

**Јелена М. Јовановић<sup>1</sup>**

Универзитет у Београду, Факултет организационих наука, Београд

## **ВЕШТАЧКА ИНТЕЛИГЕНЦИЈА У ОБРАЗОВАЊУ ИЗ ПЕРСПЕКТИВЕ АНАЛИТИКА УЧЕЊА<sup>2</sup>**

### **Апстракт**

Широка примена дигиталних система и алата у образовању је омогућила прикупљање и анализу података о интеракцијама ученика и наставника са различитим материјалима и активностима учења, а са крајњим циљем бољег разумевања учења и унапређења како исхода, тако и целокупног искуства учења. Управо ове могућности и циљеви су мотивисали развој истраживачке области аналитика учења, као и коришћење увида изведених из података за доношење одлука у различитим контекстима учења. Иако су аналитике учења дале значајан допринос бољем разумевању учења и окружења у којима се оно одвија, многа отворена питања и изазови и даље остају. Штавише, нове могућности и изазови настављају да се појављују са континуираним променама модалитета наставе и учења, од којих су најновије повезане са брзим развојем и доступношћу вештачке интелигенције, посебно генеративне вештачке интелигенције. Узимајући циклични модел аналитика учења као аналитички оквир, овај рад разматра интеракцију између аналитика учења и вештачке интелигенције кроз призму четири

<sup>1</sup> jelena.jovanovic@fon.bg.ac.rs

<sup>2</sup> Овај рад је делимично заснован на предавању под називом „Вештачка интелигенција и Аналитике учења: могућности и изазови”, одржаном у САНУ, 7. новембра 2023. године. Такође је делимично заснован на предавању по позиву под називом „Learning analytics: Challenges and opportunities opened by AI” припремљеном за конференцију *19th Conference on Computer Science and Intelligence Systems (FedCSIS 2024)*, септембар 2024, Београд.

кључне компоненте овог модела: ученици, подаци, методе и акције. У циљу емпиријски поткрепљене анализе, рад се ослања на најновија емпиријска истраживања у области аналитика учења и сродних области које се баве применом вештачке интелигенције у образовању.

**Кључне речи:** аналитике учења, вештачка интелигенција, генеративна вештачка интелигенција, учење, образовање

## 1. Увод

Образовање је већ више деценија у процесу континуиране дигиталне трансформације, условљене новим технологијама које налазе примену у настави и учењу. Различити онлајн (*online*) модалитети и комбиноване наставе су све доступнији, а велики број софтверских алата и „геџета” (*gadgets*) сада је уобичајен у учионицама. Осим директних промена у начину реализације образовања, ове технолошке иновације остварују и имплицитан утицај тиме што омогућавају једноставно прикупљање података о интеракцији ученика са различитим активностима учења, материјалима за учење и другим учесницима у образовном процесу. Ово обиље података је омогућило развој различитих аналитичких, рачунарски заснованих приступа за разумевање учења и унапређење како исхода учења, тако и целокупног образовног искуства. Разноликост развијених приступа је велика и креће се од потпуно аутоматизованих приступа који имају за циљ да, кроз одговарајућа софтверска решења, персонализују учење према потребама и преференцијама појединачних ученика, до приступа оријентисаних на пружање релевантних информација ученицима, оснажујући их тиме да преузму иницијативу и сами прилагоде своје циљеве и стратегије учења. Фокус овог рада је на приступима из овог спектра који наглашавају иницијативу и активност (*agency*) ученика и наставника, као и њихово ангажовање на прилагођавању процеса учења на основу увида остварених кроз податке и аналитике. Овакви приступи су својствени области аналитика учења.

Интензивни развој области вештачке интелигенције (ВИ) (*Artificial Intelligence*), као и широка доступност софтверских система и алата заснованих на технологијама ВИ-ја, отворили су не само нове могућности, већ и изазове у домену образовања.<sup>3</sup> Ту се посебно истиче генеративна вештачка интелигенција (ГВИ) (*Generative Artificial*

---

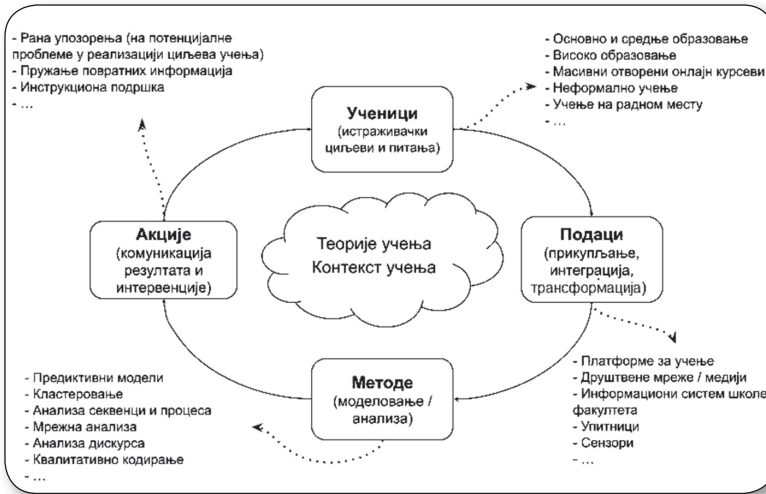
<sup>3</sup> Michail Giannakos et al., “The Promise and Challenges of Generative AI in Education”, *Behaviour & Information Technology* (2024), in press.

*Intelligence*), тренутно најактуелнија област ВИ-ја, за коју се сматра да поседује велики потенцијал да значајно утиче и (пре)обликује начин на који су образовне структуре и процеси уређени и како функционишу у пракси. Како би се адекватно и правовремено одговорило на могућности и изазове које технологије ГВИ-ја доносе, потребно је стећи увид у стварну примену тих технологија у образовању и систематично испитати њихову улогу и ефекте.

Област аналитика учења (*Learning Analytics*), са својим добро развијеним приступима за проучавање учења на основу података прикупљених из образовне праксе, представља истраживачку и практичну област која је вероватно најбоље позиционирана за систематско истраживање и разумевање предности и недостатака укључивања технологија ВИ-ја у образовање. С друге стране, област аналитика учења се и сама даље развија и унапређује кроз интеграцију технологија ВИ-ја у своје методолошке приступе и процесе. Тако можемо говорити о врло интересантној динамици успостављеној између ове две области у којој не само да област аналитика учења омогућава сагледавање потенцијала и изазова примене ВИ-ја у образовању, већ се и сама мења у складу са могућностима и изазовима које ВИ отвара.

Узимајући у обзир постављени контекст, овај рад има два циља: да пружи иницијални увид у реалне могућности примене технологија ВИ-ја у образовању и да укаже на улогу коју у томе има интеракција аналитика учења и ВИ-ја. У складу са овим циљевима, рад прво даје кратак увод у аналитику учења, наглашавајући њену итеративну природу и кључне елементе. Затим, рад истражује интеракцију између аналитика учења и ВИ-ја, фокусирајући се на то како аналитика учења може побољшати наше разумевање улоге и утицаја ВИ-ја у образовању, као и како процес аналитика учења и његове кључне компоненте могу имати користи од ВИ-ја. Испитујући ову динамику, рад такође настоји да покаже како ВИ, а посебно ГВИ, могу оснажити аналитику учења да одржи корак са динамиком промена у сфери образовања и остане верна својој мисији разумевања и унапређења учења. У остваривању ових циљева, рад се ослања на објављена емпиријска истраживања у области аналитика учења, као и у блиско повезаним областима вештачке интелигенције у образовању (*Artificial Intelligence in Education – AIED*) и истраживања података у образовању (*Educational Data Mining – EDM*). Бирајући приступ заснован на доказима (*evidence-based approach*), овај рад одражава једно од основних начела области аналитика учења.

## 2. Аналитика учења



Слика 1. Циклични модел аналитика учења

Аналитику учења (АНУ) је, вероватно, најједноставније сагледати као цикличан процес<sup>4</sup> са четири кључне компоненте: ученици, подаци, методе, и акције (слика 1). Прецизније, циклус АНУ пролази кроз фазе (1) идентификације ученика и контекста у коме се учење одвија; (2) прикупљања релевантних података (о ученицима, процесу и контексту учења); (3) одабира и примене аналитичких метода прикладних за дате ученике, контекст учења и податке; и (4) акција, односно, деловања на основу увида остварених кроз аналитике, често кроз различите облике педагошких интервенција.

За разумевање овог цикличног модела, односно АНУ уопштено, потребно је истаћи да је један од основних циљева АНУ разумевање учења.<sup>5</sup> У складу са тим, фазе процеса АНУ које се односе на податке и методе су, пре свега, вођене циљем разумевања учења. То је нешто што разликује АНУ од сродних области као што су наука о подаци-

<sup>4</sup> Doug Clow, "The Learning Analytics Cycle: Closing the Loop Effectively", in *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge, LAK '12* (New York, NY, USA: Association for Computing Machinery, 2012), 134–138.

<sup>5</sup> Charles Lang et al., "What Is Learning Analytics?", in *The Handbook of Learning Analytics*, ed. Charles Lang et al., 2<sup>nd</sup> ed. (Vancouver, Canada: SoLAR, 2022), 8–18, <https://www.solaresearch.org/publications/hla-22/hla22-chapter1/>.

ма (*Data Science*) и машинско учење (*Machine Learning*), где је фокус на перформансама рачунарских модела. С обзиром да разумевање учења које се стиче кроз аналитике треба да послужи као основа за деловање (на пример, предузимање одговарајућих педагошких интервенција), развој модела у области АНУ је заснован на добро успостављеним педагошким теоријама и на добром познавању специфичности контекста учења.

Контекст учења је препознат као посебно важан у развоју модела и у интерпретацији резултата.<sup>6</sup> У АНУ, контекст учења се често описује као специфична комбинација унутрашњих и спољашњих чинилаца који могу утицати на учење.<sup>7</sup> Овде се ученик сматра референтном тачком, што значи да унутрашњи фактори обухватају све оно што чини ментално стање ученика, као што су емоционално стање, мотивација, претходно знање и когнитивно оптерећење. С друге стране, спољашњи фактори укључују све оно што може утицати на учење и спољашње је у односу на ученика, односно ученик нема директну контролу над тим (на пример, педагошки план курса, специфичан педагошки приступ наставника, распоред часова).

Да би се кроз аналитике формирале основе за адекватне педагошке интервенције, осим сагледавања и разумевања контекста учења, потребно је и да истраживачка питања и методе буду утемељени на добро успостављеним теоријама учења. Иако се АНУ ослања на различите теоријске приступе учењу, један од најзаступљенијих приступа је саморегулисано учење (*self-regulated learning*). Према овом теоријском приступу, ученик је агент – неко ко има могућност одлучивања и деловања – који, у процесу учења, најпре дефинише своје циљеве, а затим бира стратегије и тактике учења које ће те циљеве остварити, и док делује у правцу својих циљева, континуирано прати и евалуира свој напредак и на основу тога прилагођава своје стратегије и тактике.<sup>8</sup> Значајна улога АНУ је у томе да подржи ученика у свим фа-

<sup>6</sup> Dragan Gašević et al., “Learning Analytics Should Not Promote One Size Fits All: The Effects of Instructional Conditions in Predicting Academic Success”, *The Internet and Higher Education*, 28 (2016): 68–84; Jelena Jovanović et al., “Students Matter the Most in Learning Analytics: The Effects of Internal and Instructional Conditions in Predicting Academic Success,” *Computers & Education*, 172 (2021): 104251.

<sup>7</sup> Philip H. Winne, “Cognition and Metacognition within Self-Regulated Learning”, in *Handbook of Self-Regulation of Learning and Performance*, 2<sup>nd</sup> ed. (Routledge, 2017).

<sup>8</sup> Philip H. Winne and Allyson E. Hadwin, “Studying as Self-Regulated Learning”, in *Metacognition in Educational Theory and Practice* (Routledge, 1998).

зама процеса учења, пружајући увиде, препоруке и смернице до којих се дошло кроз аналитике.

Укратко, истраживање АНУ није вођено подацима (*data-driven*), као што је то често случај у сродним областима науке о подацима и машинског учења, већ користи податке на начин који је обликован одговарајућом теоријом учења и специфичностима контекста учења. Штавише, важност разумевања рачунарског модела и онога што се из њега може научити о процесу учења и/или ученицима је разлог зашто се АНУ често ослања на релативно једноставне моделе машинског учења чији се механизми идентификовања образаца у подацима могу релативно једноставно објаснити, док се сложени модели дубоког учења (*deep learning*) и даље ретко примењују.

С обзиром да ће циклични модел АНУ (слика 1) послужити као основа за разматрање интеракције АНУ и ГВИ-ја, потребно је најпре обезбедити основно разумевање самог модела. У том циљу, у наставку је дат сажет опис основних компоненти овог модела.

## 2.1. Ученици

Пошто су основни циљеви АНУ разумевање и оптимизација учења и окружења у којима се оно одвија,<sup>9</sup> сваки процес АНУ, без обзира да ли је истраживачки или практично оријентисан, почиње идентификацијом ученика и контекста учења који се проучава. Ово осигурава да су све наредне фазе процеса вођене циљем да се подржи и/или унапреди учење за дате ученике и дати контекст учења.<sup>10</sup> Аналитика учења се бави ученицима и учењем у различитим контекстима учења, од основног и средњег образовања, преко високошколског образовања, до учења на радном месту. Такође, истражује различите облике неформалног и полуформалног учења које је типично за целоживотно учење (*lifelong learning*). Различити модалитети учења су предмет истраживања, с тим што и даље доминирају они модалитети који укључују примену дигиталних технологија у учењу, с обзиром да њихова примена значајно поједностављује прикупљање података неопходних за аналитике.

<sup>9</sup> Видети фусноту број 2 изнад.

<sup>10</sup> Dragan Gašević, Shane Dawson, and George Siemens, "Let's Not Forget: Learning Analytics Are about Learning", *TechTrends*, 59, 1 (2014): 64–71.

## 2.2. Подаци

У контексту цикличног модела АНУ, компонента података се односи на прикупљање, интеграцију и трансформацију података који се директно или индиректно односе на процесе и исходе учења. Аналитика учења се ослања на податке из различитих и често вишеструких извора, међу којима су најчешћи платформе и алати за учење, као и платформе и алати опште намене који се могу користити за учење (на пример, онлајн друштвене мреже и друштвени медији); затим, информациони систем школе, односно, универзитета, у случају формалног образовања; различите врсте анкета, које се често примењују пре и/или после курса или процеса учења; сензори као што су уређаји за праћење погледа (*eye-tracking devices*), праћење позиције и кретања у простору (*postion and movement tracking*) и видео-снимци активности учења.<sup>11</sup> Коришћење различитих података, често на комбиновани начин, омогућава свеобухватан увид у процес учења. Штавише, комбиновање података из више извора доприноси веродостојности закључака изведених из података. Међутим, приступ вишеструким изворима података је и даље привилегија студија које се реализују у контролисаним условима. У природном окружењу учења, лог подаци и даље остају ако не једини, онда свакако доминантан извор података.

Трагови учења (*learning traces*) или лог подаци (*logged data*) су подаци о интеракцијама ученика са различитим (дигиталним) ресурсима за учење, (онлајн) активностима учења, као и другим ученицима и наставницима (на пример, комуникација у онлајн дискусионим форумима). Главна предност трагова учења у поређењу са подацима који се традиционално користе у истраживањима у домену образовања – на пример, анкете и протоколи засновани на размишљању наглас (*think-aloud protocols*) – јесте то што се трагови учења могу прикупљати неприметно током процеса учења, без додатног оптерећења за ученике и наставнике. Континуирано повећање броја и разноврсности софтверских платформи и алата који се користе у процесу учења, као и све веће усвајање онлајн и комбинованих модалитета учења у формалном и неформалном образовању, чине трагове учења све доступнијим. Овај растући тренд доступности трагова учења се позитивно одражава на релевантност и усвајање АНУ у пракси.

---

<sup>11</sup> Abdulkadir Palanci, Rabia Meryem Yilmaz, and Zeynep Turan, “Learning Analytics in Distance Education: A Systematic Review Study”, *Education and Information Technologies* (2024).

Осим трагова учења прикупљених у контексту онлајн и комбинованих модалитета учења, прикупљање података у вези са учењем у традиционалним учионицама и физичким просторима уопште, привлачи све више интересовања у области АНУ. Ово је омогућено све већом доступношћу сензора (на пример, камера, микрофона, сензора за праћење позиције и кретања) који омогућавају мерење и прикупљање података о интеракцији ученика са различитим физичким објектима који се користе у учењу, као и података о међусобним интеракцијама ученика и наставника у различитим ситуацијама, пре свега, колаборативног учења. Прикупљање и комбинована употреба података из више извора, као и напредне аналитике које такви подаци омогућавају, у фокусу су подобласти АНУ познате као мултимодалне аналитике учења (*Multimodal Learning Analytics*).<sup>12</sup>

### 2.3. Методе

Аналитике учења користе бројне и разноврсне квантитативне и квалитативне методе. Посебно су заступљене методе засноване на ВИ-ју, односно, прецизније, методе из домена машинског учења и обраде природног језика. Такве методе се користе за креирање предиктивних модела (на пример, предвиђање успеха студената у оквиру одређеног курса или студијског програма); за груписање ученика који су међусобно слични по неким битним карактеристикама везаним за учење (на пример, груписање на основу индикатора интеракције са материјалима учења и активностима у оквиру курса); за анализу дискурса (на пример, аналитика порука које се размењују онлајн комуникационим каналима).<sup>13</sup> Аналитика учења такође доста користи и различите врсте мрежних анализа. Рачунарска анализа друштвених мрежа (*Social Network Analysis*) и епистемичких мрежа (*Epistemic Network Analysis*) се користе за боље разумевање структуре и садржаја интеракција међу актерима у процесу учења,<sup>14</sup> док се анализа психолошких мрежа (*Psychological Network Analysis*) примењује за проучавање статичких и динамичких карактеристика

<sup>12</sup> Hamza Ouhachi, Daniel Spikol and Bahtijar Vogel, "Research Trends in Multimodal Learning Analytics: A Systematic Mapping Study", *Computers and Education: Artificial Intelligence*, 4 (2023): 100136.

<sup>13</sup> Winne, "Cognition and Metacognition within Self-Regulated Learning"; Winne and Hadwin, "Studying as Self-Regulated Learning".

<sup>14</sup> Bodong Chen and Oleksandra Poquet, "Networks in Learning Analytics: Where Theory, Methodology, and Practice Intersect", *Journal of Learning Analytics*, 9, 1 (2022): 1–12.



психолошког стања ученика.<sup>15</sup> Анализа секвенци и процеса, често комбинована са напредним статистичким моделима, примењује се за проучавање динамике процеса учења, посебно саморегулисаног учења.<sup>16</sup>

## 2.4. Акције

Компонента акција се односи на оптимизацију учења и окружења у коме се учење одвија, што је већ наведено као један од основних циљева АНУ.<sup>17</sup> Притом, важно је истаћи да термин оптимизација у овом контексту не подразумева аутоматско прилагођавање процеса учења одређеном ученику (на пример, аутоматизована персонализација учења), као што је случај у блиско повезаним областима вештачке интелигенције у образовању и истраживања података у образовању. У области АНУ, оптимизација значи да се резултати аналитике, као што су увиди у процес учења или препоруке, чине доступним ученицима, наставницима и/или другим релевантним актерима (*stakeholders*), и њима се препушта да одлуче како најбоље да поступи на основу добијених повратних информација (*feedback*). Деловање на основу повратних информација у случају старијих/зрелијих ученика може имати облик прилагођавања сопственог приступа учењу, у складу са примљеним информацијама и препорукама. У случају млађих ученика, повратне информације се обично упућују наставнику, да послуже као основа при избору педагошког приступа којим ће најбоље помоћи својим ученицима. Једноставно речено, за АНУ је важно укључити релевантне актере (ученике, наставнике, родитеље и друге) у процес прилагођавања и побољшања учења, што је принцип који се често назива „човек у центру” (*human-in-the-center*).

У складу са наведеним, акције засноване на аналитикама започињу преношењем увида стечених кроз аналитике релевантним актерима (ученицима, наставницима, координаторима програма и другим). Та комуникација се најчешће реализује преко такозваних АНУ контрол-

---

<sup>15</sup> Jelena Jovanovic et al., “Explaining Trace-Based Learner Profiles with Self-Reports: The Added Value of Psychological Networks”, *Journal of Computer Assisted Learning*, 40, 4 (2024): 1481–1499.

<sup>16</sup> Winne and Hadwin, “Studying as Self-Regulated Learning”; Jiahui Du, Khe Foon Hew, and Lejia Liu, “What Can Online Traces Tell Us about Students’ Self-Regulated Learning? A Systematic Review of Online Trace Data Analysis”, *Computers & Education*, 201 (2023): 104828.

<sup>17</sup> Видети фусноту број 2 изнад.

них табли (*learning analytics dashboards*),<sup>18</sup> односно софтверских алата који представљају резултате АНУ, најчешће у визуелном облику. У случају АНУ контролних табли намењених ученицима, циљ је омогућити и/или подстаћи рефлексивно размишљање о реализованим активностима и оствареним резултатима и тиме створити услове за саморегулацију учења. У случају АНУ контролних табли намењених наставницима, циљ је обезбедити информације за доношење одлука, односно предузимање адекватних педагошких интервенција. Међутим, континуирано присутан изазов је преношење увида АНУ на начин на који крајњи корисници, којима можда недостаје техничка стручност, могу исправно да их протумаче и реагују на њих.<sup>19</sup>

Овај циклични модел АНУ ће у следећем одељку послужити као оквир за сагледавање интеракције АНУ и ВИ-ја. Конкретно, ослањајући се на резултате недавно објављених емпиријских студија у области АНУ и сродним областима (вештачка интелигенција у образовању и истраживање података у образовању), сагледаћемо, кроз призму појединачних компоненти модела АНУ, релације успостављене између АНУ и ВИ-ја, а посебно између АНУ и ГВИ-ја.

### 3. Интеракција аналитика учења и вештачке интелигенције

Овај одељак разматра интеракцију АНУ и ВИ-ја из перспективе ученика, података, метода и акција, као основних чинилаца цикличног модела АНУ. За сваку компоненту биће представљена унапређења која су остварена применом ВИ-ја, као и то како је примена АНУ, посматрано из аспекта те компоненте, омогућила боље разумевање улоге и утицаја ВИ-ја на учење.

#### 3.1. Ученици

Како софтверски системи и алати засновани на технологијама ВИ-ја постају све присутнији не само у домену наставе и учења, већ и у свакодневном животу и раду, све је више оних који сматрају да предмет истраживања АНУ не треба да буде ученик издвојен од

---

<sup>18</sup> Rogers Kaliisa et al., “Have Learning Analytics Dashboards Lived Up to the Hype? A Systematic Review of Impact on Students’ Achievement, Motivation, Participation and Attitude”, in *Proceedings of the 14th Learning Analytics and Knowledge Conference*, (New York, NY, USA: Association for Computing Machinery, 2024), 295–304.

<sup>19</sup> Ibid.

технологије, односно људска интелигенција одвојена од вештачке интелигенције.<sup>20</sup> Све се више говори о томе како фокус треба да буде на хибридној интелигенцији<sup>21</sup> и хибридној регулацији учења, кроз међуделовање човека и вештачке интелигенције,<sup>22</sup> односно, да је потребно ревидирати разумевање појма ученика, тако да он интегрише димензију ВИ-ја.<sup>23</sup> Међутим, и даље је веома мало емпиријских студија које на овај начин конципирају ученика. Једна од неколицине таквих студија<sup>24</sup> бави се евалуацијом знања у контексту када ученици раде на задацима провере знања (конкретно, кроз писања есеја) уз коришћење ГВИ-ја (конкретно, GPT-4 модела). У оваквом контексту, фокус је не само на процени успешности ученика у решавању задатка већ, пре свега, на анализи процеса решавања задатка, и конкретно облика и степена укључивања ученика у тај процес. За потребе анализе процеса, истраживачи су прикупили податке о интеракцији ученика и ГВИ-ја (детаљне лог податке), кодирали их, а затим анализирали применом епистемичких мрежа. Резултати студије указују да предложени приступ анализе процеса омогућава идентификацију различитих облика интеракције ученика и ГВИ-ја у процесу писања есеја и тиме ствара основу за нове облике евалуације знања и вештина, релевантне за доба у којем је ГВИ свеприсутна.

### 3.2. Подаци

У овом одељку ћемо се дотаћи два начина на која технологије ВИ-ја унапређују компоненту података модела АНУ, и тиме истовремено унапређују потенцијал АНУ за разумевање улоге и утицаја ВИ-ја у образовању. Први облик унапређења се односи на прикупљање

---

<sup>20</sup> Lixiang Yan, Roberto Martinez-Maldonado, and Dragan Gašević, “Generative Artificial Intelligence in Learning Analytics: Contextualising Opportunities and Challenges through the Learning Analytics Cycle”, in *Proceedings of the 14th Learning Analytics and Knowledge Conference* (2024): 101–111.

<sup>21</sup> Sanna Jarvela et al., “Hybrid Intelligence – Human-AI Co-Evolution and Learning in Multirealities (HI)”, in *HAI 2023: Augmenting Human Intellect* (IOS Press, 2023), 392–394.

<sup>22</sup> Inge Molenaar, “The Concept of Hybrid Human-AI Regulation: Exemplifying How to Support Young Learners’ Self-Regulated Learning”, *Computers and Education: Artificial Intelligence*, 3 (2022): 100070.

<sup>23</sup> Видети фусноту број 2 изнад.

<sup>24</sup> Yixin Cheng et al., “Evidence-Centered Assessment for Writing with Generative AI”, in *Proceedings of the 14th Learning Analytics and Knowledge Conference, LAK ‘24* (New York, NY, USA: Association for Computing Machinery, 2024), 178–188.

података о менталном стању ученика (афективно стање, мотивација и слично). Други се односи на дуални циљ АНУ да, с једне стране, заштити приватност података, а с друге, да омогући репликацију резултата студија и подстакне даља истраживања, кроз дељење података.

### 3.2.1. Подаци о менталном стању ученика

Као што је претходно наведено, трагови учења (односно, лог подаци) представљају доминантан облик података у области АНУ. Анализа трагова учења је омогућила истраживачима да разумеју како ученици приступају различитим задацима учења и проверама знања. Међутим, те анализе нису омогућиле да се одговори на питања „зашто”: Зашто је одређена тактика или стратегија учења одабрана при решавању одређеног задатка? Зашто је ученик прешао с једне тактике на другу и зашто баш у датом тренутку? Да би се одговорило на таква питања, анализа понашања ученика, заснована на траговима учења, није довољна. Потребни су подаци о ономе што покреће и мотивише то понашање, односно, потребни су подаци о менталном стању ученика (перцепција, намера, мотивација и слично).

Иако је релевантност менталних чинилаца ученика добро препозната у АНУ, прикупљање података о тим чиниоцима је и даље изазов. Традиционално, такви подаци су се прикупљали путем анкета које се најчешће спроводе на почетку и/или на крају курса. Међутим, такви приступи прикупљању података не дозвољавају да се ухвати динамика мотивације, емоција, циљева, когнитивног оптерећења и других релевантних менталних чинилаца.<sup>25</sup> У систематском прегледу литературе о АНУ,<sup>26</sup> Досон и колеге су јасно истакли изазове повезане са прикупљањем података о ученицима и приметили да се „упркос недавним напрецима у мултимодалним АНУ, подаци који се тичу личних димензија ученика, као што су мотивација, емоције, психо-физичко стање, и културолошки аспекти, ослањају на упитнике или се прикупљају уз помоћ скупе опреме, несвојствене реалним процесима

<sup>25</sup> Mingming Zhou and Philip H. Winne, “Modeling Academic Achievement by Self-Reported versus Traced Goal Orientation”, *Learning and Instruction* 22, no. 6 (December 2012): 413–19; Dragan Gasevic et al., “Detecting Learning Strategies with Analytics: Links with Self-Reported Measures and Academic Performance,” *Journal of Learning Analytics* 4, no. 2 (July 5, 2017): 113–128.

<sup>26</sup> Shane Dawson et al., “Increasing the Impact of Learning Analytics”, in *Proceedings of the 9th International Conference on Learning Analytics & Knowledge, LAK19* (New York, NY, USA: Association for Computing Machinery, 2019), 446–455.

учења”.<sup>27</sup> Тренутна истраживања у области АНУ настоје да превазиђу овај изазов кроз различите приступе који деле једну заједничку особину, а то је ослањање на неинвазивне методе и алате за прикупљање лонгитудиналних података о менталном стању ученика.

Једна значајна група поменутих приступа заснива се на примени ВИ-ја у аутоматизацији детекције афективних стања и емоционалног ангажовања ученика, користећи или само лог податке или лог податке у комбинацији са порукама које се размењују онлајн комуникационим каналима. На пример, један интересантан приступ<sup>28</sup> користи индикаторе активности ученика независне од домена и платформе (на пример, гледање снимака предавања, решавање квизова, учешће у дискусионом форуму) и савремене алгоритме машинског учења, у циљу идентификације 18 различитих афективних стања ученика. Аутори су прикупили веома велики скуп података (лог податке за 69.174 ученика, у 1.898 школа у САД, током целе школске године) и креирали предиктивне моделе афективних стања ученика. Међутим, тачност модела је далеко од жељене, односно потребне за примену у пракси. Још један интересантан пример је студија Љуа и колега<sup>29</sup> у којој је предложен и евалуиран класификациони модел за идентификацију емоционалног ангажмана ученика (позитиван, негативан, збуњен) у масивном отвореном онлајн курсу (*Massive Open Online Course* – *МООС*). Предложени модел је заснован на једном од најновијих великих језичких модела (*BERT*)<sup>30</sup> и додатно обучен (*fine-tuned*) коришћењем порука размењених у *МООС* дискусионом форуму. Иако је овај модел надмашио алтернативне моделе, потребна су даља побољшања пре него што се може користити као поуздан извор информација о емоционалном ангажовању ученика током учења.

Софистицирани конверзацијски агенти (*conversational agents, chat bots*), који су постали доступни захваљујући најновијој генерацији технологија ГВИ-ја, могли би да постану замена (или допуна) традицио-

---

<sup>27</sup> Ibid., 453.

<sup>28</sup> Stephen Hutt, Joseph F. Grafsgaard and Sidney K. D’Mello, “Time to Scale: Generalizable Affect Detection for Tens of Thousands of Students across An Entire School Year”, in *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, CHI ’19 (New York, NY, USA: Association for Computing Machinery, 2019), 1–14.

<sup>29</sup> Sannyuya Liu et al., “Automated Detection of Emotional and Cognitive Engagement in MOOC Discussions to Predict Learning Achievement”, *Computers & Education* 181, C (2022).

<sup>30</sup> Jacob Devlin et al., “BERT: Pre-Training of Deep Bidirectional Transformers for Language Understanding” (arXiv, May 24, 2019).

налним инструментима за прикупљање података о менталном стању ученика (као што су различите врсте упитника). Укључивање ученика у разговор са конверзацијским агентом, уместо захтева за попуњавање често дугих и заморних упитника, може смањити оптерећење прикупљања података и можда га учинити чак и занимљивим за ученике, што се даље може позитивно одразити на стопу и квалитет одговора. Још увек нема емпиријских увида о овом облику примене конверзацијских агената у образовном контексту, тако да остаје да се види да ли се ови потенцијали могу остварити. Како су способности конверзацијских агената потребне за такав задатак (на пример, проактивност, деловање вођено циљем) предмет активног истраживања у домену ВИ-ја,<sup>31</sup> реално је ускоро очекивати и студије које ће испитати могућности конверзацијских агената за прикупљање података о унутрашњем стању ученика на природнији и примамљивији начин.

### 3.2.2. Приватност података

Скупови података који се користе у истраживањима и пракси АНУ често садрже осетљиве податке (на пример, оцене, ИП адресе<sup>32</sup> ученика, индикаторе психолошког и/или физичког стања). Подаци о унутрашњем стању ученика, о којима је претходно било речи, представљају посебно осетљиву категорију. Како се прикупљање осетљивих података повећава, расте и забринутост у вези са заштитом приватности. Генерално, континуирано повећање обима и разноликости података који се прикупљају у домену образовања, као и растући потенцијал за злоупотребу података коришћењем напредних технологија (укључујући и оне засноване на ВИ-ју), учинили су да приватност података постане веома актуелна тема у истраживањима и пракси АНУ.<sup>33</sup>

Традиционални приступи анонимизације података показали су се недовољним за заштиту приватности, што је указало на потребу за робуснијим решењима. На пример, показало се да се технике не-

---

<sup>31</sup> Видети, на пример, Lizi Liao, Grace Hui Yang, and Chirag Shah, "Proactive Conversational Agents in the Post-ChatGPT World", in *Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval, SIGIR '23* (New York, NY, USA: Association for Computing Machinery, 2023), 3452–3455.

<sup>32</sup> ИП (*Internet Protocol*) адреса је мрежна адреса рачунара који неко користи.

<sup>33</sup> Srećko Joksimović et al., "Privacy-Driven Learning Analytics", in *Manage Your Own Learning Analytics: Implement a Rasch Modelling Approach*, ed. Elspeth McKay (Cham: Springer International Publishing, 2022), 1–22.

надгледаног машинског учења могу користити за приступ осетљивим подацима ученика, упркос анонимизацији података пре њиховог објављивања.<sup>34</sup> Додатни изазов је то што традиционални приступи заштити приватности података често постижу заштиту приватности на рачун корисности података за АНУ.<sup>35</sup> Конкретно, како се повећава приватност података, корисност података која се огледа, на пример, у тачности предвиђања заснованој на тим подацима, значајно опада. Овај својеврсни облик „компромиса” (*trade-off*) између приватности података и њихове корисности за АНУ, представља велику препреку у реализацији претходно поменутог дуалног циља АНУ: учинити податке доступним ради репликације студија и даљих истраживања, али истовремено сачувати приватне податке од потенцијалне злоупотребе. Све наведено, као и општи консензус о потреби за етичким и одговорним коришћењем података у АНУ, довели су до повећаног интересовања за робусније облике заштите приватности података.

Синтетички подаци представљају најсавременије решење за очување приватности података у веома осетљивим доменима, као што су образовање, здравство и финансије.<sup>36</sup> Да би се сачувала приватност података, синтетички подаци, генерисани опонашањем карактеристика оригиналних података, чине се јавно доступним уместо оригиналних података. Недавна истраживања су показала да, за разлику од ранијих приступа заштити података у образовању, употреба синтетичких података испуњава захтеве и корисности података и приватности.<sup>37</sup>

Важно је напоменути да је до недавно генерисање и коришћење синтетичких података било у великој мери ограничено на структуриране податке, односно табеларне податке и временске серије. Међутим, развој ГВИ-ја не само да је омогућио софистицираније генерисање структурираних података,<sup>38</sup> већ је отворио и могућности

---

<sup>34</sup> Elad Yacobson et al., “De-Identification Is Insufficient to Protect Student Privacy, or – What Can a Field Trip Reveal?”, *Journal of Learning Analytics* 8, no. 2 (September 3, 2021): 83–92.

<sup>35</sup> Qinyi Liu et al., “Scaling While Privacy Preserving: A Comprehensive Synthetic Tabular Data Generation and Evaluation in Learning Analytics”, in *Proceedings of the 14th Learning Analytics and Knowledge Conference* (New York, NY, USA: Association for Computing Machinery, 2024), 620–31.

<sup>36</sup> James Jordon et al., “Synthetic Data -- What, Why and How?” (arXiv, May 6, 2022).

<sup>37</sup> Chen Zhan et al., “Preserving Both Privacy and Utility in Learning Analytics”, *IEEE Transactions on Learning Technologies*, 17 (2024): 1655–67.

<sup>38</sup> Joksimović et al., “Privacy-Driven Learning Analytics”.

за генерисање синтетичких текстуалних података и мултимедијалног садржаја. На пример, да би решили проблем ограничених података за обуку конверзацијског турског система, Шен и колеге<sup>39</sup> су предложили приступ који користи ГВИ (конкретно, GPT-3.5 модел) за синтетичко генерисање дијалога (односно података који имају структуру и форму дијалога). Слично томе, да би допринели превазилажењу проблема ограничених података за обуку конверзацијских система заснованих на знању (*grounded dialog systems*), као што су интелигенти педагошки агенти, Бао и колеге<sup>40</sup> су предложили оквир за генерисање синтетичких података за дијалоге утемељене у знању. Предложени оквир користи ГВИ (конкретно, T5 модел) да трансформише задату структуру дијалога (односно низ сегмената знања које је потребно обухватити у дијалогу) у кохерентан дијалог.

Још један актуелни приступ заштити приватности података ученика је коришћење великих језичких модела за идентификацију и уклањање личних података (*Personally Identifying Information – PII*) из порука које се размењују путем онлајн комуникационих канала. Пример је недавна студија<sup>41</sup> која је евалуирала перформансе GPT-4 модела у деидентификацији порука из дискусионих форума девет масивних отворених онлајн курсева. Алат се показао веома успешним у идентификацији PII, препознајући чак и случајеве које су људи пропустили приликом уређивања података. Међутим, алат није показао адекватну осетљивост, тако да је уклањао из текста и ентитете који не представљају PII.

### 3.3. Методе

Из перспективе метода АНУ, интеракција АНУ и ВИ-ја долази у два главна облика: 1) примена ВИ-ја за унапређење методолошких

---

<sup>39</sup> Dapeng Shan et al., “Annotating Educational Dialog Act with Data Augmentation in Online One-on-One Tutoring”, in *Artificial Intelligence in Education*, ed. Ning Wang et al. (Cham: Springer Nature Switzerland, 2023), 472–477.

<sup>40</sup> Jianzhu Bao et al., “A Synthetic Data Generation Framework for Grounded Dialogues”, in *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics*, ed. Anna Rogers, Jordan Boyd-Graber, and Naoaki Okazaki (ACL 2023, Toronto, Canada: Association for Computational Linguistics, 2023), 10866–10882.

<sup>41</sup> Shreya Singhal et al., “De-Identifying Student Personally Identifying Information with GPT-4”, in *Proceedings of the 17th International Conference on Educational Data Mining, EDM 2024*, 559–565.



приступа АНУ; 2) примена метода АНУ за проучавање улоге и ефеката примене ВИ-ја у различити контекстима учења.

Што се тиче првопоменутог аспекта интеракције АНУ и ВИ-ја, значајно је поменути примену технологија ВИ-ја за унапређење квалитативног кодирања текстуалних садржаја. Квалитативно кодирање је облик квалитативне анализе садржаја који је АНУ преузела из друштвених наука и представља неизоставни део анализе интеракције учесника у процесу учења. На пример, анализе дискурса и анализе за епистемичких мрежа захтевају квалитативно кодирање текстуалног садржаја који се размењује током интеракција везаних са учење (на пример, размењене поруке или коментари током колаборативног учења). Квалитативно кодирање је традиционално мануелни задатак, који захтева доста времена и труда. Међутим, најновија генерација великих језичких модела пружила је солидну технолошку основу за делимичну или потпуну аутоматизацију овог задатка.

На пример, Хоу и колеге<sup>42</sup> су истраживали ефикасност „промпт-инжењеринга” (*prompt engineering*) и финог подешавања модела (*fine tuning*) за дедуктивно кодирање дељених анотација (*social annotations*). Код дедуктивног кодирања, категорије (кодови) које се користе при кодирању садржаја су унапред дефинисане и потичу или из релевантног теоријског оквира или из сродног претходног емпиријског истраживања. Категорије за кодирање могу бити зависне или независне од контекста. Независне од контекста су оне категорије за које је приступ појединачним деловима садржаја (на пример, порука или коментар) довољан за кодирање. С друге стране, категорије зависне од контекста захтевају разумевање датог дела садржаја у односу на контекстуално повезане делове садржаја (на пример, претходне поруке или неки спољни материјали), да би се правилно извршило кодирање. У својој студији, Хоу и колеге су размотрили обе врсте кодова и испитали перформансе *GPT-3.5-turbo* модела прилагођеног задатку кодирања путем „промпт-инжењеринга” или финог подешавања. Резултати студије су показали да је, за различите категорије кодова, „промпт-инжењеринг” омогућио усаглашеност са кодовима експерата у распону од солидне до значајне. Нешто бољи резултати, односно виши ниво слагања, постигнути су финим подешавањем. Као што се и очекивало, у оба случаја је слагање било веће за категорије које су независне од контекста него за оне зависне од контекста. У

<sup>42</sup> Chenyu Hou et al., “Prompt-Based and Fine-Tuned GPT Models for Context-Dependent and Independent Deductive Coding in Social Annotation”, in *Proceedings of the 14th Learning Analytics and Knowledge Conference* (New York, NY, USA: Association for Computing Machinery, 2024), 518–528.

сродној студији, Барани и колеге<sup>43</sup> су испитивали различите улоге које би велики језички модели, конкретно GPT-4 модел, могли имати у процесу развоја кодног система за квалитативно кодирање текста. Креирање кодног система је задатак који су, до сада, извршавали искључиво истраживачи, односно, захтевао је људску експертизу и ангажовање. У својој студији, Барани и колеге су упоредили четири приступа развоју кодног система: потпуно мануелни приступ, потпуно аутоматизовани приступ и два приступа која су се ослањала на GPT-4 у оквиру специфичних корака процеса развоја кодног система. Налази студије указују да GPT-4 може бити драгоцен за побољшање кодног система за квалитативну анализу садржаја у контексту образовања, али је учешће истраживача и даље неопходно.

Други смер интеракције АНУ и ВИ-ја, односно примена метода АНУ за проучавање улоге и ефеката примене ВИ-ја у ситуацијама учења, лепо је илустрована недавном студијом Фана и колега<sup>44</sup> која се фокусира на компаративну анализу облика и ефеката интеракције студената са конверзацијским агентом заснованим на ГВИ-ју и другим, традиционалним облицима подршке током задатка ревизије есеја. Прецизније, Фан и колеге су спровели експерименталну студију у којој су насумично поделили студенте у четири групе: једна контролна група (без било каквог облика подршке) и три експерименталне групе. Свака експериментална група је имала специфичан облик подршке током рада на задатку ревизије есеја: комуникација са наставником, интеракција са ChatGPT-јем, и коришћење персонализоване листе предлога и смерница за ревизију есеја. Да би испитали интеракцију студената са овим различитим облицима подршке, истраживачи су прикупили податке из више извора: трагове учења (односно лог податке), податке о коришћењу миша и тастатуре, као и податке о кретању погледа на екрану (*eye-gaze tracking*). Прикупљени подаци су мапирани у микропроцесе учења (когнитивне и метакогнитивне) који су даље анализирани применом метода за идентификацију процеса из података (*process mining*), са циљем да се идентификују специфични профили интеракције током рада студената на датом задатку. Ова анализа је открила различите обрасце интеракције са различитим из-

---

<sup>43</sup> Amanda Barany et al., "ChatGPT for Education Research: Exploring the Potential of Large Language Models for Qualitative Codebook Development", in *Artificial Intelligence in Education*, ed. Andrew M. Olney et al. (Cham: Springer Nature Switzerland, 2024), 134–149.

<sup>44</sup> Yizhou Fan, "Learning and Regulating with ChatGPT: What an Experimental Study Tells Us", YouTube, accessed on 25 June 2024, <https://www.youtube.com/watch?v=YdWePJSYrzw>.

ворима подршке. У *ChatGPT* групи, доминантни образац је имао облик директне релације између употребе *ChatGPT*-ја и самог рада на ревизији есеја, док су остали когнитивни (на пример, читање) и метакогнитивни (на пример, оријентација, евалуација) процеси готово изостали. С друге стране, група која је била у интеракцији са наставником није инхибирала, већ је побољшала везе између ревизије есеја и других процеса учења. Штавише, док је *ChatGPT* група имала значајно боље резултате на ревидираним есејима у поређењу са осталим групама, групе се нису значајно разликовале у погледу стеченог знања, као ни у мотивацији за решавање задатка. Све у свему, резултати студије указују на потенцијалне проблеме прекомерног ослањања на ГВИ и такозвану метакогнитивну лењост, односно тенденцију ученика да при интеракцији са ГВИ-јем не активирају своје метакогнитивне капацитете (као што су праћење, евалуација, и прилагођавање учења).

Сличне закључке изнели су Дарвиши и колеге<sup>45</sup> на основу велике контролисане студије (1625 студената и 10 курсева). Користећи методе АНУ, студија је испитала да ли ће студенти учити из редовних, детаљних и персонализованих повратних информација које им пружа алат заснован на технологијама ВИ-ја у оквиру задатка учења где се од њих очекује да дају свој критички осврт на радове других студената (*peer-feedback*). Идеја је била да се кроз помоћ алата заснованог на ВИ-ју студенти оспособе за критичку анализу, тако да могу самостално да је ураде када помоћ алата или наставника није доступна. Резултати су показали да су студенти успели ефикасно да ураде дате задатке уз помоћ ВИ-ја, али је укидањем ове подршке њихов учинак значајно опао. Другим речима, студенти су били склони да се, при формирању критичког осврта на радове других студената, ослањају на помоћ ВИ-ја, уместо да развијају сопствене вештине и знање потребне за тај задатак. Ове и сличне студије указују да ће са све већим присуством ВИ-ја у образовању, педагошке интервенције које мотивишу метакогнитивно ангажовање ученика и успостављање односа сарадње са ВИ-јем (уместо чистог ослањања на ВИ) бити све потребније.

Надовезујући се на резултате претходно поменуте студије,<sup>46</sup> Фан и колеге су спровели још једну студију која је имала за циљ компаративну анализу интеракције студената са наставником и *ChatGPT*-јем, овај пут посматрајући ту интеракцију из перспективе тражења помоћи

<sup>45</sup> Ali Darvishi et al., "Impact of AI Assistance on Student Agency", *Computers & Education* (2023): 104967.

<sup>46</sup> Singhal et al., "De-Identifying Student Personally Identifying Information with GPT-4".

(*help seeking*), као једне од вештина саморегулисаног учења.<sup>47</sup> У том циљу су коришћени снимци комуникације студената са наставником, односно ChatGPT-јем (зависно од експерименталне групе у којој је студент био). Ови снимци су кодирани на основу усвојеног теоријског модела и резултујући кодови су послужили као основа за темпоралну анализу комуникације између студената и наставника и ChatGPT-ја (тачније, за идентификацију процеса из података – *process mining*). Добијени модели процеса су сугерисали врло различите обрасце тражења помоћи у две разматране групе: у поређењу са групом која је могла да се обрати наставнику за помоћ, у ChatGPT групи, студенти су постављали више „директних” питања (односно питања усмерених на добијање директних решења) и најчешће су прихватили помоћ ChatGPT-ја каква јесте, без критичког сагледавања. Штавише, у кратким интервјуима након студије, студенти у ChatGPT групи су навели да су били слободнији у комуникацији, у поређењу са групом која је радила са наставником. Конкретније, студенти су изјавили да им је било лакше да траже помоћ од ChatGPT-ја јер није било ризика да се осрамоте.

Још један занимљив пример коришћења метода АНУ за боље разумевање употребе ГВИ-ја у образовном контексту је студија<sup>48</sup> која је испитивала различите обрасце интеракције студената са ChatGPT-јем у контексту курса роботике на постдипломским студијама. Груписањем студената на основу карактеристика изведених из промптова које су писали како би тражили помоћ од ChatGPT-ја, истраживачи су идентификовали три профила (кластера) коришћења ChatGPT-ја који су се разликовали у смислу остварених резултата учења и учинка на задацима: а) „дебагери” (*Debuggers*), који су питали за исправке грешака у коду, односно за решења за проблеме у коду на које су наилазили; б) концептуални истраживачи (*Conceptual explorers*), који су настојали да разумеју концепте, задатке и код; и в) практични програмери (*Practical developers*), који су искључиво тражили решења задатака. Док су „дебагери” остварили најбољи учинак на задацима, попут практичних програмера, ти добри резултати најчешће нису били праћени концептуалним разумевањем. Насупрот томе, концептуални истраживачи су се показали најбољим по питању укупних резултата учења. Ова студија нуди још једну потврду да претерано ослањање на

---

<sup>47</sup> Ibid.

<sup>48</sup> Jérôme Brender et al., “Who’s Helping Who? When Students Use ChatGPT to Engage in Practice Lab Sessions”, in *Artificial Intelligence in Education*, ed. Andrew M. Olney et al. (Cham: Springer Nature Switzerland, 2024), 235–249.

ГВИ, иако је често корисно за краткорочне циљеве, може инхибирати истинско савладавање нових знања и вештина.

Истраживачи су такође почели да експериментишу са педагошким приступима који укључују интеракцију ученика са више од једног агента заснованог на ВИ-ју. На пример, студија која је у току у време писања овог рада, користи два конверзацијска агента заснована на ГВИ-ју (конкретно, *ChatGPT-4*), са циљем да помогне студентима медицине да науче како да кроз разговор са пацијентом што боље утврде његово здравствено стање.<sup>49</sup> Конкретно, један агент преузима улогу пацијента чије здравствено стање студент треба да испита, док други преузима улогу искусног лекара који „прати” интеракцију између „пацијента” и студента и даје повратне информације студенту у реалном времену. Истраживачи упоредо прикупљају лог податке као и податке о садржају комуникације студента и агената, са циљем да се, применом приступа АНУ, боље разуме овај облик учења који се остварује у сарадњи са ГВИ-јем.

Описана студија је једна од више актуелних студија које примењују АНУ за боље разумевање и унапређење сарадње човека (ученика, наставника) и ВИ-ја у контексту учења. Ово је мотивисано препознавањем чињенице да су системи и алати засновани на ВИ-ју постају саставни део различитих професија и да ће будућност рада укључивати различите облике сарадње између људи и ВИ-ја. Стога је задатак образовања да помогне ученицима да развију знања и вештине потребне за успешну сарадњу са ВИ-јем. За реализацију тог задатка, потребно је и осмислити и омогућити евалуацију сарадње човека и ВИ-ја. Актуелни приступи таквој евалуацији укључују не само евалуацију производа колаборативног задатка, већ и евалуацију процеса који су довели до тог производа.<sup>50</sup> Пример истраживања које следи овај приступ је претходно поменута студија Ченга и колега<sup>51</sup> у којој се за процену колаборативног писања људи и ГВИ-ја предлаже метод заснован на АНУ.

---

<sup>49</sup> Singhal et al., “De-Identifying Student Personally Identifying Information with GPT-4”.

<sup>50</sup> Dragan Gasevic, “Reimagining Assessment in the Age of Artificial Intelligence”, YouTube, accessed on 13 May 2024, <https://www.youtube.com/watch?v=2Ea3oJysD6s>.

<sup>51</sup> Jarvela et al., “Hybrid Intelligence – Human-AI Co-Evolution and Learning in Multirealities (HI)”.

### 3.4. Акције

Као што је претходно наведено, АНУ контролне табле су примарни облик преношења увида који се стичу кроз аналитике крајњим корисницима, са циљем да се омогући добро информисано доношење одлука и предузимање акције. Иако су АНУ контролне табле биле предмет бројних истраживања у домену АНУ, и даље их карактерише низ ограничења.<sup>52</sup> Једно добро познато ограничење је једносмерна комуникација резултата АНУ и повратних информација, с обзиром да су истраживања у домену едукације показала да је такво преношење повратних информација далеко од оптималног.<sup>53</sup> Оно што је далеко пожељније је дијалогска форма, односно двосмерна комуникација која омогућава боље разрешење било ког потенцијалног проблема идентификованог кроз АНУ или решавање било каквог потенцијално погрешног тумачења увида остварених кроз АНУ. Конверзацијски агенти, засновани на ГВИ-ју, отворили су могућност за преношење повратних информација у форми дијалога, а тиме и за нову генерацију АНУ контролних табли. Богата литература о педагошким агентима,<sup>54</sup> која претходи развоју ГВИ-ја, може понудити јаку основу за развој таквих агената. Као први корак у том смеру, може се навести *VizChat*, прототип конверзацијског агента отвореног кода који је пројектован да допуни АНУ контролне табле контекстуализованим објашњењима визуелно представљених резултата АНУ.<sup>55</sup> Циљ је побољшати могућност корисника да разуме повратне информације представљене на контролној табли, без оптерећивања корисника претераним информацијама. У том циљу, *VizChat* користи мултимодалну ГВИ (*GPT-4V*) и тренутно актуелни приступ за унапређење ГВИ резултата (*Retrieval Augmented Generation – RAG*), да, на захтев корисника, генерише контекстуално релевантна објашњења специфичних визуелизација или сажетак информација интегрисаних из више визуелних приказа резултата АНУ. Да би се повећала транспарентност и допринело поверењу у повратне информације пренете преко АНУ контролне

<sup>52</sup> Du, Hew and Liu, “What Can Online Traces Tell Us about Students’ Self-Regulated Learning? A Systematic Review of Online Trace Data Analysis”.

<sup>53</sup> Bhagya Maheshi et al., “Dialogic Feedback at Scale: Recommendations for Learning Analytics Design”, *Journal of Computer Assisted Learning* (2024).

<sup>54</sup> Pieta Sikström et al., “How Pedagogical Agents Communicate with Students: A Two-Phase Systematic Review”, *Computers & Education*, 188 (2022): 104564.

<sup>55</sup> Lixiang Yan et al., “VizChat: Enhancing Learning Analytics Dashboards with Contextualised Explanations Using Multimodal Generative AI Chatbots”, in *Artificial Intelligence in Education*, ed. Andrew M. Olney et al. (Cham: Springer Nature Switzerland, 2024), 180–193.

табле, VizChat такође нуди детаљне информације о коришћеним изворима података и аналитичким процесима који стоје иза сваке визуелизације. Иако VizChat доста обећава, реч је о истраживачком прототипу чија информативност и употребљивост тек треба да се испитају кроз свеобухватније емпиријске студије са студентима и наставницима.

Још један интересантан приступ унапређењу комуникације увида остварених кроз АНУ је заснован на приповедању прича на основу података (*data story telling*). Употреба приповедања било као алтернативе или као допуна АНУ контролним таблама је већ истражена,<sup>56</sup> посебно у контексту мултимодалних АНУ, где је, услед употребе више извора података, изазов комуникације остварених увида посебно изражен.<sup>57</sup> Са циљем да додатно олакшају преношење повратних информација ученицима и учине их интересантним, Милеси и колеге<sup>58</sup> су предложили комбиновану примену ГВИ-ја и стрипова базираних на подацима (*data comics*). Овакви стрипови представљају нови формат приповедања података који помаже крајњим корисницима, а посебно онима који немају техничку стручност, да разумеју сложене податке и аналитику. Конкретно, истраживачи су користили *MidJourney*,<sup>59</sup> тренутно популаран ВИ алат за генерисање слика, као и алат за креирање стрипова, како би креирали персонализоване стрипове засноване на подацима и увидима АНУ који се тичу појединачних ученика. Иницијална евалуација овог приступа са студентима медицинске школе показала је да, иако су студенти сматрали ове стрипове привлачним и интересантним, они су такође изразили забринутост да таквом облику преношења увида из података недостаје професионализам потребан за дати контекст учења (професионално образовање). Иако вероват-

---

<sup>56</sup> Видети, на пример, Gloria Milena Fernandez Nieto et al., “Beyond the Learning Analytics Dashboard: Alternative Ways to Communicate Student Data Insights Combining Visualisation, Narrative and Storytelling”, in *12th International Learning Analytics and Knowledge Conference, LAK22* (New York, NY, USA: Association for Computing Machinery, 2022), 219–229.

<sup>57</sup> Roberto Martinez-Maldonado et al., “From Data to Insights: A Layered Storytelling Approach for Multimodal Learning Analytics”, in *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems, CHI '20* (New York, NY, USA: Association for Computing Machinery, 2020), 1–15.

<sup>58</sup> Mikaela E Milesi et al., “‘It’s Really Enjoyable to See Me Solve the Problem like a Hero’: GenAI-Enhanced Data Comics as a Learning Analytics Tool”, in *Extended Abstracts of the 2024 CHI Conference on Human Factors in Computing Systems, CHI EA '24* (New York, NY, USA: Association for Computing Machinery, 2024), 1–7.

<sup>59</sup> <https://www.midjourney.com/home>.

но није погодан за одрасле ученике, овај приступ делује обећавајуће за млађе ученике.

#### 4. Закључак

Овај рад је дао увид у међусобни однос и динамику успостављену између аналитика учења (АНУ) и вештачке интелигенције (ВИ), ослањајући се на најновије емпиријске студије у области АНУ, као и сродне области вештачке интелигенције (AIED) и истраживања података у образовању (EDM). Рад је истакао нове могућности које су технологије ВИ-ја донеле АНУ, као и примену АНУ за боље разумевања улоге и утицаја ВИ-ја, а посебно ГВИ-ја, на учење. Све представљено указује да је истраживачка заједница у области АНУ остварила значајне доприносе у две сфере:

- у примени ВИ-ја за решавање дуготрајних изазова у АНУ, као што је обезбеђивање приватности података и унапређење АНУ контролних табли,
- у примени АНУ за стицање увида у интеракције ученика са ВИ-јем, као што је идентификација склоности ученика да се претерано ослањају на ВИ и показују слабо метакогнитивно ангажовање.

Вештачка интелигенција уводи нове могућности и изазове за АНУ, а истовремено обезбеђује истраживачима напредније методе, богатije податке и напредније начине преношења увида остварених кроз аналитике, као што су вербална објашњења и повратне информације у форми дијалога. Динамика успостављена између АНУ и ВИ-ја обећава да ће континуирано доносити релевантне увиде у све већу улогу ВИ у учењу. Да би се ови увиди ефикасно интегрисали у образовну праксу, активно ангажовање свих заинтересованих страна (ученика, наставника, координатора студијских програма и других) је кључно, као што су врло релевантне јавне политике у домену едукације које препознају важност правовременог доношења одлука заснованих на доказима (*evidence-based decisions*).



## Литература

1. Bao, Jianzhu, Rui Wang, Yasheng Wang, Aixin Sun, Yitong Li, Fei Mi, and Ruifeng Xu. "A Synthetic Data Generation Framework for Grounded Dialogues". In *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, edited by Anna Rogers, Jordan Boyd-Graber, and Naoaki Okazaki, 10866–10882. Toronto, Canada: Association for Computational Linguistics, 2023. doi:10.18653/v1/2023.acl-long.608.
2. Barany, Amanda, Nidhi Nasiar, Chelsea Porter, Andres Felipe Zambrano, Alexandra L. Andres, Dara Bright, Mamta Shah, et al. "ChatGPT for Education Research: Exploring the Potential of Large Language Models for Qualitative Codebook Development." In *Artificial Intelligence in Education*, edited by Andrew M. Olney, Irene-Angelica Chounta, Zitao Liu, Olga C. Santos, and Ig Ibert Bittencourt, 134–149. Cham: Springer Nature Switzerland, 2024. doi:10.1007/978-3-031-64299-9\_10.
3. Brender, Jérôme, Laila El-Hamamsy, Francesco Mondada, and Engin Bumbacher. "Who's Helping Who? When Students Use ChatGPT to Engage in Practice Lab Sessions". In *Artificial Intelligence in Education*, edited by Andrew M. Olney, Irene-Angelica Chounta, Zitao Liu, Olga C. Santos, and Ig Ibert Bittencourt, 235–249. Cham: Springer Nature Switzerland, 2024. doi:10.1007/978-3-031-64302-6\_17.
4. Chen, Bodong, and Oleksandra Poquet. "Networks in Learning Analytics: Where Theory, Methodology, and Practice Intersect". *Journal of Learning Analytics* 9, 1 (2022): 1–12. doi:10.18608/jla.2022.7697.
5. Cheng, Yixin, Kayley Lyons, Guanliang Chen, Dragan Gašević, and Zachari Swiecki. "Evidence-Centered Assessment for Writing with Generative AI". In *Proceedings of the 14th Learning Analytics and Knowledge Conference*, 178–188. LAK '24. New York, NY, USA: Association for Computing Machinery, 2024. doi:10.1145/3636555.3636866.
6. Clow, Doug. "The Learning Analytics Cycle: Closing the Loop Effectively". In *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge*, LAK '12, 134–138. New York, NY, USA: Association for Computing Machinery, 2012. doi:10.1145/2330601.2330636.
7. Darvishi, Ali, Hassan Khosravi, Shazia Sadiq, Dragan Gašević, and George Siemens. "Impact of AI Assistance on Student Agency". *Computers & Education* (2023): 104967. doi:10.1016/j.compedu.2023.104967.
8. Dawson, Shane, Srečko Joksimovic, Oleksandra Poquet, and George Siemens. "Increasing the Impact of Learning Analytics". In *Proceedings of the 9th International Conference on Learning Analytics & Knowledge*, LAK19, 446–455. New York, NY, USA: Association for Computing Machinery, 2019. doi:10.1145/3303772.3303784.
9. Devlin, Jacob, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. "BERT: Pre-Training of Deep Bidirectional Transformers for Language Understanding". *arXiv*, May 24, 2019. doi:10.48550/arXiv.1810.04805.

10. Du, Jiahui, Khe Foon Hew, and Lejia Liu. "What Can Online Traces Tell Us about Students' Self-Regulated Learning? A Systematic Review of Online Trace Data Analysis". *Computers & Education*, 201 (2023): 104828. doi:10.1016/j.compedu.2023.104828.
11. Fan, Yizhou, "Learning and Regulating with ChatGPT: What an Experimental Study Tells Us". YouTube. Accessed on 25 June 2024. <https://www.youtube.com/watch?v=YdWePjSYrzw>.
12. Fernandez Nieto, Gloria Milena, Kirsty Kitto, Simon Buckingham Shum, and Roberto Martinez-Maldonado. "Beyond the Learning Analytics Dashboard: Alternative Ways to Communicate Student Data Insights Combining Visualisation, Narrative and Storytelling". In *12th International Learning Analytics and Knowledge Conference, LAK22*, 219–229. New York, NY, USA: Association for Computing Machinery, 2022. doi:10.1145/3506860.3506895.
13. Gasevic, Dragan. "Reimagining Assessment in the Age of Artificial Intelligence". YouTube. Accessed on 13 May 2024. <https://www.youtube.com/watch?v=2Ea3oJysD6s>.
14. Gasevic, Dragan, Jelena Jovanovic, Abelardo Pardo, and Shane Dawson. "Detecting Learning Strategies with Analytics: Links with Self-Reported Measures and Academic Performance". *Journal of Learning Analytics* 4, no. 2 (July 5, 2017): 113–128.
15. Gašević, Dragan, Shane Dawson, Tim Rogers, and Danijela Gasevic. "Learning Analytics Should Not Promote One Size Fits All: The Effects of Instructional Conditions in Predicting Academic Success". *The Internet and Higher Education*, 28 (2016): 68–84. doi:10.1016/j.iheduc.2015.10.002.
16. Gašević, Dragan, Shane Dawson, and George Siemens. "Let's Not Forget: Learning Analytics Are about Learning". *TechTrends*, 59, 1 (2014): 64–71. doi:10.1007/s11528-014-0822-x.
17. Giannakos, Michail, Roger Azevedo, Peter Brusilovsky, Mutlu Cukurova, Yannis Dimitriadis, Davinia Hernandez-Leo, Sanna Järvelä, Manolis Mavrikis, and Bart Rienties. "The Promise and Challenges of Generative AI in Education". *Behaviour & Information Technology* (2024): in press.
18. Hou, Chenyu, Gaoxia Zhu, Juan Zheng, Lishan Zhang, Xiaoshan Huang, Tianlong Zhong, Shan Li, Hanxiang Du, and Chin Lee Ker. "Prompt-Based and Fine-Tuned GPT Models for Context-Dependent and -Independent Deductive Coding in Social Annotation". In *Proceedings of the 14th Learning Analytics and Knowledge Conference*, 518–528. New York, NY, USA: Association for Computing Machinery, 2024. doi:10.1145/3636555.3636910.
19. Hutt, Stephen, Joseph F. Grafsgaard, and Sidney K. D'Mello. "Time to Scale: Generalizable Affect Detection for Tens of Thousands of Students across An Entire School Year". In *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems, CHI'19*, 1–14.

- New York, NY, USA: Association for Computing Machinery, 2019. doi:10.1145/3290605.3300726.
20. Jarvela, Sanna, Guoying Zhao, Janne Heikkilä, Hanna Järvenoja, Hanna Rvenoja, Kristina Mikkonen, and Satu Kaleva. "Hybrid Intelligence – Human-AI Co-Evolution and Learning in Multirealities (HI)". In *HAI 2023: Augmenting Human Intellect*, 392–394. IOS Press, 2023. doi:10.3233/FAIA230107.
  21. Joksimović, Srećko, Ruth Marshall, Thierry Rakotoarivelo, Djazia Ladjal, Chen Zhan, and Abelardo Pardo. "Privacy-Driven Learning Analytics". In *Manage Your Own Learning Analytics: Implement a Rasch Modelling Approach*, edited by Elspeth McKay, 1–22. Cham: Springer International Publishing, 2022. doi:10.1007/978-3-030-86316-6\_1.
  22. Jordon, James, Lukasz Szpruch, Florimond Houssiau, Mirko Bottarelli, Giovanni Cherubin, Carsten Maple, Samuel N. Cohen, and Adrian Weller. "Synthetic Data -- What, Why and How?". *arXiv*, 6 May 2022. doi:10.48550/arXiv.2205.03257.
  23. Jovanović, Jelena, Mohammed Saqr, Srećko Joksimović, and Dragan Gašević. "Students Matter the Most in Learning Analytics: The Effects of Internal and Instructional Conditions in Predicting Academic Success." *Computers & Education*, 172 (2021): 104251. doi:10.1016/j.compedu.2021.104251.
  24. Jovanovic, Jelena, Dragan Gašević, Lixiang Yan, Graham Baker, Andrew Murray, and Danijela Gasevic. "Explaining Trace-Based Learner Profiles with Self-Reports: The Added Value of Psychological Networks." *Journal of Computer Assisted Learning*, 40, 4 (2024): 1481–1499. doi:10.1111/jcal.12968.
  25. Kaliisa, Rogers, Kamila Misiejuk, Sonsoles López-Pernas, Mohammad Khalil, and Mohammed Saqr. "Have Learning Analytics Dashboards Lived Up to the Hype? A Systematic Review of Impact on Students' Achievement, Motivation, Participation and Attitude". In *Proceedings of the 14th Learning Analytics and Knowledge Conference*, 295–304. New York, NY, USA: Association for Computing Machinery, 2024. doi:10.1145/3636555.3636884.
  26. Lang, Charles, Alyssa Friend Wise, Agathe Merceron, Dragan Gašević, and George Siemens. "What Is Learning Analytics?". In *The Handbook of Learning Analytics*, edited by Charles Lang, George Siemens, Alyssa Friend Wise, Dragan Gašević, and Agathe Merceron, 2<sup>nd</sup> ed., 8–18. Vancouver, Canada: SoLAR, 2022. <https://www.solaresearch.org/publications/hla-22/hla22-chapter1/>.
  27. Liao, Lizi, Grace Hui Yang, and Chirag Shah. "Proactive Conversational Agents in the Post-ChatGPT World." In *Proceedings of the 46th International ACM SIGIR Conference on Research and Development in Information Retrieval, SIGIR '23*, 3452–3455. New York, NY, USA: Association for Computing Machinery, 2023. doi:10.1145/3539618.3594250.

28. Liu, Sannyuya, Shiqi Liu, Zhi Liu, Xian Peng, and Zongkai Yang. "Automated Detection of Emotional and Cognitive Engagement in MOOC Discussions to Predict Learning Achievement". *Computers & Education* 181, C (2022). doi:10.1016/j.compedu.2022.104461.
29. Liu, Qinyi, Mohammad Khalil, Jelena Jovanovic, and Ronas Shakya. "Scaling While Privacy Preserving: A Comprehensive Synthetic Tabular Data Generation and Evaluation in Learning Analytics". In *Proceedings of the 14th Learning Analytics and Knowledge Conference, LAK '24*. 620–631. New York, NY, USA: Association for Computing Machinery, 2024. doi:10.1145/3636555.3636921.
30. Maheshi, Bhagya, Wei Dai, Roberto Martinez-Maldonado, and Yi-Shan Tsai. "Dialogic Feedback at Scale: Recommendations for Learning Analytics Design". *Journal of Computer Assisted Learning* (2024). doi:10.1111/jcal.13034.
31. Martinez-Maldonado, Roberto, Vanessa Echeverria, Gloria Fernandez Nieto, and Simon Buckingham Shum. "From Data to Insights: A Layered Storytelling Approach for Multimodal Learning Analytics". In *Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems*, 1–15. New York, NY, USA: Association for Computing Machinery, 2020. doi:10.1145/3313831.3376148.
32. Molenaar, Inge. "The Concept of Hybrid Human-AI Regulation: Exemplifying How to Support Young Learners' Self-Regulated Learning". *Computers and Education: Artificial Intelligence*, 3 (2022): 100070. doi:10.1016/j.caeai.2022.100070.
33. Milesi, Mikaela E, Riordan Alfredo, Vanessa Echeverria, Lixiang Yan, Linxuan Zhao, Yi-Shan Tsai, and Roberto Martinez-Maldonado. "'It's Really Enjoyable to See Me Solve the Problem like a Hero': GenAI-Enhanced Data Comics as a Learning Analytics Tool". In *Extended Abstracts of the 2024 CHI Conference on Human Factors in Computing Systems*, 1–7. New York, NY, USA: Association for Computing Machinery, 2024. doi:10.1145/3613905.3651111.
34. Ouhaichi, Hamza, Daniel Spikol, and Bahtijar Vogel. "Research Trends in Multimodal Learning Analytics: A Systematic Mapping Study". *Computers and Education: Artificial Intelligence*, 4 (2023): 100136. doi:10.1016/j.caeai.2023.100136.
35. Palanci, Abdulkadir, Rabia Meryem Yilmaz, and Zeynep Turan. "Learning Analytics in Distance Education: A Systematic Review Study". *Education and Information Technologies* (2024). doi:10.1007/s10639-024-12737-5.
36. Sikström, Pieta, Chiara Valentini, Anu Sivunen, and Tommi Kärkkäinen. "How Pedagogical Agents Communicate with Students: A Two-Phase Systematic Review.". *Computers & Education*, 188 (2022): 104564. doi:10.1016/j.compedu.2022.104564.
37. Singhal, Shreya, Andres Felipe Zambrano, Maciej Pankiewicz, Xiner Liu, Chelsea Porter, and Ryan S. Baker. "De-Identifying Student Personally

- Identifying Information with GPT-4". In *Proceedings of the 17th International Conference on Educational Data Mining*, (2024): 559–565. doi:10.5281/zenodo.12729884.
38. Shan, Dapeng, Deliang Wang, Chenwei Zhang, Ben Kao, and Carol K. K. Chan. "Annotating Educational Dialog Act with Data Augmentation in Online One-on-One Tutoring". In *Artificial Intelligence in Education*, edited by Ning Wang, Genaro Rebolledo-Mendez, Vania Dimitrova, Noboru Matsuda, and Olga C. Santos, 472–77. Cham: Springer Nature Switzerland, 2023. doi:10.1007/978-3-031-36336-8\_73.
39. Yacobson, Elad, Orly Fuhrman, Sara Hershkovitz, and Giora Alexandron. "De-Identification Is Insufficient to Protect Student Privacy, or – What Can a Field Trip Reveal?". *Journal of Learning Analytics*, 8, 2 (2021): 83–92. doi:10.18608/jla.2021.7353.
40. Yan, Lixiang, Linxuan Zhao, Vanessa Echeverria, Yueqiao Jin, Riordan Alfredo, Xinyu Li, Dragan Gašević, and Roberto Martinez-Maldonado. "VizChat: Enhancing Learning Analytics Dashboards with Contextualised Explanations Using Multimodal Generative AI Chatbots". In *Artificial Intelligence in Education*, edited by Andrew M. Olney, Irene-Angelica Chounta, Zitao Liu, Olga C. Santos, and Ig Ibert Bittencourt, 180–193. Cham: Springer Nature Switzerland, 2024. doi:10.1007/978-3-031-64299-9\_13.
41. Yan, Lixiang, Roberto Martinez-Maldonado, and Dragan Gašević. "Generative Artificial Intelligence in Learning Analytics: Contextualising Opportunities and Challenges through the Learning Analytics Cycle". In *Proceedings of the 14th Learning Analytics and Knowledge Conference* (2024): 101–111. doi:10.1145/3636555.3636856.
42. Zhan, Chen, Srećko Joksimović, Djazia Ladjal, Thierry Rakotoarivelo, Ruth Marshall, and Abelardo Pardo. "Preserving Both Privacy and Utility in Learning Analytics". *IEEE Transactions on Learning Technologies*, 17 (2024): 1655–1667. doi:10.1109/TLT.2024.3393766.
43. Zhou, Mingming, and Philip H. Winne. "Modeling Academic Achievement by Self-Reported versus Traced Goal Orientation". *Learning and Instruction*, 22, 6 (2012): 413–419. doi:10.1016/j.learninstruc.2012.03.004.
44. Winne, Philip H. "Cognition and Metacognition within Self-Regulated Learning". In *Handbook of Self-Regulation of Learning and Performance*, 2<sup>nd</sup> ed. Routledge, 2017.
45. Winne, Philip H., and Allyson E. Hadwin. "Studying as Self-Regulated Learning". In *Metacognition in Educational Theory and Practice*. Routledge, 1998.

**Jelena M. Jovanović**

University of Belgrade, Faculty of Organisational Sciences, Belgrade

### **ARTIFICIAL INTELLIGENCE IN EDUCATION FROM THE PERSPECTIVE OF LEARNING ANALYTICS**

The wide adoption of digital platforms and tools in educational practices has paved the way for collecting and analyzing extensive data related to the learners' interactions with diverse learning resources, as well as their mutual interactions during a variety of collaborative learning activities. The resulting data-informed insights allow for a deeper understanding of learning processes and promise to enhance both educational outcomes and the overall learning experience. This promise has been the driving force behind the emergence of Learning Analytics (LA) as a research and practice field with the overarching objectives of understanding and optimizing learning and the environments in which learning occurs. To attain those objectives, LA relies on data about various aspects of learning, learners, and the learning context. The insights derived through data analytics are communicated back to learners, teachers, instructional designers, and other relevant stakeholders, in order to support evidence-based decision-making across diverse educational contexts. Despite its substantial contributions to unraveling the complexities of learning processes, LA still faces numerous unresolved questions and challenges. Moreover, the dynamic nature of teaching and learning modalities continues to introduce new challenges and opportunities, the latest of which stem from the rapid advancements in Artificial Intelligence (AI).

The recent developments in AI are affecting all aspects of education, including educational content creation, assessment of knowledge and skills, and educational feedback provision, to name but a few. Even though AI has been used in education for several decades and substantial knowledge and experience related to the use of AI in education has accumulated, that proved insufficient for properly understanding the role and effect of the latest AI technologies, especially Generative AI, on educational practices. To fill that gap and support evidence-based decision making in a wide variety of AI-augmented learning settings, we need a systematic approach to understanding the role and impact of the new generation of AI on education and its stakeholders. The field of LA, with its established methodologies for studying learning, is well-positioned to systematically explore and understand the benefits and drawbacks of incorporating (Generative) AI into education. On the other hand, LA itself continues to evolve and improve through the integration of AI technologies into its methodological approaches and processes. Thus, LA not only enables a comprehensive examination of the

potentials and challenges of AI applications in education, but also transforms itself in response to the opportunities and challenges that AI introduces.

This paper aims to examine the interplay that has been established between LA and AI in education. To that end, the paper first offers a brief introduction to LA, focusing on the iterative (cyclical) nature of the LA process and its key components. Next, the cyclical model of LA is used as the conceptual framework for exploring the intersection of LA and the latest developments in AI, particularly Generative AI. Specifically, the paper examines how core components of the LA process – learners, data, methods, and actions – have been augmented or transformed through cutting-edge AI technologies, as well as how they contribute to better understand of the place, role, and effect of AI on learning. By examining the dynamic that has been established between LA and AI, the paper also aims to demonstrate how AI, particularly Generative AI, can empower LA to keep pace with the dynamic changes in the educational field and remain true to its mission of understanding and improving learning. To achieve these goals, the paper draws on published empirical research in the field of LA, as well as in the closely related areas of Artificial Intelligence in Education (AIED) and Educational Data Mining (EDM). By relying on findings of relevant empirical studies, the paper seeks to provide evidence-based insights into the evolving relationship between LA and AI, and point out direction for future research at the intersection of LA and AI.

**Keywords:** Learning Analytics, Artificial Intelligence, Generative Artificial Intelligence, Learning, Education

*Прихваћено за објављивање на седници  
Уређивачкој одбора 1. новембра 2024.*

