudje (zunaj Evropske unije) dojemajo Evropo kot destinacijo za migracije. Projekt MIRROR je razdeljen na delovne pakete, da strukturira delo, ki ga je treba opraviti med izvajanjem, in omogoči več skupinam, da hkrati delajo na različnih komponentah v projektu. Razdeljen je na 12 delovnih paketov, ki vsebujejo skupino povezanih nalog (Horizon 2020 programme, 2020).

⁶ Načrtovanje virov podjetja (ERP) je platforma, ki jo podjetja uporabljajo za upravljanje in integracijo bistvenih delov svojega poslovanja. Številne aplikacije programske opreme ERP so pomembne za podjetja, saj jim pomagajo pri načrtovanju virov z integracijo vseh procesov, potrebnih za vodenje njihovih podjetij, z enim samim sistemom. Programski sistem ERP lahko združuje tudi načrtovanje, nabavo zalog, prodajo, trženje, finance, človeške vire itn. (Anderson 2023).

⁷ Danes je na trgu na voljo veliko učnih okolij, med najpogostejše omenjenimi so Blackboard, med prosto dostopnimi je zelo uveljavljen Moodle, pogosto se omenjajo še Dokeos, ATutor in Sakai. Izbira učnega okolja izhaja iz ciljev programa elektronskega izobraževanja, ki mora upoštevati značilnosti ciljnih skupin, za katere bo program potekal. Iz pedagoškega vidika je treba proučiti, ali učno okolje omogoča izpeljavo predvidenih učnih dejavnosti, s katerimi bomo dosegli načrtovane cilje. Za učna okolja, ki se uporabljajo v komercialne namene, je treba proizvajalcu plačevati določeno licenčnino. Za uporabo odprtokodnih učnih okolij ni treba plačevati licenčnim proizvajalcem in so na internetu s prostim dostopom (Bregar idr., 2010).

Slika 3 prikazuje poenostavljen model procesa uspešnosti študentov, ki ga je oblikovala delovna skupina ECAR-Analytics⁸ in ki napovedni učni analitiki namenja osrednje mesto v procesu učenja študentov. Učna analitika je zelo pomembna za institucionalno ukrepanje (intervencijo). Brez institucionalnega posredovanja bi bila učna analitika le poročanje, brez ustrezne učne analitike pa bi institucionalni posegi temeljili na instinktih in prepričanjih. Institucionalna kulturna sprememba je prva razsežnost, ki je bistvena za omogočanje intervencij, ki temeljijo na učni analitiki, torej za odločanje, ki temelji na učni analitiki. Institucionalni sistemi se morajo spremeniti iz kulture poročanja o učni analizi brez ukrepanja v kulturo ukrepanja, ki temelji na učni analizi (Little idr., 2015, str. 3–7).

Slika 3:
Pomen spremembe organizacijske kulture in napovedne učne analitike na poti do uspeha študentov (Little idr., 2015)



3 METODE IN PREDNOSTI ČUSTVENE UČNE ANALITIKE

Čustva so dvoumna in dinamična, zato je brez inovacij na področju učne analitike in podatkovnega rudarjenja v izobraževanju taka čustva težko napovedati (D'Mello, 2017, str. 115). Čustva so konceptualne entitete, ki izhajajo iz interakcij možgani-telo-okolje, vendar jih ni mogoče najti z iskanjem v možganih, telesu ali okolju. Namesto tega se čustva pojavijo, ko interakcije organizem-okolje sprožijo spremembe na več časovnih skalah in na več ravneh – nevrobiološki, fiziološki, kognitivni, metakognitivni itn. »Akademska čustva« so na primer razvrščena v štiri kategorije. Čustva uspešnosti (zadovoljstvo, tesnoba in frustracija) so povezana z učnimi dejavnostmi (domača naloga, opravljanje testa) in rezultati (uspeh, neuspeh) (Lewis, 2005, str. 173).

⁸ Delovna skupina ECAR-Analytics je bila ustanovljena na univerzi v Bostonu in želi razviti standardiziran podatkovni model analitike učenja, ki obdaja hitro rastoče izobraževalne podatke. Leta 2020 so začeli razvijati samodejni pretok podatkov od tretjih ponudnikov do skladišča podatkov in do nadzorne plošče za analizo učenja (Little idr., 2015).

Tematska čustva so povezana z učno vsebino (empatija do glavnega junaka med branjem klasične literature). Socialna čustva, kot so ponos, sram in ljubosumje, se pojavljajo, ker je izobraževanje umeščeno v družbene okvire. Epistemična čustva izhajajo iz kognitivne obdelave, kot je presenečenje ob novosti ali zmeda ob brezizhodni situaciji. Epistemična čustva imajo pri spletnem učenju zaradi pomanjkanja povratne zanke v realnem času kompleksen vpliv. Ta čustva so lahko pozitivna (presenečenje, užitek) ali negativna (razočaranje, dolgčas), lahko pa so tudi dvojna (zmeda). Ključno postane pravočasno in natančno zaznavanje takih čustev, preden negativno vplivajo na učenca (D'Mello, 2017, str. 115).

Analitika čustvenega učenja uporablja štiri temeljne teme:

- Analiza vpliva iz podatkov o klikih je ena izmed najosnovnejših uporab tehnik učne analitike oziroma podatkovnega rudarjenja v izobraževanju. Za razumevanje kognitivnih procesov učencev uporablja pester tok podatkov, ki nastaja med interakcijami z učnimi tehnologijami. Dopolnilni niz vpogledov je mogoče zbrati, če je vpliv vključen v učne dejavnosti (branje besedila, preizkušanje kode, sprejemanje napak, prikazovanje namigov itn.) (Corbett in Anderson, 1995, str. 116; Sinha idr., 2014, str. 3).
- Zaznavanje vpliva iz vzorcev interakcije bi moralo biti mogoče s primerjavo konteksta učne ure in dejanj učenca. To področje dela, ki se imenuje »interakcijsko« ali »dnevniško datotečno« zaznavanje afektov, se je začelo pred več kot desetletjem (D'Mello idr., 2006, str. 3–5).
- Pri zaznavanju vpliva iz telesnih signalov se za sklepanje o vplivu učenca uporabljajo gibi telesa in značilnosti obraza (Ibid).
- Vključevanje modelov afekta v učne tehnologije, ki se zavedajo afekta, uporablja detektorje afekta, ki temeljijo na interakciji in telesu, da se zagotovi ocenjevanje afekta učencev z učno tehnologijo v realnem času. Cilj takih učnih tehnologij, ki se zavedajo vpliva, je razširiti pasovno širino prilagodljivosti sedanjih učnih tehnologij z odzivanjem na to, kar učenci čutijo, poleg tega, kar mislijo in delajo (D'Mello idr., 2014, str. 36). Eden teh sistemov je Affective AutoTutor (D'Mello in Graesser, 2012, str. 1–3).

V zadnjem času se pojavljajo naslednje teme analitike čustvenega učenja:

- Prediktorji osipa in prekinitve izobraževanja, ki temeljijo na čustvih, so zgodnji pokazatelj tveganja za prekinitve izobraževanja in sistem za zgodnje preprečevanje oziroma intervencijo prekinitve izobraževanja. Velja za »ubijalsko aplikacijo« učne analitike in podatkovnega rudarjenja v izobraževanju (Jayaprakash idr., 2014, str. 9).
- Analiza razpoloženja na forumih temelji na dejstvu, da jezik sporoča čustva. Zato imajo tehnike analize čustev in rudarjenja mnenj velik potencial za preučevanje, kako misli študentov o učni izkušnji napovedujejo ustrezno vedenje (predvsem osip) (Pang in Lee, 2008, str. 53–54).

- Analitika učenja v razredu samodejno modelira vidike izkušenj učencev v razredu, ki jih je bilo prej mogoče pridobiti le s človeškim opazovanjem. Ti sistemi lahko zaznajo gibanje oči in ust ter tako sklepajo o pozornosti učencev (Pang in Lee, 2008, str. 54).
- Učiteljska analitika zagotavlja metode za samodejno analizo učnih praks učiteljev (Ibid).

Glede na pomen čustev pri učenju bodo poskusi analiziranja (ali pridobivanja podatkov) učenja brez upoštevanja čustev nepopolni. Analitične metode LA in podatkovnega rudarjenja v izobraževanju, usmerjene v odkrivanje, ki temeljijo na podatkih, imajo skupaj s poudarkom na zbiranju podatkov iz resničnega sveta veliko možnosti za napredek tako znanosti o učenju kot znanosti o čustvih. Vse se začne z vključitvijo čustev v analizo učenja (Ibid).

Uspeh učenja na lokalni ravni je odvisen od raznovrstnosti virov in količine podatkov, ki jih je mogoče zbrati o učnih dejavnostih. V idealnem primeru bi moralo učenje potekati v digitalnem okolju z uporabo različnih digitalnih orodij. Ta digitalna orodja vključujejo sisteme za upravljanje učenja, inteligentne tutorske sisteme, množične odprte spletne tečaje, izobraževalne videoigre ali druge vrste sistemov, ki uporabljajo računalnik kot aktivni del učnega procesa. Po drugi strani pa v okoljih, v katerih računalniki niso prisotni, kot so predavanja iz oči v oči, dejanja učencev niso zajeta, modelov in orodij učne analitike pa ni mogoče uporabiti (Ibid).

4 IZZIVI IN NAJBOLJŠE PRAKSE

Izmenjava podatkovnih nizov med različnimi zainteresiranimi stranmi ni dovolj; nekatera raziskovalna dela zahtevajo obsežno obdelavo, saj je v teh korakih mogoče sprejeti več odločitev, ki jih je morda težko jasno opredeliti. Druga skupina strokovnjakov iz učne analitike, ki poskuša pripraviti nabor podatkov po istih pravilih, zato morda ne bo prišla do enakih zaključkov. Na to lahko vpliva tudi narava programske opreme, ki se uporablja pri obdelavi. Izvajanje ključnih metod se lahko pri uporabi različnih orodij razlikuje, kar lahko privede tudi do različnih zaključkov. Drugi sporni vidik je apriorna predpostavka ali »osnovna resnica«, na kateri temelji statistični model. Številni statistični testi so lahko pomembni, vendar njihovi rezultati niso točni. Poudariti je treba pomen raziskovalne celovitosti, saj je pri analitiki učenja in rudarjenja podatkov v izobraževanju včasih zanimivo zainteresiranim stranem zagotoviti »ustrezne« rezultate (Kop, Fournier in Durand, 2017, str. 320–321; Baker in Inventado, 2016, str. 86–89).

Sedanje tehnološko bogato učno okolje vključuje globalne omrežne komunikacije, ki vključujejo reflektivno pripovedovanje in bogato slikovno gradivo, kar postavlja raziskovalce pred izziv, da na novo izumijo svoje raziskovalne metodologije. Analiziranje spreminjajočih se zbirk besed in podob na družbenih omrežjih, ki so zdaj del učnega okolja, bi lahko bolj prodrlo v bistvo učnega procesa kot uradne evalvacije tečajev. Pri tako hitrem ravnanju s tako veliko količino podatkov in informacij

morajo raziskovalci predvideti najboljše mogoče postopke ter tehnike za prevajanje podatkov v razumljive, da bi bili rezultati uporabni za tiste, ki se izobražujejo, in za izobraževalce ter vodje ustanov. Sposobnost učinkovitega sporočanja zapletenih zamisli je pomembna pri ustvarjanju nečesa, kar bo imelo vrednost in bo preneslo ugotovitve raziskav v prakso (Boyd in Crawford, 2012, str. 664–665; Kop, Fournier in Durand, 2017, str. 321).

Glede uporabe in analize osebnih podatkov bi lahko šest elementov predstavljalo podlago za učno analitiko, osredotočeno na študente, in zmanjšalo skrb študentov za zasebnost (Prinsloo in Slade, 2016, str. 170–171):

1. Uporaba zbirnih, neosebni podatkov je bistvena za zagotavljanje učinkovitega in ustreznega poučevanja in učenja, vendar morajo imeti učenci možnost, da se informirano odločajo o izbiri oziroma odjavi.
2. Učenci morajo biti seznanjeni s tem, kateri podatki se zbirajo in kako se uporabljajo.
3. Študenti morajo poskrbeti, da so njihove evidence osebnih podatkov popolne in posodobljene.
4. Nadzor dejavnosti in zbiranje podatkov ne smeta škodovati napredku učencev.
5. Algoritmčne rezultate mora pregledati človek in jih, če je treba, popraviti.
6. Učna analitika zagotavlja kontekstno in časovno specifične, začasne in nepopolne slike učencev, algoritme pa je treba pogosto preverjati in potrjevati.

Močno vodstvo, ki podpira učno analitiko, je prav tako zelo pomembno za uspešno izvajanje učne analitike. Vodje organizacije morajo podpirati odločanje na podlagi podatkov, zagotavljati strateško vizijo in prepoznati v organizaciji akademske izzive, ki jih je mogoče obravnavati z uporabo veljavnih podatkov s pomočjo učne analitike (Arroway idr., 2016, str. 37–38; Bichsel, 2012, str. 6).

Za učno analitiko so potrebni kakovostni podatkovni nizi, ki predstavljajo kompleksnost učenja. Pomembno je razumeti vrste podatkov, ki so na voljo v ustanovi, čistost, veljavnost in zanesljivost podatkov, kje so shranjeni in kako se do njih dostopa, ter lastništvo podatkov. Znane so nekatere omejitve podatkov učne analitike, ki naj bi poustvarila kompleksen učni proces, povezovanje razdelanih podatkovnih nizov med sistemi pa bi olajšalo oblikovanje analitike, ki bi bila bolj usmerjena k učencu (Arnold, Lonn in Pistilli, 2014, str. 166; Arroway idr., 2016, str. 15).

Univerze so birokratske organizacije z enotami in fakultetami, ki delujejo po sklopih. Ustvarjanje sprememb v tako razdrobljenem okolju z različnimi strukturami, politikami, kulturami in družbenimi normami je na splošno težko. Pristop od zgoraj navzdol ne deluje v razdrobljenih organizacijah, kot so visokošolske ustanove. Za izvajanje sprememb sta najpomembnejši tesno sodelovanje in usklajevanje v celotni organizaciji (Sorter, 2019, str. 39–40).

Sklep Učna analitika je široko področje, ki združuje analiziranje in razumevanje podatkov ter njihovo uporabo za izboljšanje izobraževanja in učenja. Zavedanje in razumevanje učne analitike sta ključni za njeno učinkovito uporabo tako v civilnih kot v vojaških izobraževalnih ustanovah. Pomembno je, da izobraževalci in drugi deležniki prepoznajo vrednost uporabe učne analitike v obliki izboljšanja izvajanja izobraževanja. Podatkovno rudarjenje in analitika imata velike možnosti razvoja v izobraževanju na daljavo. Tako kot pri mnogih področjih izobraževanja bo izobraževanje na daljavo izboljšano z vedno večjo količino podatkov. V prihodnosti bosta umetna inteligenca in strojno učenje omogočila vse boljše napredno analizo podatkov. Napredni algoritmi bodo sposobni še natančneje napovedovati učne potrebe posameznih izobraževalcev in drugih deležnikov, kar bo omogočalo še bolj prilagojeno učenje. Strinjam se z Elano Zeide (2017, str. 330), da bosta morala tako razvoj kot uporaba učne analitike v prihodnosti nameniti še večjo pozornost etičnim vprašanjem. Etična vprašanja bodo imela pomembno vlogo v prihodnji učni analitiki. Predvsem bo treba z vidika etike v učni analitiki odgovoriti na vprašanje varovanja zasebnosti podatkov vseh deležnikov. Študenti morajo imeti nadzor nad tem, kateri podatki se zbirajo in kako se uporabljajo. To vključuje zagotavljanje informacij o zbiranju podatkov, varnosti podatkov in privolitvi. Prav tako je treba pri analizi podatkov zagotoviti, da ni oziroma ne bo diskriminacije ali pristranskosti. Algoritmi in analize ne smejo škoditi določeni skupini študentov ali posameznikom. Uporabniki, vključno s študenti in učitelji, morajo razumeti, kako se zbirajo, obdelujejo in uporabljajo njihovi podatki. Transparentnost je torej ključna za vzpostavitev zaupanja. Zaščita podatkov pred nepooblaščenim dostopom ali zlorabo je nujna, kar vključuje varnostne ukrepe, kot sta šifriranje in redno posodabljanje varnostnih sistemov. Dolžnost obveščanja je prav tako pomemben element zaupanja v učno analitiko. Ob odkritju varnostne kršitve ali zlorabe podatkov morajo izobraževalne ustanove in ponudniki učne analitike obvestiti vse prizadete strani. Študenti morajo imeti možnost dostopa do svojih podatkov in jih uporabiti za izboljšanje učenja. Uporabnike, tudi učitelje in administratorje, bi bilo treba izobraževati o etičnih vprašanjih, povezanih z učno analitiko, da bi lahko sprejeli odgovorne odločitve. Ker je poznano že precejšnje število sistemov za upravljanje učenja, ki vključujejo orodja za učno analitiko, mora uspešen razvoj učne analitike temeljiti na nadaljnjem upoštevanju etičnih smernic in načel, kar bo omogočilo, da učna analitika ostane orodje za izboljšanje izobraževanja, hkrati pa varuje pravice, zasebnost in dostojanstvo vseh deležnikov ter ohranja zaupanje v izobraževalne ustanove in tehnologije.

Literatura

1. Anderson, S., 2023. *Enterprise Resource Planning (ERP): Meaning, Components, and Examples*. New York: Investopedia. <https://www.investopedia.com/terms/e/erp.asp>, 10. 9. 2023.
2. Arnold, K. E., Lonn, S., Pistilli, M. D., 2014. *An Exercise in Institutional Reflection: The Learning Analytics Readiness Instrument (LARI)*. V *Proceedings of the 4th International Conference on Learning Analytics and Knowledge*. New York: ACM. Str. 163–169.
3. Arroway, P., Morgan, G., O'Keefe, M., Yanosky, R., 2016. *Learning Analytics in Higher Education*. Louisville: Educause Center for Analysis and Research.
4. Baker, S., in Inventado, P. S., 2016. *Educational data mining and learning analytics: Potentials and possibilities for online education*. V Veletsianos (ur.), *Emergence and Innovation in Digital Learning*. Edmonton: AU Press, Athabasca University. Str. 83–98.
5. Bichsel, J., 2012. *Analytics in higher education: Benefits, barriers, progress, and recommendations*. V *Research report*. Louisville: Educause Center for Analysis and Research – ECAR.
6. Boud, D., in Garrick, J., 1999. *Understandings of Workplace Learning*. V Boud, Garrick (ur.), *Understanding Learning at Work*. London: Routledge. Str. 1–11.
7. Boyd, D., in Crawford, K., 2012. *Critical Questions for Big Data: Provocations for a Cultural, Technological, and Scholarly Phenomenon*. V *Information, Communication & Society*. London: Routledge. 15–5, str. 662–679.
8. Bregar, L., in dr., 2010. *Osnova e-izobraževanja*. Ljubljana: Andragoški center Slovenije.
9. Campbell, J. P., DeBloist, P. B., Oblinger, D. G., 2007. *Academic Analytics: A New Tool for a New Era*. Boulder: Educause review. 42–4, str. 40–57.
10. Corbett, A., in Anderson, J., 1995. *Knowledge tracing: Modeling the acquisition of procedural knowledge*. V *User Modeling and User-Adapted Interaction*. Dordrecht: Kluwer Academic Publishers. 4–4, str. 253–278.
11. Cordis EU research results, 2015. *Wearable Experience for Knowledge Intensive Training*. Brussels: EU Commission. <https://cordis.europa.eu/project/id/687669>, 4. 9. 2023.
12. D'Mello, S. K., 2017. *Emotional Learning Analytics*. V Lang, Siemens, Wise, Gasevic (ur.), *Handbook of Learning Analytics*. Society for Learning Analytics Research. New York: Teacher College, Columbia University. Str. 115–127.
13. D'Mello, S. K., Blanchard, N., Baker, R., Ocumpaugh, J., Brawner, K., 2014. *I feel your pain: A selective review of affect-sensitive instructional strategies*. V Sottolare, Graesser, Hu, Goldberg (ur.), *Design recommendations for adaptive intelligent tutoring systems: Adaptive instructional strategies*. Orlando: US Army Research Laboratory. 2, str. 35–48.
14. D'Mello, S. K., Craig, S., Sullins, J., Graesser, A., 2006. *Predicting affective states expressed through an emotealoud procedure from AutoTutor's mixed-initiative dialogue*. V *International Journal of Artificial Intelligence in Education*. New York: Springer ZDA. 16–1, str. 3–28.
15. D'Mello, S., Graesser, A., 2012. *AutoTutor and Affective AutoTutor: Learning by talking with cognitively and emotionally intelligent computers that talk back*. V *ACM Transactions on Interactive Intelligent Systems*. New York: Association for Computing Machinery. 23, 2–4, str. 1–38.
16. Didakt. UM., 2020. *Učna analitika: strokovna podlaga*. Maribor: Univerza v Mariboru.
17. Elkina, M., Fortenbacher, A., Merceron, A., 2013. *Learning Analytics und Visualisierung mit dem LeMo-Tool – Rationals and first results*. *International Journal of Computing*. 12–3, str. 226–234.
18. Eraut, M., 2000. *Non-formal learning and tacit knowledge in professional work*. *British Journal of Educational Psychology*. Hoboken: Wiley-Blackwell. 70–1, str. 113–137.
19. Eraut, M., 2004. *Informal learning in the workplace*. *Studies in Continuing Education*. Brighton: University of Sussex. 26–2, str. 247–273.

20. Fortunato, S., 2010. *Community detection in graphs*. Kidlington: *Physics Reports* 486. 3–5, str. 75–174.
21. Fournier-Viger, P., Gomariz, A., Gueniche, T., Soltani, A., Wu, C. W., Tseng, V. S., 2014. *SPMF: A Java Open-Source Pattern Mining Library*. *Journal of Machine Learning Research*. 15–1, str. 3389–3393.
22. Hoppe, H. U., Erkens, M., Clough, G., Daems, O. & Adams, A., 2013. *Using Network Text Analysis to characterise teachers' and students' conceptualisations in science domains*. V *Vatrapu, Reimann, Halb, Sull (ur.), Proceedings of the 2nd International Workshop on Teaching Analytics (IWTA 2013)*. Milton Keynes: *The Open University, Institute of Educational Technology*.
23. *Horizon 2020 programme, 2020. Migration-Related Risks Caused by Misconceptions of Opportunities and Requirement*. Brussels: *EU Commission*. <https://h2020mirror.eu/>, 14. 9. 2023.
24. Horvat, K., 2021. *Elektronsko izobraževanje v Ministrstvu za obrambo kot primer dobre prakse*. Kranj: *Nova univerza, Fakulteta za državne in evropske študije*.
25. Jayaprakash, S. M., Moody, E. W., Lauría, E. J. M., Regan, J. R., Baron J. D., 2014. *Early Alert of Academically At-Risk Students: An Open Source Analytics Initiative*. V *Journal of Learning Analytics*. Beaumont: *Society for Learning Analytics Research (SoLAR)*. 1–1, str. 6–47.
26. Jordaan, D., in *Van der Merwe, A., 2015. Best practices for learning analytics initiatives in higher education. Moving beyond the hype: A contextualised view of learning with technology in higher education*. Pretoria: *Universities South Africa*.
27. Kladnik, T., 2017. *Vojaško izobraževanje v Slovenski vojski – izzivi prihodnosti*. V *Brožič (ur.), Sodobni vojaški izzivi*. Ljubljana: *MORS*. 19-1, str. 95–113.
28. Kop, R., Fournier, H., Durand, G., 2017. *A Critical Perspective on Learning Analytics and Educational Data Mining*. V *Lang, Siemens, Wise, Gasevic (ur.), Handbook of Learning Analytics*. Society for Learning Analytics Research. New York: *Teacher College, Columbia University*. Str. 319–326.
29. Lewis, M. D., 2005. *Bridging emotion theory and neurobiology through dynamic systems modeling*. V *Behavioral and Brain Sciences*. Cambridge: *Cambridge University Press*. 28–2, str. 169–245.
30. Little, R., in *sod., 2015. The Predictive Learning Analytics Revolution: Leveraging Learning Data for Student Success*. *Ecar-Analytics Working Group*. Louisville: *Educause Center for Analysis and Research – ECAR*.
31. Littlejohn, A., 2017. *Learning and Work: Professional Learning Analytics*. V *Lang, Siemens, Wise, Gasevic (ur.), Handbook of Learning Analytics*. Society for Learning Analytics Research. New York: *Teacher College, Columbia University*. Str. 269–277.
32. Littlejohn, A., Milligan, C., Margaryan, A., 2012. *Charting collective knowledge: Supporting self-regulated learning in the workplace*. *Journal of Workplace Learning*. Bingley: *Emerald Publishing Limited*. 24–3, str. 226–238.
33. MacLure, M., 2010. *The offence of theory*. V *Journal of Education Policy*. Amsterdam: *Elsevier*. 25–2, str. 277–286.
34. Pang, B., in *Lee, L., 2008. Opinion mining and sentiment analysis*. V *Foundations and Trends in Information Retrieval*. Boston: *Publicers*. 2 (1–2), str. 1–135.
35. Prinsloo, P., in *Slade, S., 2016. Student Vulnerability, Agency and Learning Analytics: An Exploration*. V *Journal of Learning Analytics*. Beaumont: *Society for Learning Analytics Research (SoLAR)*. 3–1, str. 159–182.
36. Siemens, G., in *Long, P., 2011. Penetrating the fog: Analytics in learning and education*. Boulder: *Educause review*. 46–5, str. 30–40.
37. Sinha, T., Jermann, P., Li, N., Dillenbourg, P., 2014. *Your click decides your fate: Inferring information processing and attrition behavior from MOOC video clickstream interac-*

- tions. *V Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Doha: Association for Computational Linguistics. Str. 3–14.
38. Sorter, H., 2019. *Best Practices for Learning Analytics Implementations in Higher Education*. *V McFall (ur.), Capstone Report*. Eugene: The University of Oregon.
39. Ščavničar, D., 2014. *E-learning in the Slovenian Armed Forces – from its first steps to its wider use*. *V Security and Defence Quarterly Central European Forum on Military Education*. Warsaw: War Studies University Warsaw. 4, str. 67–74.
40. Ščavničar, D., 2023. *Streamlining the delivery of military education through the distance learning method*. *V Čutić (ur.), Strategos*. Zagreb: Dr. Franjo Tuđman Croatian Defence Academy. VII-1, str. 33–69.
41. Winne, P. H., 2011. *A Cognitive and Metacognitive Analysis of the Self-Regulated Learning*. *V Zimmerman, Schunk (ur.), Handbook of Self-Regulation of Learning and Performance*. New York, London: Routledge. Str. 15–33.
42. Winne, P. H., in Hadwin, A., 1998. *Studying as Self-Regulated Learning*. *V Hacker, Dunlosky (ur.), Metacognition in Educational Theory and Practice* Hillsdale. New York: Lawrence Erlbaum. Str. 277–304.
43. Zeide, E., 2017., *Unpacking Student Privacy*. *V Lang, Siemens, Wise, Gasevic (ur.), Handbook of Learning Analytics*. Society for Learning Analytics Research. New York: Teacher College, Columbia University. Str. 327–333.

email: darko.scavnicar@mors.si

ORCID: 0009-0003-9740-0368

e-mail: darko.scavnicar@mors.si

Doc. dr. Darko Ščavničar je načelnik Visoke vojaške šole, dekan, ki deluje v okviru Centra vojaških šol Slovenske vojske, in docent na Fakulteti za organizacijske študije. Glede na poklicno okolje, v katerem deluje, v svojih strokovnih, znanstvenih in pedagoških delih obravnava tematiko, povezano z uporabo informacijsko-komunikacijskih tehnologij v izobraževalnem sistemu ter z razvojem vojaškega izobraževalnega sistema, še posebej z razvojem konceptov izobraževanja častnikov ter metodologijo vojaških ved.

Darko Ščavničar, PhD, is the Head of the National Military College, Dean within the Slovenian Armed Forces Military Schools Centre and Assistant Professor at the Faculty of Organisational Studies. In line with his professional environment, his professional, scientific and pedagogical works deal with topics related to the use of information and communication technologies in the education system and the development of the military education system, in particular the development of concepts of officer education and the methodology of military sciences.

ORCID: 0009-0003-9740-0368

* Prispevki, objavljeni v Sodobnih vojaških izzivih, niso uradno stališče Slovenske vojske niti organov, iz katerih so avtorji prispevkov.

* Articles published in the Contemporary Military Challenges do not reflect the official viewpoint of the Slovenian Armed Forces nor the bodies in which the authors of articles are employed.