



УНИВЕРЗИТЕТ У КРАГУЈЕВЦУ
ФАКУЛТЕТ ТЕХНИЧКИХ НАУКА У ЧАЧКУ

Мр Бранка Б. Арсовић

**РАЗВОЈ АДАПТИВНОГ СИСТЕМА ЗА
ЕЛЕКТРОНСКО УЧЕЊЕ ЗАСНОВАНОГ
НА НАУЦИ О ПОДАЦИМА**

докторска дисертација

Чачак, 2021



UNIVERSITY OF KRAGUJEVAC
FACULTY OF TECHNICAL SCIENCES ČAČAK

MSc Branka B. Arsović

**DEVELOPMENT OF AN ADAPTIVE
E-LEARNING SYSTEM BASED ON DATA
SCIENCE**

Doctoral Dissertation

Čačak, 2021

Аутор
Име и презиме: Бранка Арсовић
Датум и место рођења: 4. август 1972. Ужице
Садашње запослење: Педагошки факултет Ужице, Универзитет у Крагујевцу, самостални стручно-технички сарадник за информационе системе и технологије
Докторска дисертација
Наслов: Развој адаптивног система за електронско учење заснованог на науци о подацима
Број страница: 203
Број слика: 76 слика + 101 табела
Број библиографских података: 178
Установа и место где је рад израђен: Факултет техничких наука у Чачку, Универзитет у Крагујевцу
Научна област (УДК): 37.018.043 (043.3)
Ментор: др Ненад Стефановић, ванредни професор, Факултет техничких наука у Чачку
Оцена и одбрана
Датум пријаве теме: 26.06.2019.
Број одлуке и датум прихватања теме докторске/уметничке дисертације:
Број: IV-04-987/13 Датум: 11.12.2019.
Комисија за оцену научне заснованости теме и испуњености услова кандидата:
1. др Божидар Раденковић, редовни професор, Факултет организационих наука у Београду, Универзитет у Београду
2. др Данијела Милошевић, редовни професор, Факултет техничких наука у Чачку, Универзитет у Крагујевцу
3. др Ненад Стефановић, ванредни професор, Факултет техничких наука у Чачку, Универзитет у Крагујевцу (ментор).
Комисија за оцену и одбрану докторске/уметничке дисертације:
1. др Божидар Раденковић, редовни професор, Факултет организационих наука у Београду, Универзитет у Београду
2. др Данијела Милошевић, редовни професор, Факултет техничких наука у Чачку, Универзитет у Крагујевцу
3. др Верица Милутиновић, доцент, Факултет педагошких наука Јагодина, Универзитет у Крагујевцу
Датум одбране дисертације:

Author
Name and surname: Branka Arsović
Date and place of birth: 4. august 1972. Užice
Current employment: Faculty of Education in Užice, University of Kragujevac, independent expert-technical associate for information systems and technologies
Doctoral Dissertation
Title: Development of an adaptive e-learning system based on data science
No. of pages: 203
No. of images: 76 Figures + 101 Table
No. of bibliographic data: 178
Institution and place of work: Faculty Of Technical Sciences Čačak, University of Kragujevac
Scientific area (UDK): 37.018.043 (043.3)
Mentor: Phd Nenad Stefanović, Associate Professor, Faculty of technical sciences Čačak, University of Kragujevac
Grade and Dissertation Defense
Topic Application Date: 26.06.2019.
Decision number and date of acceptance of the doctoral / artistic dissertation topic:
No: IV-04-987/13 Date: 11.12.2019.
Commission for evaluation of the scientific merit of the topic and the eligibility of the candidate:
<ol style="list-style-type: none"> 1. Božidar Radenković, PhD, full professor, Faculty of Organisational Sciences Belgrade, University of Belgrade 2. Danijela Milošević, PhD, full professor, Faculty of Technical Sciences Čačak, University of Kragujevac 3. Nenad Stefanović, PhD, Associate Professor, Faculty of Technical Sciences Čačak, University of Kragujevac (mentor).
Commission for evaluation and defense of doctoral / artistic dissertation:
<ol style="list-style-type: none"> 1. Božidar Radenković, PhD, full professor, Faculty of Organisational Sciences Belgrade, University of Belgrade 2. Danijela Milošević, PhD, full professor, Faculty of Technical Sciences Čačak, University of Kragujevac 3. Verica Milutinović, Phd, docent, Faculty of Education in Jagodina, University of Kragujevac
Date of Dissertation Defense:

РЕЗИМЕ

Учење је окосница савременог друштва, које је претрпело глобалне промене, у смислу дигитализације и употребе ИКТ. Намеће се питање е-учења, које је актуелизовано текућом пандемијом. Код е-учења је потребно осмислити и спровести у дело један спознајни процес усвајања нових појмова, савлађивања умећа примене стечених знања у реалном окружењу и постављања темеља за даље продубљивање знања из обрађене области. Увек актуелни проблем је прилагођавање процеса учења потребама ученика, тј. персонализација учења. Адаптивност учења је изазов који је пренет и на поље е-учења.

Области истраживања дисертације односе се на е-учење и науку о подацима. Предмет дисертације је развој и имплементација адаптивног управљачког система за е-учење и одговарајућих аналитичких модела науке о подацима ради ефикасног доношења оптималних одлука. Ово укључује дефинисање методологије у реализацији адаптивног LMS, као и сам његов развој. Задатак је сложен и мултидисциплинаран, јер укључује области попут система за управљање учењем, науке о подацима (Data Mining, складиштење и обраду података, статистичке методе, извештавање итд), интернет технологија, експертских система, као и дидактику и методике.

Настава путем развијеног и имплементираниог адаптивног модула е-учења је спроведена на Педагошком факултету Ужице, Универзитета у Крагујевцу. Резултати спроведеног експеримента су обрађени статистичким методама и применом модела Data Mining и науке о подацима. Развијени су и примењени статистички модели за анализу података и специјализовани Data Mining модели за интелигентну анализу података из система за е-учење, екстраховање знања и предвиђање. На тај начин је адаптивни систем за е-учење проширен модулом за Data Mining. Добијен је богат скуп информација који је показао оправданост примене адаптивног LMS-а.

Кључне речи: *e-Learning, LMS, адаптивни системи за електронско учење, стил учења, предзнање, наука о подацима, Data Mining, машинско учење.*

ABSTRACT

Learning is the backbone of modern society, which has undergone global changes, in terms of digitalization and the involvement of ICT. The issue of e-learning arises, which has become relevant due to the current pandemic. In e-learning, it is necessary to design and implement a cognitive process of acquiring new concepts, mastering skills of applying the acquired knowledge in a real environment and laying the foundations for further deepening of knowledge from the processed area. The always current problem is adaptation of the learning process to the needs of students, ie. personalization of learning. The adaptability of the learning is a challenge that has been transferred to the field of e-learning.

The research areas of this doctoral dissertation relate to e-learning and data science. The subject of the dissertation is the development and implementation of an adaptive learning management system for e-learning and appropriate analytical models of data science for efficient decision making. This includes defining the methodology in the implementation of adaptive LMS, as well as its development. The task is complex and multidisciplinary, as it includes areas such as learning management systems, data science (Data Mining, data storage and processing, statistical methods, reporting, etc.), internet technologies, expert systems, as well as didactics and teaching methods.

Teaching through the developed and implemented adaptive e-learning module was conducted at the Faculty of Education in Uzice, University of Kragujevac. The results of the conducted experiment were processed by statistical methods, Data Mining and data science methods. Statistical models for data analysis and specialized Data Mining models for intelligent data analysis from e-learning systems, knowledge extraction and prediction, have been developed and applied. In this way, the adaptive e-learning system has been extended with a module for Data Mining. A rich set of information was obtained, which showed the justification of the use of adaptive LMSs.

Key words: *e-Learning, LMS, adaptive e-learning systems, learning style, prior knowledge, data science, Data Mining, machine learning.*

САДРЖАЈ

1. УВОД	1
1.1 Предмет и циљ истраживања	1
1.2 Опис проблема	2
1.3 Хипотезе и коришћене методе	4
1.4 Преглед рада	5
1.5 Резултати и научни допринос	7
2. ПРЕГЛЕД И АНАЛИЗА САВРЕМЕНИХ МОДЕЛА И МЕТОДА Е-УЧЕЊА	9
2.1 E-learning – основни појмови	9
2.2 Web оријентисани образовни системи	19
2.3 Адаптивни e- Learning системи	20
2.4 Педагошке стратегије у адаптивном електронском учењу	23
2.5 Моделовање студента	31
2.6 Различити приступи персонализацији учења	33
2.7 Типови адаптивних образовних система	35
3. ПРЕГЛЕД РАЗЛИЧИТИХ ТИПОВА И МОДЕЛА АДАПТИВНИХ СИСТЕМА ЗА Е-УЧЕЊЕ И НАПРЕДНУ АНАЛИЗУ ПОДАТАКА	46
3.1 Креирање адаптивних образовних e-Learning система	46
3.2 Контрола и критеријуми квалитета	57
3.3 Општа архитектура адаптивног e-Learning LMS-a	62
3.4 Типови/модел адаптирања e-Learning образовних система	66
3.5 Адаптивни e-Learning LMS за студенте различитих нивоа знања	67
3.6 Адаптивни e-Learning LMS за студенте са различитим стиловима учења	71
3.7 Адаптирање e-Learning LMS путем креирања персонализоване повратне информације	78
3.8 Адаптирање e-Learning LMS путем персонализованог интерфејса	80
3.9 Методе и технике науке о подацима у e-Learning системима	85
4. МОДЕЛ АДАПТИВНОГ СИСТЕМА ЗА Е-УЧЕЊЕ	94

4.1	<i>Општа основна структура</i>	94
4.2	<i>Постојећа платформа – опште карактеристике и недостаци</i>	99
4.3	<i>Унапређења и видови персонализације постојећег LMS</i>	101
4.4	<i>Решење персонализације постојеће LMS платформе</i>	104
4.5	<i>Имплементација и тестирање персонализованог, адаптивног LMS</i>	107
5.	АНАЛИЗА И ДИСКУСИЈА РЕЗУЛТАТА	137
5.1	<i>Анализа резултата статистичким методама</i>	137
5.2	<i>Развој Data Mining модела за напредну анализу података</i>	167
6.	ЗАКЉУЧАК	189
	РЕФЕРЕНЦЕ	191

1. УВОД

1.1. Предмет и циљ истраживања

Образовни процес јесте један активан, динамичан процес, који се налази у сталном предефинисању, константним променама и унапређењима. Сва побољшања и измене образовно-наставног процеса имају заједнички крајњи циљ – побољшавање процеса учења и његово прилагођавање потребама ученика, у циљу што квалитетнијег и потпунијег стицања и усвајања знања. Унапређење образовања се креће ка креирању прилагодљивог, персонализованог образовног окружења, које би побољшало процес учења и подучавања. При том је апсолутно небитно да ли се мисли на класично, традиционално наставно окружење или окружење за е-Learning.

Креирање персонализованог образовног окружења, и у условима традиционалне наставе, је комплексан процес, а е-Learning окружење том задатку даје нову димензију и додатну тежину, као и изазове друге природе. Е-Learning окружење, које би било по мери ученика, персонализовано и адаптивно, би могло да унапреди учење и сам процес поучавања и образовања. Због комплексности процеса адаптивног е-образовања, код нас, до сада, није било много радова који су са методолошког аспекта, као и са аспекта саме изградње интегрисаног система електронског образовања, истраживали ову област. У том смислу, материја изложена у овом раду, има посебну вредност. Идеја, развијена и примењена у оквиру овог рада, је да се интеграцијом система за образовање на даљину, система за управљање знањем и система за мултимедијалну комуникацију, а пре свега персонализацијом процеса учења, може унапредити образовни процес.

Области истраживања ове докторске дисертације односе се на електронско учење и науку о подацима. Предмет ове докторске дисертације јесте развој и имплементација адаптивног управљачког система за електронско учење и одговарајућих аналитичких модела науке о подацима ради ефикасног доношења оптималних одлука. Ово укључује и дефинисање методологије у реализацији индивидуализованог/персонализованог адаптивног LMS (Learning Management System), као и сам његов развој.

Овај задатак је сложен и мултидисциплинаран, јер укључује области попут система за управљање учењем, науке о подацима (машинско учење - Data Mining, складиштење и обраду података, статистичке методе, извештавање, итд.), интернет технологија, експертних система, као и дидактику и методике.

Циљ је дефинисање методологије обједињене примене напредних информатичких технологија, традиционалних образовних теорија учења и актуелних трендова у области LMSs, које има за крајњи циљ унапређење наставног процеса, у смислу персонализације учења и образовања.

Примена предложене методологије омогућава унапређење образовно/наставног процеса, као и самог процеса учења, а из следећих разлога:

- напредно дизајниран и креиран LMS омогућава модернији приступ процесу наставе, како ученику/студенту, тако и наставнику/предавачу

- адаптиван LMS и интерактивне мултимедијалне технологије омогућавају персонализацију наставе и учења (што је основни приоритет и тежња сваког образовно/наставног процеса)
- рад са адаптивним LMS-ом омогућава ученику/студенту да његово учење не буде везано за место и време извођења наставе.

Интерактиван, визуелно побољшан и студенту прилагођен кориснички итерфејс, као и сами образовни садржаји изложени у образовном систему, омогућавају сваком од студената да учи у сопственом маниру, чиме се постиже ефикасније учење, стицање знања и мотивисање за даље напредовање у датој области.

Докторска дисертација систематизује актуелне домете у области примене савремених метода и технологија у домену адаптивних LMSs за електронско учење и дефинише методологију за креирање таквог система, која је унапређена у односу на постојеће. На основама ове технологије је изграђен софтвер који има практичну примену у одређеним образовним областима.

Циљ истраживања које је спроведено је имплементација адаптивних метода у електронском образовању, прилагођена примени у условима високошколског образовања у Србији. Истраживање представљено овом дисертацијом има за циљ да, посредством комбиновања више техника, а првенствено моделовањем корисника/студената на основу нивоа знања и по стиливима учења, као и помоћу система повратних информација (енгл. feedback), омогући наставницима и ауторима образовних садржаја бољи увид у процес учења који се одвија у виртуелним софтверским окружењима за учење и да тиме, посредно, створи боље услове за персонализовано учење у овим e-Learning окружењима. Генерисање повратних информација о релевантним аспектима процеса учења (тј. о начину коришћења образовних садржаја, о интеракцијама међу студентима, колаборативним активностима и сл.), засновано је на подацима о контексту едукативних објеката (енгл. Learning Object Context – LOC). LOC се односи на студента (или групу студената) који ступа у неки облик интеракције са (online) образовним садржајима, кроз одређену активности учења (нпр. читање, решавање тестова, четовање), и то ради остваривања одређеног циља. Смисао овог концепта је да се омогући апстракција релевантних аспеката сваке конкретне ситуације учења, односно, технички посматрано, циљ је омогућити апстракцију релевантних концепата из корисничких логова (енгл. user-tracking data) бројних e-Learning система.

Циљ спроведеног истраживања је дефинисање методолошког приступа креирању адаптивног, персонализованог образовног окружења у online наставним курсевима, као и проналажење прикладних начина развијања и имплементације адаптивних метода у електронском образовању, прилагођени примени у условима високошколског образовања у Србији. Кроз креирање и проблемску анализу конкретног модела и модула, кристализује се и дефинише поменута методологија креирања персонализованих образовних курсева.

1.2. Опис проблема

Континуирани раст интересовања за асихроно, тзв. „anywhere & anytime” учење, који је присутан током последњих неколико година, је имао за последицу интензиван раст популације која се окреће учењу посредством Интернета (првенствено WWW –

World Wide Web, краће – Web). При томе, дефинитивно највећи број корисника бележе Learning Management Systems (LMS), које данас користе на хиљаде институција широм света (Durak & Çankaya, 2019)

Шире посматрано, циклус учења путем Web-а (тј. Web апликација) започиње креирањем садржаја намењених учењу, за које се у литератури већ дуго низ година користи израз образовни објекти (енгл. *Learning Objects – LOs*) (Bártek & Nocar, 2016). У овој, почетној, фази процеса учења појављују се два кључна актера: аутори образовних садржаја и наставници. Аутори су најчешће обласни експерти, који креирају LOs из своје области експертизе и описују креиране LOs иницијалним скупом метаподатака. Наставници користе већ постојеће LOs, тј. уклапају их, уз потребне мање или веће модификације, у изабрани наставни план и на тај начин креирају материјале за учење (тј. лекције и курсеве). Међутим, врло често се дешава, да је аутор садржаја и наставник једна те иста особа, односно да је реч о две улоге које могу припадати истом појединцу. Након креирања образовних/наставних садржаја (тј. LOs), следи фаза креирања online курса, у оквиру које се LOs користе као градивне јединице за његово формирање. У том поступку, LOs се најчешће структурирају у складу са неким од званичних стандарда/спецификација за организовање и „паковање“ едукативних садржаја (као што је, на пример, Sharable Content Object Reference Model – SCORM) (Shen, 2018). Резултат је online курс представљен у форми тзв. content package-а који осим LOs које интегрише, садржи и формализован опис редоследа LOs који би требало следити при презентацији LOs студентима.

Овако припремљени курсеви су студентима на располагању најчешће посредством LMSs. Ови системи, не само да пружају студентима потребне садржаје за учење, већ интегришу и бројне сервисе који су студентима на располагању током учења, као подршка интерактивном учењу. Реч је о дискусионим форумима, собама за ћаскање, тестовима провере знања, дељеним (виртуелним) радним просторима (енгл. *shared whiteboards*), систему електронске поште путем кога се може обављати комуникација итд. На крају курса, од студената се најчешће тражи да изврше евалуацију курса попуњавањем упитника којим су обухваћени различити аспекти online курса који су похађали (на пример, квалитет садржаја, начин организације садржаја и сл). Повратне информације (енгл. *feedback*) би требало да помогну наставницима да унапреде садржај и начин реализације курса.

Овако добијене повратне информације (посредством поменутих упитника) дају неки општи увид у задовољство студената курсем, али ипак њима недостају детаљи који су неопходни уколико се стварно желе идентификовати (потенцијалне) слабе тачке online курса. Тако на пример, ови упитници не пружају информације које би указивале на конкретне делове садржаја курса који су студентима били тешки за разумевање, нити на могуће конкретне концепте обрађене области, које би требало додатно објаснити и/или илустровати примерима. Са друге стране, узроци проблема су најчешће условљени конкретном ситуацијом у којој се јављају, односно контекстом, и могу се идентификовати само уколико се прати процес учења студената и региструју релације између активности учења (нпр. читање, дискутовање), садржаја намењених учењу (LOs), резултата учења (нпр. остварених резултата на тестовима провере знања) и карактеристика самих студената. Поседовањем увида у релације тог типа, могуће је генерисати много корисније повратне информације. На пример, за студенте који су имали слабе резултате на тесту провере знања, могуће је идентификовати путање учења које су следили (тј. начин кретања кроз садржаје курса), да ли су и у којој мери учествовали у online дискусијама, да ли су и у којој мери поруке које су размењивали са другим студентима биле везане за сам курс,

и ако јесу, на које делове курса су се односиле (тј. лекције и/или концепте из обрађених области) и сл.

За очекивање је да савремени LMSs обезбеђују повратне информације релевантне и неопходне за адаптацију процеса online учења. Међутим, то није случај. Иако данашњи LMSs пружају углавном добру подршку за реализацију већине претходно описаних активности, подршка адаптацији процеса учења је прилично слабо реализована. Савремени LMSs углавном нуде само неке једноставније алате намењене едитовању садржаја/структуре online курсева. Међутим, да би се процес учења прилагодио потребама студената, неопходно је знати који аспект овог процеса би требало прилагодити (садржај или инструкциони приступ, или можда и једно и друго) и чему прилагодити (тј. потребан је увид у карактеристике конкретног контекста учења). То даље имплицира потребу за повратним информацијама, како о начину интеракције студената са садржајима курса, тако и о облицима и начину међусобних интеракција студената током учења. За разлику од традиционалног окружења за учење (тј. наставе у учионици) у којима наставници имају непосредни увид у то шта њихови студенти раде, и да ли им и у којој мери одговарају коришћени наставни садржаји и примењени наставни приступ, у виртуелном окружењу, наставници могу да се ослоне само на једноставне статистичке податке које им већина LMSs обезбеђује.

Због тога, један од циљева овог рада јесте да се посао наставника online курсева учини једноставнијим тиме што ће им се пружити релевантне повратне информације о активностима студената током процеса online учења и њиховој интеракцији са садржајима курса. На основу оваквих информација, наставници ће моћи једноставније да идентификују шта је то што треба модификовати (у садржају/организацији курса) и на који начин. Другим речима, повратне информације су ту да омогуће персонализацију процеса учења.

1.3. Хипотезе и коришћене методе

Разматрањем предложеног проблема и истакнутих циљева и предмета истраживања, искристалисале су се основне хипотезе од којих се полази:

X1 – Интеграцијом система за образовање на даљину, система за управљање знањем и система за мултимедијалну комуникацију, а пре свега, персонализацијом процеса учења, може се унапредити образовни процес.

X2 – Применом статистичких метода могуће је установити корелације у подацима, који указују на повезаност успешности постигнућа студената и персонализоване наставе путем адаптивног e-Learning курса.

X3 – Техникама напредне анализе података (Data Mining - machine learning) могу се открити нове и корисне информације које се могу употребити у процесу учења и реализације наставе.

X4 – Примена експертног система може да допринесе ефикаснијем и интелигентнијем доношењу одлука.

Приликом писања дисертације анализирана је расположива литература, па се у теоријском делу рада користите дескриптивне и компаративне методе, као и методе синтезе и анализе.

Подаци, потребни за спровођење планираног експеримента скупљени су методом анкете (анкета је потребна за одређивање стила учења студената и користи се FSLSM упитник, према коме се одређују стилови учења у е-образовању) и тестирања (у циљу одређивања нивоа предзнања студената из експериментом обухваћене теме, студенти су подвргнути тестирању и, сходно својим постигнућима, сврстани у једну од три категорије: почетник, просечни ниво, напредни ниво).

Резултати, добијени емпиријским истраживањем, су статистички обрађени у складу са прихваћеним статистичким методама. За опис узорка користи се дескриптивна статистичка анализа (аритметичка средина, медијана и стандардна девијација). А за обраду добијених података употребљене су следеће статистичке анализе:

- репрезентативна статистичка анализа (метода узорка): t – тест
- мултиваријабилна анализа: факторска анализа, метода главних компоненти
- регресиона анализа: линеарна регресија, бинарна логистичка регресија

Приликом обраде резултата је коришћен софтвер за статистичку обраду података IBM SPSS Statistic.

У циљу добијања више информација о ефектима адаптивног е-учења на преференце укључених студената, резултати спроведеног експеримента су обрађени методама машинског учења (Data Mining). Описивање класа и концепата подразумева карактеризацију циљних класа и поређење са супростављеним класама. Такође је урађена и асоцијативна анализа. Data Mining технике подразумевају: класификацију и регресију (конструкцију модела, презентацију модела – стабла одлучивања (Tree Structured Rules) и неуронске мреже, регресију – предвиђање бројних вредности); кластеризацију (груписање података у класе – Clustering, максимизација сличности унутар кластера и минимизација сличности ван кластера).

За поступке прикупљања, складиштења, обраде и извештавања коришћени су алати пословне интелигенције и науке о подацима. За организацију базе подата користи се OLAP технологија (за интерактивно аналитичко процесирање, као и за сакупљање, обраду, процесирање и презентацију вишедимензионалних података за потребе анализе и управљања одлукама).

1.4. Преглед рада

Рад се састоји из шест поглавља. Након уводног поглавља, у коме су предочени предмет истраживања и научни циљеви, опис проблема, као и полазне хипотезе и коришћене методе током израде рада и спровођења истраживања, следи део у коме је дат сажет преглед Web оријентисаних образовних система, е-Learning система и LMSs релевантних за истраживање презентовано у овом раду. Релевантна област истраживања представљена у овом поглављу је електронско учење, тачније савремени приступи, модели и оквири е-учења. Посебно је истакнута проблематика персонализације, тј. адаптивних образовних е-Learning система. Направљена је веза са педагошким стратегијама које подржавају адаптивно е-учење. Након тога су описани различити приступи персонализацији процеса учења, и то најпре класични приступи, реализовани у форми адаптивних едукативних хипермедијалних система (Adaptive Educational Hypermedia Systems - AEHS) и интелигентних тугорских система (Intelligent Tutors

Systems - ITS), а затим и модернији приступи засновани на интелигентним агентима и Web сервисима, као и хибридно учење. Поглавље се завршава представљањем концепта контекста који у последњем периоду побуђују интересовање и постају централна тема у бројним истраживачким областима. У овом прегледу представљени су различити приступи моделовању контекста.

Трећи део рада је посвећен прегледу развоја различитих типова и модела адаптивних система за управљање процесом учења (LMS). Разматрају се техничке карактеристике, као и начини креирања адаптивних LMSs. Истакнута је важност увођења метода и техника науке о подацима (енг. Data science) у област адаптивних LMS, са посебним освртом на машинско учење (енг. Machine learning) и Data Mining, као и образовни Data Mining (EDM). Представљене су методе и алати контроле квалитета, као и критеријуми које један овакав систем треба да испуњава. Размотрени су различити приступи персонализацији, са различитих аспеката и дата је општа архитектура адаптивног LMS-а.

Четврти део чини детаљан опис проблема истраживања (различити типови и начини персонализације система за учење), представљени су недостаци постојећих приступа његовом решавању и описано је решење које се предлаже у овом раду. На основу анализе постојећих система за учење и њихових уочених недостатака, осмишљен је и развијен модел за е-учење. Развијени модел, као решење за персонализоване, адаптивне LMS, је описан кроз своје карактеристике, могућности, као и кроз расположиве алате за његово креирање. Изнети су детаљи имплементације модела за унапређивање персонализације постојећег LMSs: описани су софтверски алати и архитектуре, коришћени при имплементацији; дати су примери који илуструју примену ових технологија у циљу реализације неких специфичних функција реализованог софтверског решења. Описана је реализована студија са циљем евалуације предложене методологије за креирање модела за персонализацију адаптивних online курсева, као практичне реализације тог приступа. Наредну тему овог поглавља представљају неке додатне могућности примене развијеног framework-а модела.

Пето поглавље представља опис спроведене валидације креираног адаптивног LMS (кроз спроведени експеримент), формирања базе података, а затим следи детаљно представљање резултата до којих се дошло. Подаци добијени на основу спроведеног експеримента и примене развијеног модела и система за адаптивно е-учење, обрађени су и анализирани различитим техникама науке о подацима. Рађено је више врста обраде и анализа подата, у циљу проналажења што већег броја резултата. Користи се дескриптивна статистичка анализа за опис узорка, док се за обраду добијених података употребљавају статистичке анализе: репрезентативна статистичка анализа, мултиваријабилна анализа, регресиона анализа: линеарна регресија, бинарна логистичка регресија и анализа варијансе – ANOVA.

У циљу добијања додатних информација и генерисања нових знања, као и добијања више података о ефектима адаптивног е-учења и примене развијеног модела, развијени су прилагођени Data Mining модели, који подразумевају: класификацију и регресију (конструкцију модела, презентацију модела – стабла одлучивања и неуронске мреже, регресију – предвиђање бројних вредности); кластер анализу (груписање података у класе). Представљено је ново знање ових модела, које се може користити за унапређење процеса учења и ефектније и ефикасније доношење одлука.

У последњем делу дисертације направљен је критички осврт на рад, издвојени су теоријски и практични доприноси рада, анализирани су могућности практичне примене

развијеног софтверског решења и на крају су представљени планирани правци даљег развоја и истраживања.

1.5. Резултати и научни допринос

Предмет дисертације припада актуелним областима истраживања у е-образовању и науци о подацима. Велики број научних и стручних часописа, конференција, књига, Интернет ресурса и велика заинтересованост универзитета, школа и компанија, иду у прилог актуелности теме докторске дисертације.

Као продукт научно-истраживачког рада, искристалисало се више општих, стручних, практичних и научних резултата и доприноса:

- прикупљање, систематизација и критичка анализа постојећих решења, знања, искустава и научних резултата који се односе на области електронског учења, као и педагошких, дидактичких и методичких приступа;
- прикупљање, систематизација и критичка анализа постојећих решења, знања, искустава и научних резултата који се односе на области примене метода, техника и алата науке о подацима у образовању (складишта података, OLAP (On-line Analytical Processing), Data Mining/Machine Learning, EDM (Educational Data Mining), система за учења на даљину (Distance Learning System, DLS) и система за управљање знањем (Learning Management Systems – LMS).
- дефинисање и формална спецификација скупа образовних и ICT метода за реализацију адаптивног система за е-учење.
- дефинисање и развој модела, који представља основ структуре адаптивног система за е-учење;
- развој и имплементација модела за адаптивно е-учење кроз интеграцију подсистема за образовање на даљину, подсистема за управљање знањем, подсистема за мултимедијалну комуникацију и експертног подсистема за персонализацију наставе;
- Изградња експертног подсистема за персонализацију наставе који укључује различите елементе: наставне садржаје, методе учења, стилове учења, претходна знања, ангажоване ресурсе, ефикасност, мерење успеха, откривање утицајних фактора, предвиђања успеха на нивоу сваког ученика.
- Развој и примена статистичких модела за анализу података.
- Дизајн и имплементација специјализованих Data Mining (Machine Learning) модела и апликација за интелигентну анализу података из система за е-учење, екстраховање знања и предвиђање.

Научни допринос овог рада јесте дефинисање и формална спецификација скупа образовних и ICT (енг. Information Communication Technology, информационо комуникационе технологије) метода за реализацију адаптивног е-Learning система, као и формирање потпуне методологије рада. Имплементацијом скупа метода адаптивности, образовни процес постаје флексибилнији и ефикаснији, а самим тим су трошкови увођења адаптивног електронског образовања оправдани.

Идеја, развијена у оквиру ове дисертације је да се применом концепата адаптивности у електронском образовању може побољшати ефикасност наставног процеса, а кроз реализацију система за персонализовано учење, као и ефикасност система за e-Learning у целини. У експерименталном делу је организован адаптивни курс за персонализовано електронско учење коришћењем LMS система, а извршено је прилагођавање LMS-а у области методологије. Предложени модел подржава адаптивност и у исто време одржава једноставност процеса вођења курса.

2. ПРЕГЛЕД И АНАЛИЗА САВРЕМЕНИХ МОДЕЛА И МЕТОДА Е-УЧЕЊА

2.1. E-Learning – основни појмови

Термин *e-Learning* потиче од назива електронско учење и често се користи као други назив за *web* оријентисано учење, *online* учење или учење на даљину. Међутим, постоје разлике у значењу ових термина, па се због тога не могу користити као синоними.

У литератури се могу наћи ставови да *e-Learning* представља само један део процеса учења и да се, као електронско учење, мора допунити и проширити са *e-Teaching* (електронско подучавање, *e*-подучавање), а такав целокупан процес се назива *e-образовање* (енгл. *e-Education*) (Rodrigues, Almeida, Figueiredo & Lopes, 2019). Међутим, уобичајено значење термина *e-Learning* укључује целокупан процес (и *e*-учење и *e*-подучавање), па ће се за потребе овог рада користити појам *e-Learning*.

У досадашњим истраживања и литератури се *e-Learning*, углавном повезује са активностима које укључују употребу рачунара и интерактивне симулације на мрежи, другим речима *e-Learning* подразумева коришћење рачунара у образовне сврхе (Kumar Basak, Wotto & Belanger, 2018). У односу на *web* оријентисано учење, које се ограничава на доставу и пружање образовних садржаја путем *WWW*, *e-Learning* не спецификује метод преноса података и садржаја. *Online* учење је повезано са доступним образовним материјалима у информатичко-рачунарском окружењу, али не подразумева нити захтева мрежу. Учење на даљину је старији појам и уопште не мора подразумевати коришћење рачунара или мреже.

Овај рад се односи на област електронског образовања са употребом расположивих, актуелних информатичко-рачунарских технологија, па ће се у даљем раду користити термин *e-Learning*.

Електронско учење (*e-Learning*, *e*-учење) у савременом друштву, представља значајну област, како са аспекта образовних институција, тако и са аспекта привреде и пословних организација. Све већи број пословних организација прихвата *e-Learning* као основну стратегију повећања свог интелектуалног капитала (Stojanović, Staab, & Studer, 2001). Успех неке организације у економији 21. века у значајној мери зависи од тога колико је сама организација способна да креира и непрекидно развија пословне компетенције запослених и да то чини правовремено, кроз добро осмишљен систем образовања и тренинга расположивих у правом тренутку.

Са аспекта образовних институција *e-Learning* представља значајну иновацију, јер знатно олакшава размену образовних ресурса међу компетентним образовним институцијама и појединцима; омогућава целоживотно и стално усавршавање ученика/студената у много једноставнијој и прихватљивијој форми; у свакодневном наставном процесу омогућава самосталан рад ученика/студената, тако да подржава асинхронно, персонализовано учење; знатно смањује трошкове креирања образовних материјала (због могућности виšekратне употребе једном креираних материјала за *e-Learning* и њихове размене између институција) (Арсовић, 2017).

E-learning се базира на принципима често различитим, па и директно супростављеним принципима на којима је утемељен конвенционални приступ учењу.

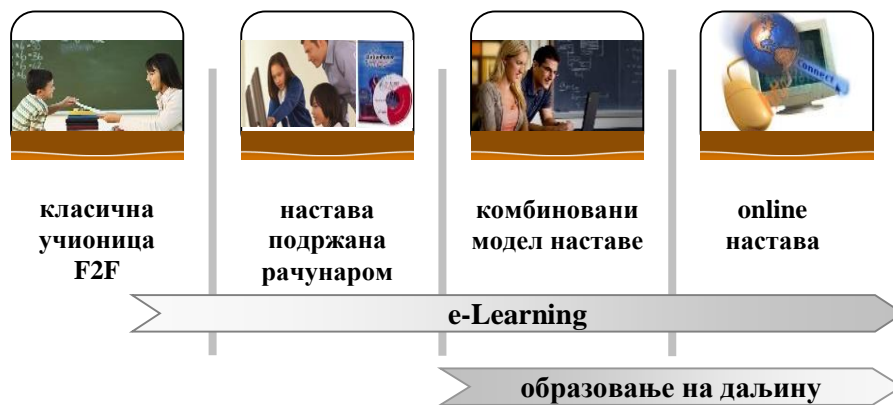
Супростављеност основних принципа традиционалне наставе и е-Learninga се најбоље илуструје следећом табелом (Tawafak, AlSideir, Alfarsi, Al-Nuaimi, Malik & Jabbar, 2019):

Табела 1: Традиционална настава V.S. eLearning

Традиционална настава	Електронско образовање eLearning
Централизација ауторитета <i>садржаји који ће бити предмет учења искључиво одређује наставник</i>	Дистрибуција ауторитета <i>садржаји који ће бити предмет учења се дефинишу кроз интеракцију ученика и наставника</i>
Пренос знања– push принцип <i>наставник у потпуности дефинише план и начин рада; едукативни садржаји се намећу студентима</i>	Пренос знања– pull принцип <i>ученици одређују начин и темпо рада</i>
“One size fits all” <i>образовни садржаји се конципирају тако да одговарају свима, без персонализације</i>	Персонализовани садржаји <i>садржаји се обликују према индивидуалним потребама сваког појединачног ученика</i>
Линеарни приступ садржајима <i>постоји унапред дефинисан начин стицања нових знања, односно редослед приступа образовним садржајима који се мора поштовати</i>	Нелинеарни приступ <i>омогућен је директан приступ едукативним садржајима у било ком редоследу који је у складу са потребама тренутне ситуације</i>
Асиметричност <i>образовање и/или тренинг, дрил се доживљавају као засебне активности, потпуно одвојене од редовних пословних обавеза</i>	Симетричност <i>учење је интегрисано у свакодневне пословне активности</i>
Дискретност у времену <i>образовање/тренинг се одвијају у јасно дефинисаним временским интервалима, са прецизно одређеним терминима почетка и завршетка</i>	Континуираност у времену <i>учење као непрекидан процес који се никада не завршава</i>
Линеарност – статичност <i>садржаји намењени учењу и редослед њиховог презентовања се не мењају током времена, већ задржавају своју оригиналну форму без обзира на промене у окружењу</i>	Нелинеарност – динамичност <i>садржаји намењени учењу се мењају у складу са новим искуствима, трендовима, пословним правилима и сл.</i>

Према Гилберту (Gilbert, 2015) е-Learning подразумева учење ослобођено временских и просторних баријера, иприлагођено потребама појединаца и организација.

Проширена класификација е-образовања приказује га као целовит, непрекидни процес (слика 1) који почиње од класичне или традиционалне наставе (F2F – Face-to-Face предавања), преко наставе подржане ICT, хибридне наставе и коначно online наставе.



Слика 1: Развој и врсте е-образовања

Образовни објекти

Једну од централних тема у области е-учења представљају образовни објекти (енгл. *Learning Object – LO*). Иако се у литератури срећу различите дефиниције појма LO, већина аутора ове области је прихватила дефиницију LO дату IEEE LOM стандардом: “LO је било који ентитет, дигитални или недигитални, који се може користити (једном или више пута) или референцирати током технолошки подржаног процеса учења”, (Duval, 2002; Bártek & Nocar, 2016). Иако ова дефиниција оставља могућност да се и недигитални образовни садржаји сматрају LO, у литератури се LO помињу искључиво у форми дигиталних ресурса, као што су online туторијали, курсеви, презентације, тестови, квизови и сл. Они најчешће садрже мултимедијалне елементе (слике, анимације, аудио и видео записе...), па и комплетне електронске књиге.

Једна од карактеристика LO, на коју указује претходно наведена дефиниција, а коју и сви релевантни аутори (Bártek & Nocar, 2016; Stojanović, Staab & Studer, 2001; Rimale, Benlahmar & Tragha, 2017) истичу као кључну, најбоље описује енглески термин *reusability* (вишекратност), односно могућност вишеструког коришћења једном креираног образовног садржаја. Важност ове карактеристике LO се једноставно објашњава чињеницом да је, с једне стране, за креирање квалитетних образовних садржаја потребно уложити доста времена и новца, а са друге стране, да су садржаји намењени образовању, у сродним организацијама и областима често веома слични. Уколико би се једном креирани образовни садржаји могли користити више пута у оквиру исте организације или, што је још значајније, и у другим сродним организацијама, то би водило значајним уштедама ресурса, јер би се тада трошкови развоја LO могли делити међу свим заинтересованим странама (Salas, 2020). Такав приступ би омогућио брже и јефтиније креирање квалитетнијих садржаја намењених учењу.

Репозиторијуми образовних објеката

Да би се омогућило поновно коришћење LOs посредством Web-a, LOs се морају на изванредан начин учинити доступним потенцијалним корисницима. То јест, морају постојати механизми који ће корисницима омогућити проналажење, приступ и (поновно) коришћење LOs расположивих на Web-у. Иако постоје различити приступи решавању овог проблема, свима је заједничко базирање на некој форми репозиторијума који ће LOs приближити корисницима. На концептуалном нивоу, можемо говорити о три основна облика репозиторијума LOs (Rimale, Benlahmar & Tragha, 2017):

- глобални репозиторијуми чувају само референце на образовне ресурсе који су физички ускладиштени на некој другој локацији на мрежи. Ови репозиторијуми се могу посматрати као глобални каталози LO. Најпознатији међу њима су: TeleCampus, Multimedia Educational Resource for Learning and Online Teaching –MERLOT и ARIADNE.
- други начин да се LO учини јавно доступним, заснива се на коришћењу брокерских сервиса. На пример, Universal Brokerage Platform (UBP) обезбеђује широк спектар сервиса везаних за приступ и коришћење LO. UBP функционише по принципу пријема „наруџбина“, у форми описа карактеристика потребних LO, од стране заинтересованих корисника. Чим се LO, који одговара траженом опису, појави у репозиторијуму, UBP обавештава корисника о томе да је захтевани LO доступан. Специфичност ових сервиса је у томе што кроз систем наручивања LO, омогућују заштиту права интелектуалне својине и регулисање плаћања приступа LO-у.
- Peer-to-Peer (P2P) мреже представљају трећи типичан систем који омогућује складиштење/размену/приступ образовних садржаја. Специфичност овог система је то што се једно исто лице (физичко или правно) врло често јавља и у улози креатора и корисника образовних садржаја, што у два претходно описана приступа није случај. Једна мрежа овог типа развијена је у оквиру EDUTELLA пројекта (Nejdl, 2002). Специфичност EDUTELLA P2P мреже је то што, коришћењем технологија Семантичког Web-а, омогућује размену LO чак и између хетерогених чворова у мрежи, односно чворова који користе различите типове репозиторијума и/или користе различите схеме за означавање LO-а метаподацима.

Стандардизација у електронском учењу

У области е-учења развијено је више типова спецификација/стандарда, међу којима су, можда најважнији, стандарди који се односе на:

- метаподатке намењене описивању LOs (metadata standards) – основни смисао стандарда овог типа је да се кроз јединствени скуп метаподатака којима се описују LOs (у репозиторијумима LOs) омогући ефикасније и ефективније претраживање репозиторијума LOs и проналажење/приступ релевантим LOs;
- структурирање и агрегацију LOs (packaging standards) – ови стандарди регулишу начин структурирања комплексних јединица образовних садржаја (енгл. content packages), као што су лекције и курсеви, полазећи од образовних ресурса (LOs) нижег нивоа гранулације; овако креирани ‘пакети’ образовних садржаја могу бити коришћени у различитим е-learning системима развијеним у складу са стандардима;
- моделовање информација о студентима (learner information standards) – идеја је да се омогући размена информација о студентима између различитих е-Learning апликација;
- приступ образовним садржајима и сервисима (communication standards) – ова група стандарда дефинише начин (протокол) на који студенти приступају различитим образовним садржајима и сервисима;
- регулисање квалитета LOs (quality standards) (Devedžić, 2006).

У свакој од поменутих категорија развијен је већи број стандарда/спецификација. У тексту који следи биће укратко објашњени само они који су релевантни за предмет истраживања овог рада.

Dublin Core Metadata Schema

Једна од најпознатијих схема метаподатака намењених опису Web ресурса је Dublin Core Metadata Schema. Ова схема дефинише петнаест основних елемената за опис Web ресурса, међу којима су: наслов (*title*), аутор (*author/creator*), издавач (*publisher*), опис (*description*) и сл. (Васа, 2017). Основна идеја је да се дефинише минимални скуп дескриптивних елемената који ће омогућити једноставно описивање и аутоматско индексирање докумената који циркулишу Интернетом. Осим тога, Dublin Core скуп метаподатака је осмишљен тако да буде довољно једноставан да га могу разумети и користити сви аутори који имају потребу да своје садржаје публикују на Web-у. Ова схема се у великој мери користи и за анотацију LOs.

IEEE Learning Object Metadata стандард

IEEE Learning Object Metadata (LOM) стандард представља први акредитовани стандард у области образовних технологија. Овај стандард дефинише скуп елемената (метаподатака) намењених опису LOs. LOM схема проширује Dublin Core Metadata Schema-у елементима и атрибутима прилагођеним специфичним потребама ученика и наставника који претражују Web у потрази за релевантним едукативним садржајима. LOM стандард групише елементе за описивање LOs у девет категорија у складу са њиховом наменом:

- категорија општих, контекстно независних елемената (*general category*) – групише елементе којима се описују карактеристике LO које не зависе од конкретног контекста примене LO. Овој категорији припадају елементи као што су: јединствени идентификатор, наслов, језик, кључне речи и сл.
- категорија животног циклуса (*lifecycle category*) – групише карактеристике LO релевантне са аспекта описа његовог животног циклуса. Ту спадају елементи попут: верзија, статус, и сл.
- категорија мета-метаподатака (*meta-metadata category*) – групише елементе којима се описују метаподаци LO, односно подаци којима је аотиран LO. Елементима ове категорије бележе се подаци о: коришћеној схеми метаподатака, особи која је урадила анотацију и/или валидацију метаподатака и сл.
- категорија техничких карактеристика (*technical category*) – садржи елементе којима се описују основне особине LO са чисто техничког аспекта. Неки од елемената ове категорије су: формат, трајање, величина, специфични захтеви инсталације и сл.
- категорија едукативних карактеристика (*educational category*) – групише елементе намењене опису едукативних/педагошких карактеристика LO. Елементима из ове категорије описује се, на пример, узраст ученика којима је конкретни LO намењен, тежина садржаја LO-а, захтевани степен интеракције ученика и LO-а, семантичка густина LO, односно његова користност у поређењу са величином и дужином трајања и сл.

- категорија права приступа (rights category) – обухвата елементе намењене дефинисању права приступа LO-а, како би се обезбедила заштита права интелектуалне својине.
- категорија релација са другим LO (relation category) – дефинише елементе којима се описују релације конкретног LO са другим LO. Релације могу бити различитог типа и указивати да је текући LO део неког другог LO, или да садржи неки други LO, или да је нова верзија/формат неког другог LO и сл.
- категорија означавања (annotation category) – групише елементе који омогућују бележење коментара о искуствима стеченим применом конкретног LO у образовној пракси.
- категорија класификације (classification category) – групише метаподатке којима се описује позиција LO у односу на неке постојеће класификационе системе (Furner, 2020).

За одређени скуп елемената LOM схеме, стандард предвиђа доделу вредности у форми слободног текста, док се за остале елементе захтева коришћење искључиво вредности из стандардом предефинисаног скупа вредности (вокабулара) за тај елемент.

Основна идеја LOM стандарда била је да се пронађе најмањи заједнички садржалац потреба апликација из различитих области компјутерски-подржаног учења и да се на основу тога креира стандард који ће подмирити идентификовани скуп потреба. Од овог стандарда се не може очекивати да подржи сваки elearning сценарио, јер за то није ни намењен. Све категорије метаподатака су опционе, и корисницима је остављена могућност проширења основне схеме у складу са својим специфичним потребама. LOM је замишљен да буде заједничка полазна основа за означавање образовних садржаја метаподацима, која ће омогућити размену и поновно коришћење тих садржаја (Bakhoui, Dehbi, Talea & Hajoui, 2017).

IMS Learning Resource Metadata спецификација креирана је са циљем унапређења IEEE LOM стандарда. Ова спецификација полази од IEEE LOM стандарда и уводи само неколико мањих измена у постојећи стандард. Тренутно је актуелна иницијатива за повезивање Dublin Core Metadata Schema и IEEE LOM стандарда, тј. за креирање обједињеног модела метаподатака. Ова иницијатива се реализује у оквиру Joint DCMI/IEEE LTSC Taskforce.

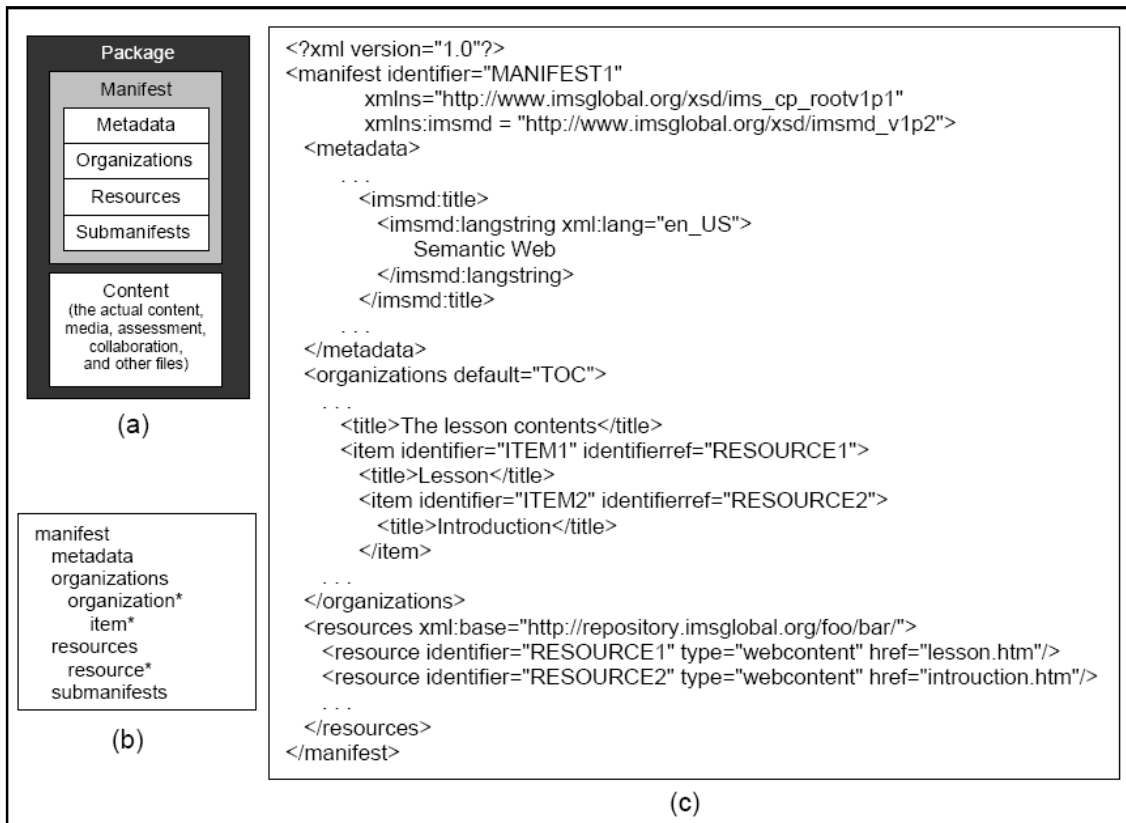
Међутим, иако су стандарди расположиви, мали је број организација које се њих стриктно придржавају. Већина организација креира свој IEEE LOM или IMS LRM апликациони профил, односно делимично се ослања на постојеће стандарде, а делимично уводи сопствене елементе и категорије, што има за последицу нижи степен интероперабилности хетерогених апликација. Осим тога, типична ситуација је да различите организације користе термине из различитих вокабулара при додели вредности елементима прописаним стандардом, што додатно угрожава интероперабилност. Генерално се може рећи да постојећим стандардима у домену метаподатака недостаје формална семантика (Bakhoui, Dehbi, Talea & Hajoui, 2017; Stojanović, Staab & Studer, 2001). Иако ови стандарди омогућују интероперабилност на нивоу једног домена (организације, система), они нису у стању да реше проблем неконзистентних схема и/или вокабулара у различитим и хетерогеним организацијама (системима).

IMS Content Packaging

Instructional Management System (IMS) Global Learning Consortium, једна је од најнапреднијих група у области развоја спецификација намењених остваривању интероперабилности образовних технологија. Један од њених производа је и Content Packaging спецификација (IMS CP, 2004) намењена дефинисању јединственог (мета) модела структуре образовних садржаја посредством кога би се омогућила размена ових садржаја између хетерогених (e-Learning) система. IMS CP је типичан пример стандарда/спецификација који се односе на структурирање и агрегацију LOs (*packaging standards*).

IMS CP спецификација дефинише општи модел структурирања садржаја LOs (тзв. *information model*). Основни елементи овог модела приказани су на слици 2(a). Као што слика указује, према IMS CP спецификацији, LO се на концептуалном нивоу може посматрати као један пакет који садржи различите образовне ресурсе и једну манифест датотеку која описује како би те ресурсе требало организовати у једну јединствену целину. Основна структура манифеста дата је на слици 2(b). Манифест датотека је један XML фајл тачно прописане структуре који се састоји из више секција од којих су неке обавезне док су друге опционе. Обавезна *resources* секција садржи референце на све ресурсе који би требало да сачињавају LO. Ови ресурси могу бити физички лоцирани у оквиру пакета (у том случају је референца практично релативна путања до одговарајућег ресурса у оквиру пакета), али исто тако могу бити и дистрибуиран (референца је тада URL локација на којој је дистрибуиран ресурс расположив). Опциона *metadata* секција описује LO (тј. пакет) као целину и најчешће користи метаподатке прописане IEEE LOM стандардом (наслов, опис, кључне речи и сл). Обавезна *organizations* секција декларише један или више различитих начина структурирања садржаја LO-а. Уствари, њоме се дефинишу алтернативни начини организовања ресурса које пакет садржи. Свака од ових алтернативних структура представљена је једном *organization* секцијом. Опциона *submanifests* секција намењена је креирању хијерархијски угњеждених пакета. Она практично омогућује креирање модуларних LOs (Ochoa & Ternier, 2017).

IMS CP дефинише и XML Schema намењену XML серијализацији описаног модела структуре LOs. На слици 2(c) приказан је сегмент манифест датотеке једног LO.



Слика 2: IMS CP спецификација

IMS Learning Design

IMS Learning Design (IMS LD) спецификација намењена је дефинисању инструкционог дизајна образовних садржаја. Инструкциони дизајн се односи на идентификовање неопходних активности и придруживање образовних садржаја тим активностима са циљем достизања задатих циљева учења (Koper & Olivier, 2004). IMS LD спецификација омогућује представљање великог броја разноврсних педагошких приступа као и развој нових, на пример, комбиновањем елемената постојећих педагошких приступа. У ствари, IMS LD се може сматрати метамоделом који, кроз релативно мали скуп елемената које дефинише, омогућује моделовање било ког инструкционог приступа. Овакве могућности ове спецификације произилазе из чињенице да је IMS LD развијен на основу дугогодишњег рада Роб Копера и његових сарадника на развоју Educational Modelling Languages (EML) (Koper & Olivier, 2004; Ouadoud, Chafiq, Rida & Chkouri, 2019).

Користећи метафору позоришта, IMS LD описује један инструкциони дизајн као једну позоришну представу која се састоји из више чинова, и у којој има више учесника који се појављују у различитим улогама. Конкретно, IMS LD спецификација уводи *Method* концепт који је аналоган концепту позоришне представе. Као што свака представа има више извођења, тако и један *Method* може имати више инстанци *Play* концепта, по један за свако извођење (слика 3). Даље, већина позоришних представа састоји се из више чинова – аналогно томе један *Play* у IMS LD се састоји из више инстанци *Act* концепта. Свака представа подразумева учешће једног или више актера који се појављују у различитим улогама – аналогно томе, IMS LD уводи концепте *Role* и *Role-Play*, где *Role* дефинише саму улогу, а *Role-Play* њене активности у датом извођењу инструкционог ди-

зајна. Као што се у једној представи, у различитим чиновима и/или сценама, исти појединац може појављивати у различитим улогама, тако се и у инструкционом дизајну једном појединцу могу придружити различите *Role* и *Role-Play*.

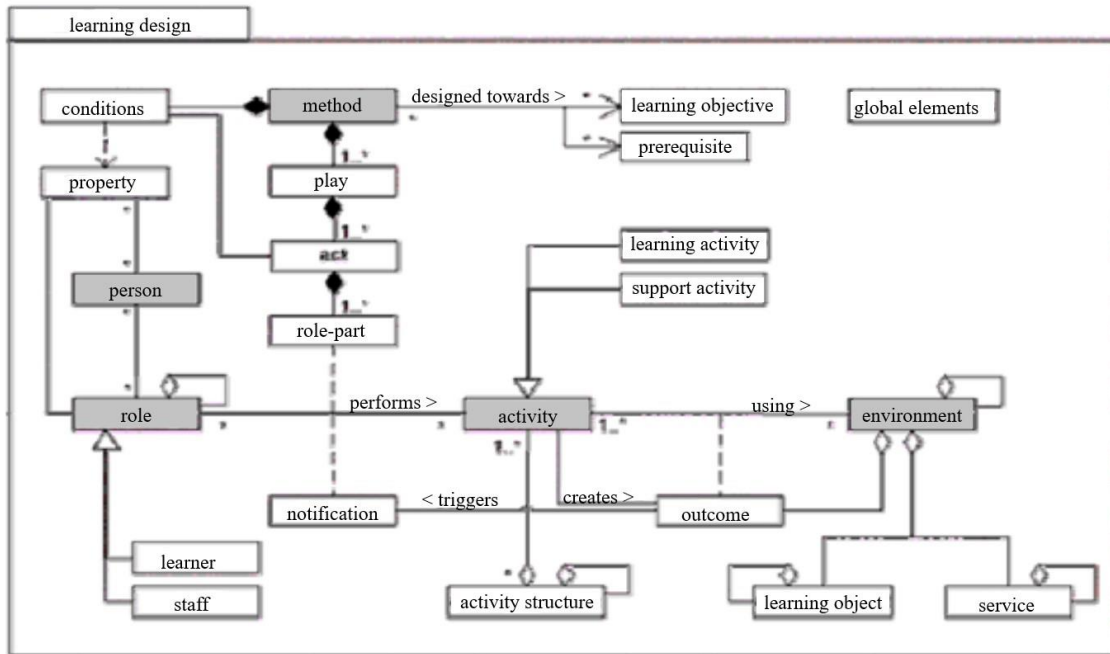
Сумирајући претходно речено, може се закључити да у контексту наставе/учења, *Method* садржи један или више конкурентних *Plays*, који се могу посматрати као начини извођења (енгл. *runscript*) курса/модула; један *Play* се састоји из једног или више *Acts*, при чему сваки се сваки односи на једну целину курса/модула; сваки *Act* се састоји из једне или више (конкурентних) *Role-Parts* које представљају асоцијацију улоге (*Role*) и активности (*Activity*).

Активност (*Activity*) се односи на операције или задатке које би требало да обави носилац одређене улоге (*Role*), користећи ресурсе (LOs и сервисе) расположиве у датом окружењу (*Environment*). Активности су класификоване на активности учења (*Learning activity*) и активности подршке (*Support activity*) и могу бити груписане у *Activity-structures*. Једна *Activity-structure* интегрише скуп повезаних активности, тј. активности које чине једну логичку целину, и које се могу придружити некој улози (*Role*) у оквиру *Role-Part*. Активности у оквиру *Activity-structure* могу бити повезане секвенцијално или у паралели. Све активности се реализују у датом окружењу (*Environment*) које интегрише LOs, сервисе и хардверске ресурсе. Свакој активности се може придружити предуслов (*Prerequisite*) за њену реализацију (на пример, потребно предзнање), као и циљ учења (*Learning objective*) који се односи на очекиване резултате студента.

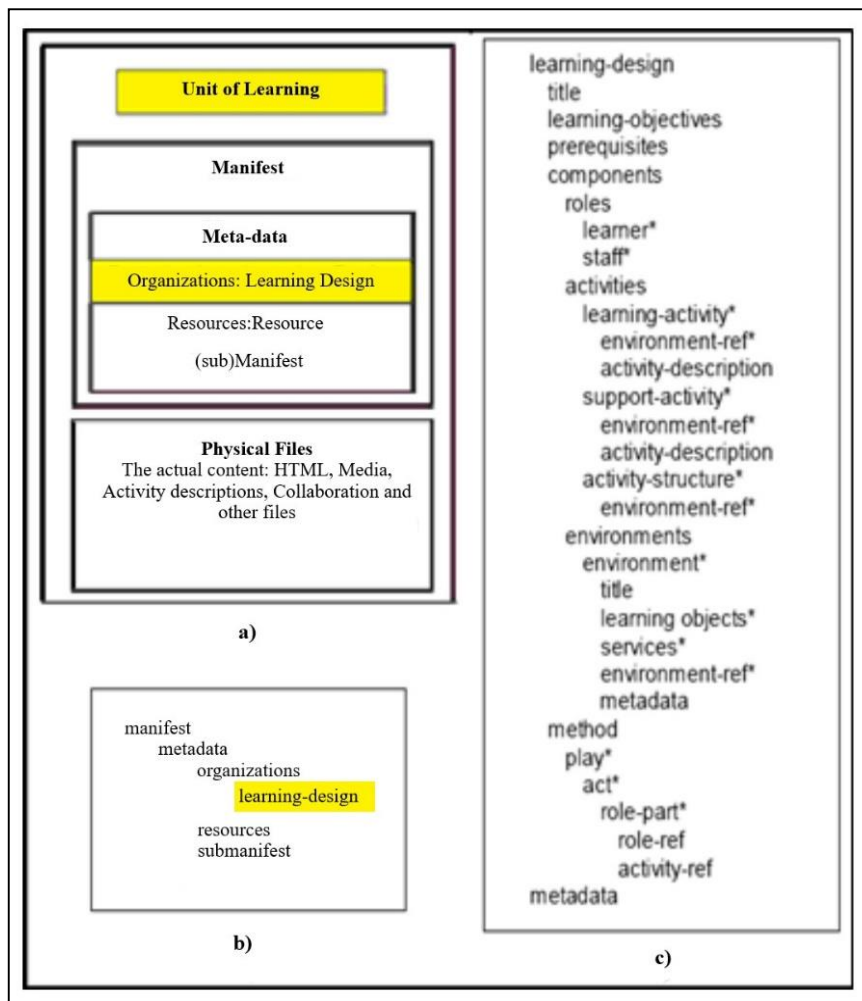
Сви претходно описани концепти чине ‘први ниво’ спецификације, односно IMS LD Level A. IMS LD уводи концепт *Properties* како би подржао персонализацију инструкционог дизајна. Пример једног *property*-а би био стил учења студента који се чува у оквиру досијеа студента (*Dossier*). Неки инструкциони планови подразумевају условно извршавање одређених активности, на пример, “уколико је преферирани стил учења студента неки стил X, онда би студент требало да изврши активност Z уместо активности Y”. За представљање услова овог и сличних типова, IMS LD уводи концепт *Condition*. Када се овај концепт и концепт *Properties* додају на претходно описани скуп концепата долази се до следећег нивоа спецификације – IMS LD Level B.

Активност може генерисати обавештење (*Notification*), што даље може условити, на пример, додељивање неке нове активности одређеној улози. Овај механизам се може користити за креирање адаптивних сценарија.

Проширивањем претходно описаног скупа концепата овим концептом, долазимо до највишег нивоа IMS LD спецификације – IMS LD Level C. Модел са слике 3 указује да су компоненте, циљеви/предуслови и ресурси независни од инструкционог дизајна. То даље значи да се они могу користити у многим различитим инструкционим плановима. С друге стране, метод је композитном везом повезан са инструкционим дизајном што указује да је он саставни део дизајна и не може постојати независно, као и да се не може (једноставно) поново применити у другим инструкционим дизајнима.



Слика 3: Концептуални модел IMS LD спецификације; функционалне зависности концепата намењених опису инструкционог дизајна



Слика 4: IMS LD спецификација

IMS LD спецификација се условно може схватити као проширење IMS CP спецификације педагошким елементима (тј. елементима намењеним опису инструкционог приступа). Као што је то на сликама 4(a) и 4(b) приказано, инструкциони дизајн се интегрише у IMS CP пакет кроз *Organizations* секцију манифест фајла. IMS LD спецификација дефинише XML Schema намењену XML серијализацији инструкционог дизајна дефинисаног у складу са овом спецификацијом. Слика 4c приказује структуру XML документа дефинисаног у складу са овом схемом. Примери инструкционих приступа дефинисаних у складу са IMS LD спецификацијом и њихова серијализација у XML формат, расположиви су на Web-у (IMS LD, 2003).

2.2. Web оријентисани образовни системи

Web оријентисани образовни системи су променили парадигму самог система и процеса образовања/учења. Учинили су учење/предавање независним од времена и места, а образовни материјали и информације, смештене и чуване на једном месту, доступне су на глобалном нивоу, у било које доба. Када говоримо о Web оријентисаним образовним системима, уствари разматрамо различите апликације, које интегришу бројне алате, чиме је омогућено учење на мрежи. Овакви системи омогућавају потпуно управљање целокупним процесом учења/предавања – од креирања потребних материјала, преко њиховог представљања и презентовања студентима, до провере стечених знања и оцењивања.

Може се рећи да су Learning Management Systems (LMSs) Web апликације које интегришу различите софтверске алате намењене електронском учењу посредством Web-а и омогућују наставницима online курсева једноставно креирање и одржавање курсева. Ови системи су толико већ распрострањени у пракси да се сами сматрају e-Learning системима. У литератури се среће неколико сродних појмова који се често користе као синоними за LMSs: *course management systems (CMSs)*, *virtual learning environments (VLEs)* и *learning content management systems (LCMSs)* (Devedžić, 2006). Стриктно говорећи разлике међу њима постоје. Тако на пример, LCMSs су системи који, између осталог, омогућују и креирање LOs и њихово означавање метаподацима, док LMSs не пружају такве могућности већ раде са претходно већ припремљеним курсевима (Van Assche & Massart, 2004). С обзиром да ове разлике нису од кључног значаја са аспекта овог рада, у наставку текста користиће се термин LMS. LMSs су намењени свим учесницима процеса учења – наставницима, студентима, администраторима, инструкционим дизајнерима и, у зависности од корисникове улоге у наставном процесу, LMS им омогућава различите видове рада и разне предности.

Наставници су у могућности да посредством LMS-а креирају online курсеве користећи при томе било постојеће LOs, доступне у репозиторијима LOs, било креирајући нове LOs за потребе датог курса. Креирани образовни садржаји (LOs и курсеви) се структурирају и представљају у складу са одговарајућим стандардима (*content packaging standards*) и означавају стандардним скупом метаподатака (*metadata standards*). На тај начин, образовни садржаји креирани у LMSs су спремни за вишеструко (вишекратно) коришћење (енгл. *reuse*). Наставницима је такође омогућено да у оквиру LMS-а дефинишу и наставни план курса, а кроз задавање активности студената и придруживање образовних објеката тим активностима. Остале функционалности LMS-а намењене наставницима обухватају: креирање тестова провере знања - квизова, (аутоматско) оцењивање, извештавање о учинку студената на тестовима, организовање колаборативних активности учења и сл.

За студенте, LMS представља комфорну платформу за приступ различитим курсевима, тј. образовним ресурсима и сервисима потребним за реализацију курса. LMS им омогућава и интеракцију/сарадњу са колегама посредством online дискусионих форума, електронске поште, соба за чет и дељених (виртуелних) радних простора (тзв. *shared whiteboards*).

Администраторима, LMS обезбеђује сервисе као што су креирање налога за студенте и наставнике, креирање и управљање групама студената различите величине, слање обавештења и извештаја студентима и наставницима, и сл.

Потребно је истаћи да је кључна реч за LMSs интеграција – интеграција различитих образовних ресурса и активности, различитих актера процеса учења, различитих софтверских алата и система за учење (Devedžić, 2006).

Тренутно најпопуларнији LMSs су: Blackboard & WebCT и Moodle. Blackboard и WebCT су до 2006. године били засебни комерцијални производи, а онда је дошло до повезивања њиховог пословања. Moodle је развијен, а тај процес и даље траје кроз стално усавршавање, као open source (отвореног кода) пројекта.

Овакав приступ учењу доприноси уопштености образовних садржаја. Али, у пракси, овакав начин рада (управо због уопштености) не одговара свим нивоима корисника. Неће сви студенти бити на истом нивоу знања, вештина, нити способности. Web образовни садржај би требало да задовољава различите потребе корисника, а у складу са њиховим способностима, вештинама и умећима. Потребе варирају од студента до студента, па чак и код једне особе ниво способности разумевања и знања, варира. Такође, корисник напредује кроз образовне нивое током курса. Све поменуто чини адаптивни садржај не само пожељним, већ и неопходним.

У наставку овог поглавља најпре је укратко представљена област адаптивног електронског учења и педагошких стратегија које га подржавају; после је укратко размотрен проблем моделовања студента, с обзиром да он представља основу сваког облика персонализације. Затим су представљени различити приступи персонализацији процеса учења, и то најпре класични приступи, реализовани у форми адаптивних образовних хипермедиских система (AENS) и интелигентних турских система (ITS), а затим и модернији приступи засновани на онтологијама, интелигентним агентима и Web сервисима. Потребно је приметити да поменути модернији приступи практично представљају унапређење класичних приступа, односно њихову реализацију применом нових технологија, док су основне поставке практично остале непромењене.

2.3. Адаптивни e-Learning системи

Адаптивност је добро познат концепт на пољу електронског образовања (и образовања уопште), који има тенденцију све веће примене у савременим образовним системима. У данашњем е-учењу мали је број Web оријентисаних образовних система који садрже и подржавају адаптивност. Адаптивно електронско учење нуди визију динамички креираних курсева, који су прилагођени специфичним потребама појединца, претходном знању, образовном окружењу, склоностима појединца током учења, повезаношћу и комуникацијским компетенцијама.

Још је Helen Parkhurst (Helen Parkhurst, 1886 – 1971., реформски педагог) предлагала тзв. Далтон план, који даје могућност да, зависно од својих способности, студенти

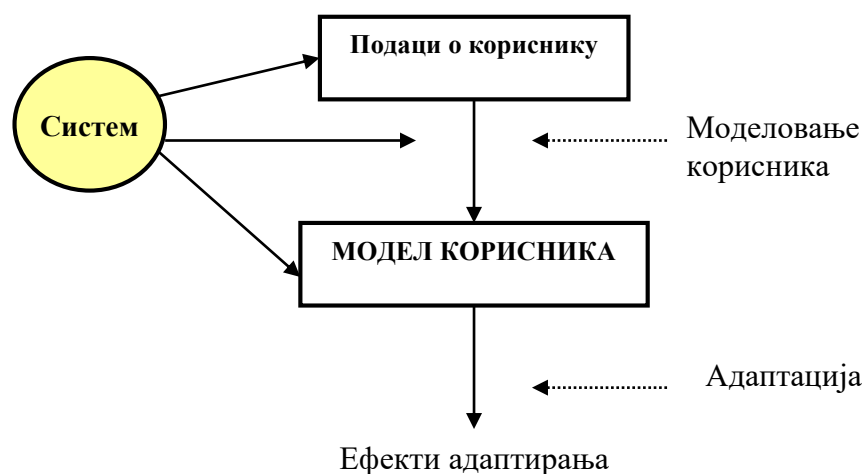
бирају између више нивоа тежине задатака у настави, при чему они сами одређују темпо рада. На тај начин студенти могу много брже напредовати из једних наставних предмета у односу на друге предмете, па разреди организовани према добу студената, нису више упутни за савлађивање већине наставних предмета. Предметни наставници прате студенте и помажу их у самосталном савлађивању наставних задатака.

Адаптивни умрежени образовни системи су се јавили као алтернатива традиционалном, једностраном приступу развоја образовних софтвера. Ови системи граде модел циљева, жеља и знања сваког појединачног студента и користе га кроз интеракцију са студентом, да би се прилагодили потребама тог студента (Yousaf, Arshad, Nouman & Arshad, 2018). Први адаптивни умрежени образовни системи развијени су 1995-1996. године (Brusilovski, 1996; De Bra, 2000; Yousaf et al, 2018). Од тада је широм света креиран велики број система. Већина адаптивних умрежених образовних система је базирана на технологијама развијеним у областима Адаптивних образовних хипермедија (АЕН) (Brusilovsky, 1996; 2017) и Интелигентног туторских система (ITS – Intelligent Tutorial System) (Castro-Schez, Glez-Morcillo, Albusac & Vallejo, 2021; Alkhatlan & Kalita, 2018)

Суштина је да се адаптивни систем прилагођава (адаптује) према својим околностим или околностима неког другог система. Процес прилагођавања се заснива на циљевима и склоностима корисника система. Ове особине корисника се складиште у тзв. моделу корисника. Тај модел корисника је део система и обезбеђује информације о кориснику, као што су нпр. претходна знања, циљеви и слично. Модел корисника омогућава систему да прави разлику између самих корисника и да према подацима из модела корисника прилагоди своје реакције (Martin, Chen, Moore & Westine, 2020).

У контексту е-Learning, адаптивни системи су специјализовани и више фокусирани на прилагођавање образовног садржаја и начина њихове презентације. Према (Mödritscher, Luengo, Law, Norpe & Stegmann, 2016), адаптивни систем се фокусира на то како ученик стиче знање (како учи) и обраћа посебну пажњу на образовне активности, когнитивне структуре и контекст образовних материјала.

На следећој слици је дата структура адаптивног система (Martin et al, 2020). Током процеса адаптације, систем интервенише на три нивоа. Систем контролише процес прикупљања података о кориснику, процес креирања модела корисника (моделовање корисника – више о томе у делу 2.5. *Моделовање студента*) и сам процес адаптације.



Слика 5: Структура адаптивног система

Сем представљене структуре адаптивног система, постоје и други модели. Адаптивни систем за електронско учење се назива адаптивни е-Learning систем. Ово ограничава сврху адаптивних система на подручје електронског образовања.

Главне проблеме у развоју адаптивног електронског учења представљају сложеност, високи трошкови и дужи временски период који су потребни за развој оваквог система. Тренутно су за развој типичног адаптивног е-Learning система потребни високо развијени тимови, који се састоје од технолога, програмера, експерата из обрађиване области, и захтева се значајан труд у интеграцији адаптивних техника, педагогије и наставног плана (захтева се један колаборативан приступ) (Arsović, 2018).

Системи за е-Learning који процес учења прилагођавају појединцу називају се адаптивни системи за електронско учење. Тако прилагодљив е-Learning систем користи активну стратегију учења која оспособљава студента да контролише садржај, темпо и обим учења. Он подржава студента, омогућавајући му алате и механизме помоћу којих студент може персонализовати своје учење. Ово оспособљавање студента и промена одговорности при учењу може помоћи у унапређивању задовољства студента у процесу учења.

Персонализација, у контексту електронског учења подразумева креирање и/или прилагођавање процеса учења појединцу (студенту), на основу анализе његових циљева учења, тренутног нивоа знања/вештина које поседује и преференци везаних за стил учења (FitzGerald, Jones, Kucirkova & Scanlon, 2018). Персонализација се може реализовати на различите начине: динамичком селекцијом и/или адаптацијом садржаја, прилагођавањем начина презентовања садржаја студенту, усмеравањем/вођењем студента кроз виртуелни простор за учење. Другим речима, персонализација може имати различите појавне облике, с обзиром да она може подразумевати прилагођавање: садржаја, навигације, активности, и/или начина презентације (Schneider & Handali, 2019), а све са циљем да се што боље одговори на потребе, циљеве и склоности појединца.

Прилагођавање и персонализација, било у ком облику да се реализује, увек се заснива на моделовању корисника, у овом случају студента (Stefanovic N., Stefanovic D. & Arsović, 2013). Моделовање студента обухвата активности, процесе, структуре за представљање знања и података, као и софтверске алате и технологије, намењене моделовању претходног знања студента, његових когнитивних карактеристика, преферираног стила учења, нивоа знања области која је предмет учења, а све са циљем динамичке адаптације процеса учења студенту (Binh & Trung, 2021; Devedžić, 2006).

Иако је персонализација већ дужи низ година једна од најактуелнијих тема у области е-учења, још увек није постигнута општа сагласност по питању тога шта се под овим термином подразумева – различити појединци, тумаче овај термин на различите начине. Услед тога, често се поставља питање у којој мери је неки адаптивни (е-Learning) систем стварно персонализован.

Као што нема сагласности по питању значења термина персонализација, тако нема ни јединственог приступа њеној реализацији. Уместо тога, постоје бројни, различити приступи, како у области истраживања, тако и у пракси. Оно што је заједничко свим тим приступима је примена извесног облика селекције (филтрирања) образовних садржаја, активности и/или процеса учења на основу знања, склоности, циљева и других карактеристика студента, релевантних за дати контекст учења.

Персонализација се може заснивати на пасивном (реактивном) или (про)активном деловању система. Док пасивни приступ подразумева да систем на персонализован начин одговара на захтеве корисника (студента), проактивни приступ подразумева да систем преузима иницијативу и нуди студенту препоруке по питању образовних садржаја, активности, даљих линкова и сл (Arsović, 2018).

Деловање реактивног система би се могло описати на следећи начин: захтев примљен од студента систем употпуњује информацијама којима располаже о студенту (тренутни ниво знања, преферирани стил учења и сл) и конкретној ситуацији учења (циљеви учења, тип окружења), а затим тако припремљен захтев прослеђује до одговарајућег извора информација (репозиторијума). Резултате процесирања захтева (тј. претраге) систем може рангирати према различитим критеријумима пре него што их представи студенту. При томе, начин рангирања резултата за различите студенте може бити (и обично јесте) различит – оно што одговара једном студенту, не значи да ће одговорати и другом.

Системи који примењују проактивни приступ персонализацији континуирано прате активности студената како би били у стању да препознају ситуацију у којој би требало да реагују. Њихова карактеристика је да сами одређују тренутак када ће преузети иницијативу. Ова одлука се заснива на студентовим преференцама и циљевима, опаженој навигацији студента, расположивим подацима о начину понашања других студената у истој или сличној ситуацији.

2.4. Педагошке стратегије у адаптивном електронском учењу

Постојеће е-Learning апликације се фокусирају на приказ мултимедијално богатих садржаја, а мање се баве самим активностима учења и самим током процеса стварања и усвајања знања. Често је случај да се мало, или ни мало, користи образовна стратегија или педагогија током креирања образовног процеса. Враћајући у фокус активности високог нивоа педагошке стратегије, могуће је подржати наставнике и студенте у искоришћавању предности које адаптивни е-Learning нуди.

Реализацију педагошке стратегије описују наративне структуре које садрже, на пример дефинисање типа активности, предлагање могућег низа активности, могућности за комуникацију и колаборацију и селекцију садржаја. Они представљају употребљиве елементе педагошких стратегија у модел базираној (XML) форми. Ови модели могу бити коришћени као педагошка основа на којој може бити базирана конструкција адаптивних педагошких курсева. Конструкција online курсева, који укључују и захтевају различите педагошке приступе, је олакшана услед коришћења ових наративних структура. На пример, учење базирано на случајевима, базирано на претраживању Веба итд., могу се комбиновати ради формирања основе за прилагодљиву педагогију. Ово дозвољава потенцијалним ауторима курса да направе прилагођене курсеве базиране на врсти моделованих приступа, који активно олакшавају поновно коришћење, не само садржаја који се учи, већ и стратегија и педагогије које стоје иза оваквог процеса учења.

Педагошке стратегије могу бити представљене као циклуси дескриптивних појмова који представљају активности учења, које треба да се предузму (Hussein & Al-Chalabi, 2020). Педагошке стратегије су обично удружене са сетом упутстава и сценарија који имају за циљ да ојачају поверење аутора курса у коришћење ових стратегија. Наративни појмови олакшавају сажет опис педагошких елемената унутар контекста независног од

садржаја. Они такође омогућавају педагошким експертима да креирају и прилагоде елементе педагошких стратегија у процесу креирања педагошких адаптивних online процеса учења.

Кључна предност у виšekратном коришћењу образовних стратегија, оствареном путем наративних структура, је могућност да се деле успешни и доказани педагошки приступи са персонализованим e-Learning-ом. Користећи проверену основу на којој су промене извршене, наставници могу модификовати ове стратегије по жељи. Овим путем, институције у разним земљама могу делити и стратегију и садржај, или само стратегију. Постоји одређен број кључних компоненти за вишеструку употребу образовних стратегија. На првом месту је коришћење стандарда за склапање модела. Стандарди утичу на вишеструко коришћење образовних стратегија на два начина. Ако су стратегије записане у формату који је компатибилан стандардима, онда могу бити интерпретиране од стране LMS који подржава ову спецификацију. Други утицај који стандард има је њихов опис према открићу. Стратегије могу бити описане на начин сличан постојећим образовним објектима (*learning objects* - LO). Ако се користе одговарајући стандарди, повећава се могућност за вишеструку употребу објеката. О стандардима и стандардизацији у e-Learning системима било је више речи у секцији *Стандардизација у електронском учењу*, а о самим образовним објектима у секцији *Образовни објекти*.

Учење и теорије учења

Да би се схватило на који начин, конкретно, у креирању адаптивног LMS-а могу помоћи педагошке стратегије/теорије, потребно је размотрити неке од њих. Потребно је удубити се у проблематику самог процеса учења и размотрити неке од теорија учења.

Особа може учити на два, суштински различита начина (Honey & Mumford, 1992). Некада је научено резултат формално структурираних активности (нпр. учење кроз похађање предавања или читањем књиге), а некада се учи кроз стицање искустава, често и несвесно, кроз негативна искуства. Првопоменути тип учења, тј. учење посвећено стицању формалног знања, је више устаљено и заступљеније је од експерименталног учења (Honey & Mumford, 1992). Две, традиционалне педагошке теорије учења су бихевиористичка и когнитивна, које имају различит приступ и виђење процеса учења. Актуелна теорија модерног времена је конструктивистички приступ (Sarrikoski, Salojarvi, Del Corso & Ovcin, 2000; Clark, 2018).

Бихевиористички приступ заступа становиште да је циљ, сврха учења промена у уочљивом/очигледном понашању, и првенствено се фокусира на релације међу атрибутима који се тичу самог студента (као што су интелигенција, друштвено залеђе и способности/вештине); а који се квантитативно мере и изражавају кроз исходе као што су предметне оцене.

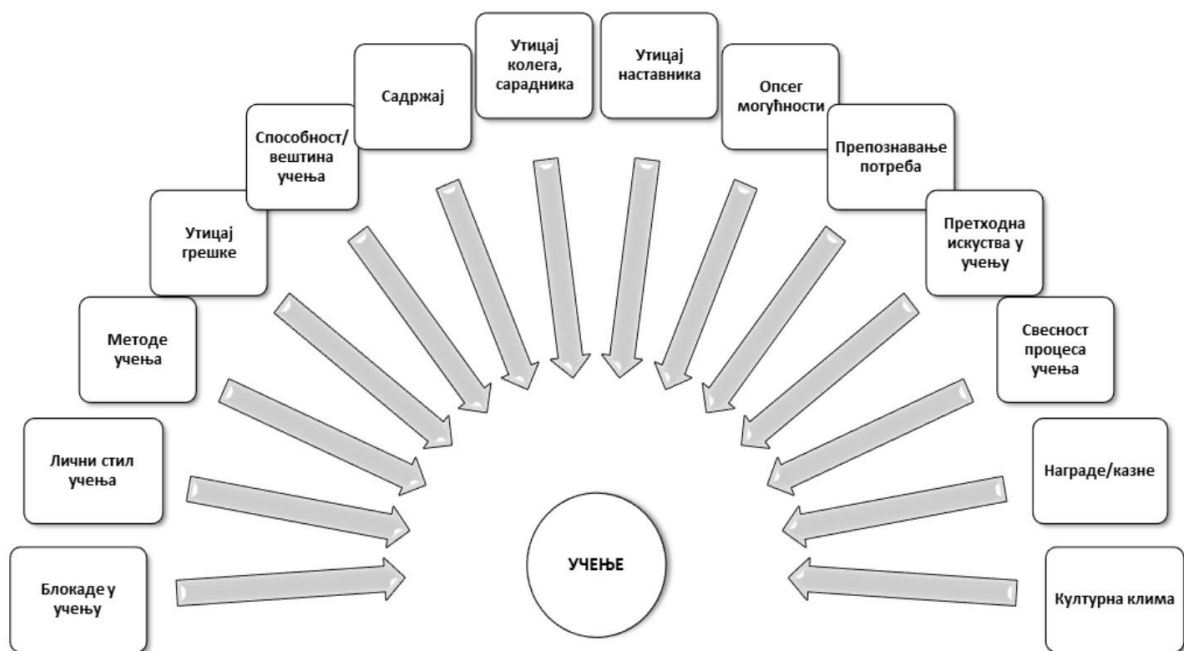
Когнитивни приступ учењу је постао популаран 60-тих година XX века, почевши да истискује бихевиористичку теорију и став, како су истраживачи и експерти постајали заинтересованији за сам процес учења, истражујући области и процесе попут резоновања, разумевања и проблемског учења (учење кроз решавање проблемских ситуација).

Полазна идеја *конструктивистичке теорије* је истраживање „самосталног, активног доприноса ученика, самом процесу учења, у друштвеном контексту; а где ученик гради своје знање кроз комбиновање нових информација и искустава са већ постојећим структурама знања“ (Clark, 2018).

На основу претходне дефиниције конструктивистичког приступа процесу учења, очигледно је да информација не може бити једноставно пренета од једне особе до друге, због чињенице да ће иста информација бити различито интерпретирана од стране различитих особа/ученика/студената. Давид Колб (David Kolb) је један од најпознатијих представника оваквог приступа учењу, а међу његовим доприносима овој теорији је и потврда постојања сопственог стила учења код сваког студента.

Стилови учења

Бројни су фактори који могу да утичу на обим учења, и неки од њих су приказани на слици 6 (Naj'iyah & Suyatna, 2021). Стил учења се може дефинисати као „став и понашање које одређује лични, преферирани начин учења“ (Honey & Mumford, 1992). На пример, студент, који предност даје практичном искуству, учећи нови програмски језик, желеће да одмах приступи писању кода; док ће други студент радије проучити карактеристике новог језика, пре писања било каквог кода. Већина студената није свесна особина свог стила учења, али су зато нејасно свесни тога која им активност током учења више или мање годи, као и од чега имају више користи. Иако постоје бројна истраживања о стиливима учења, делује да нема довољно слагања мишљења и прихватања неке јединствене теорије о томе (Bruen, Fitzpatrick, Gormley, Harvey & McAvinia, 2011). Сви модели стилова учења претпостављају да је могуће измерити студентово учење, коришћењем психометријских инструмената (Feldman, Monteserin & Amandi, 2015).

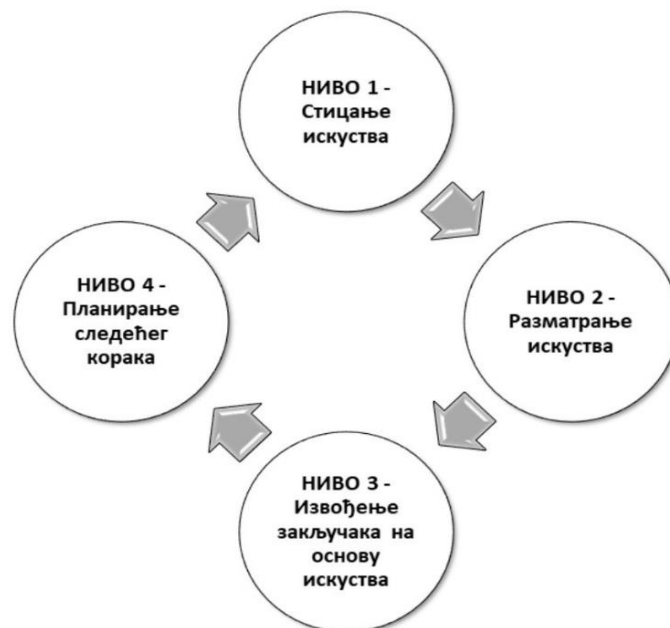


Слика 6: Фактори који утичу на учење

Honey & Mumford модел стила учења

Учење је доживотни процес који има четири јасна нивоа, која су презентовали Honey и Mumford (1992), а заснивају се на Колбијевом раду (слика 7). Иако Колб можда користи различите термине за описивање нивоа и четири стила учења, сличности између његовог модела и модела Honey & Mumford су веће него разлике.

Студент/ученик може почети било где на кругу (у циклусу) и то не неопходно на нивоу 1. На пример, може се почети на нивоу 2, стицањем неких информација и размишљањем о њима, пре доношења неких закључака на нивоу 3, а потом и одлучивања о примени стеченог знања, на нивоу 4.



Слика 7: Honey & Mumford-ови нивои учења

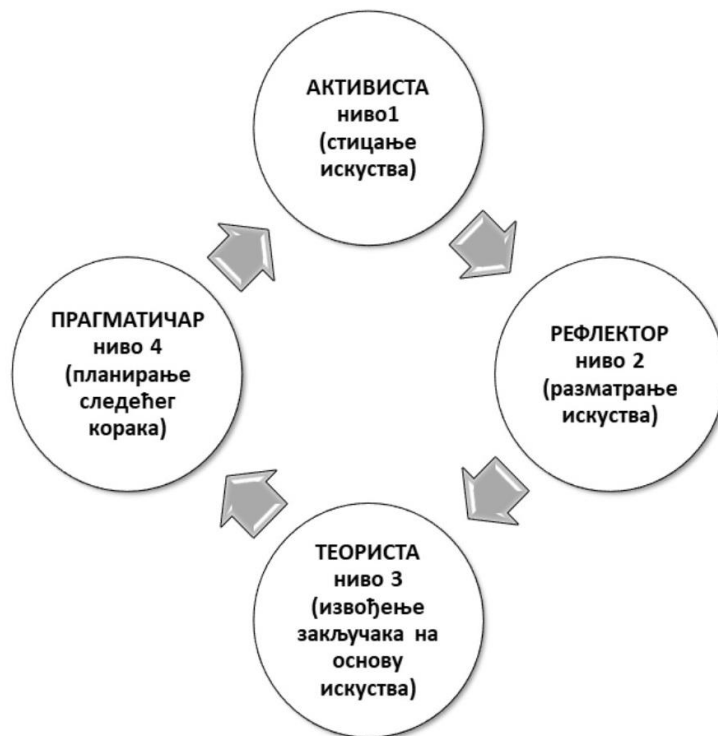
Ова четири нивоа, приказана на слици 7, се укратко могу описати као:

1. ниво, *стицање искуства* – постоје два типа искуства које неко може имати: реактивно (допуштање да искуство само допре до нас) и проактивно (намерно тражење искустава). Могућност учења из искуства знатано расте, уколико су нормална дешавања којима смо окружени замењена са посебним искуствима која сами креирамо.
2. ниво, *разматрање искуства* – уколико неко учи на основу искуства, од виталног је значаја да поново размотри шта се то дешавало и десило.
3. ниво, *закључивање на основу искуства* – ово подразумева испитивање необрађеног материјала добијеног из разматрања, у циљу доношења закључака, одговора или учења лекције.
4. ниво, *планирање наредног корака* – планирање укључује превођење неких закључака у такав облик, из кога се могу активирати и практично применити.

Све претходно изнете ставке се међусобно подржавају, али ни једна у потпуности не осликава саму процедуру учења, јер сваки ниво игра само одређену улогу у потпуном процесу (Koticha, 2019).

Већина људи развија преференце, на основу којих имају склоности ка одређеном нивоу (у односу на остале нивое). Међутим овакве преференце могу довести до дисторзије процеса учења, уколико се превише нагласи одређени ниво процеса на уштрб других. Уколико студент прати ток циклуса учења, при том обраћајући довољно пажње на

сваки појединачни ниво циклуса, тек онда ће повећати шансу ефикасног учења (Mumford, 1995; Kotecha, 2019). За сваки, претходно идентификовани ниво учења, везује се одређени стил учења (слика 8).



Слика 8: Honey & Mumford-ови стилови учења

Идентификована су четири стила учења: активиста, рефлектор, теориста и прагматичар.

Табела 2: Стили учења по Honey & Mumford класификацији

СТИЛ УЧЕЊА	КАРАКТЕРИСТИКЕ
Активиста	<ul style="list-style-type: none"> Уче из релативно кратких задатака типа сад-и-овде. Отвореног су ума, нису скептични и теже да буду ентузијастички по сваком питању. Прво делају, а тек потом разматрају и размишљају о последицама. Активни су, а проблеме решавају иновативним идејама. Воле рад са другима, теже да су у центру пажње и збивања. Најбоље уче: када су укључени у стицање нових искустава, решавање проблема и кад им се пружају нове прилике; када раде са другима у такмичарском окружењу; када раде у тиму; или када уче кроз играње улога; када председавају састанцима и радним групама или када воде дискусију.
Рефлектор	<ul style="list-style-type: none"> Уче кроз активности у којима могу да остану у позадини, слушајући и посматрајући. Преферирају скупљање информација и када им се да могућност да о њима размисле. Опрезни су. Имају скромно држање и обично се држе на дистанци, толерантни су. Најбоље уче: посматрајући појединце или групе у току рада; када имају могућност да поново размотре шта се догодило и размисле о томе шта су научили; када могу да изврше анализе и напишу извештаје о задатку, али без задавања стриктних рокова.

Теориста	<ul style="list-style-type: none"> • Прилагођавају и интегришу обсервације у комплексну, али логичну, постојану теорију. • Заинтересовани су за усвајање нових идеја, чак иако су можда, по њиховом мишљењу, далеко од праве реалности. • Воле да врше анализу, али и синтезу. • Труде се да буду непристрасни, аналитични и њихов приступ проблему је доследно логичан. • Најбоље уче: када су доведени у комплексну ситуацију са јасном сврхом; када су им понуђене занимљиве идеје или концепти, чак иако одмах не мисле да су оне релевантне; када имају шансу да испитују и расправљају идеје.
Прагматичар	<ul style="list-style-type: none"> • Жуде да, у пракси, испитају нове идеје, теорије и технике. • Воле да напредују и делају брзо и поверљиво са идејама које их привлаче. • У суштини су практични, приземни људи који воле доношење практичних одлука и решавање проблема. • Најбоље уче: када сами чине везу међу задатком/темом и послом; када им се пружи шанса да испробају технике (али са повратном информацијом, као што је нпр. играње улога); када им се демонстрирају технике очигледних предности (као нпр. уштеда времена); када им се покаже модел који могу копирати (филм или угледни шеф, инструктор итд.).

Honey и Mumford упитник о стиловима учења је развијен у циљу одређивања студентског преферираног стила учења. Овај упитник има 80 питања, 20 за сваки стил; обично се изводи у трајању од 10 до 15 минута. Овим упитником се избегава постављање директних питања о начину учења; уместо тога, он испитује уопштене тенденције у понашању ученика (нпр. „Активно трагам за новим искуствима“, или „У дискусији, волим да циљам право у суштину“). Упитник истражује бихевиоралне тенденције, а не тенденције у учењу, јер се верује да људи свесно не разматрају како уче, тако да није упутно нити од користи директно их питати о томе (Honey & Mumford, 1992; Honey, 2004).

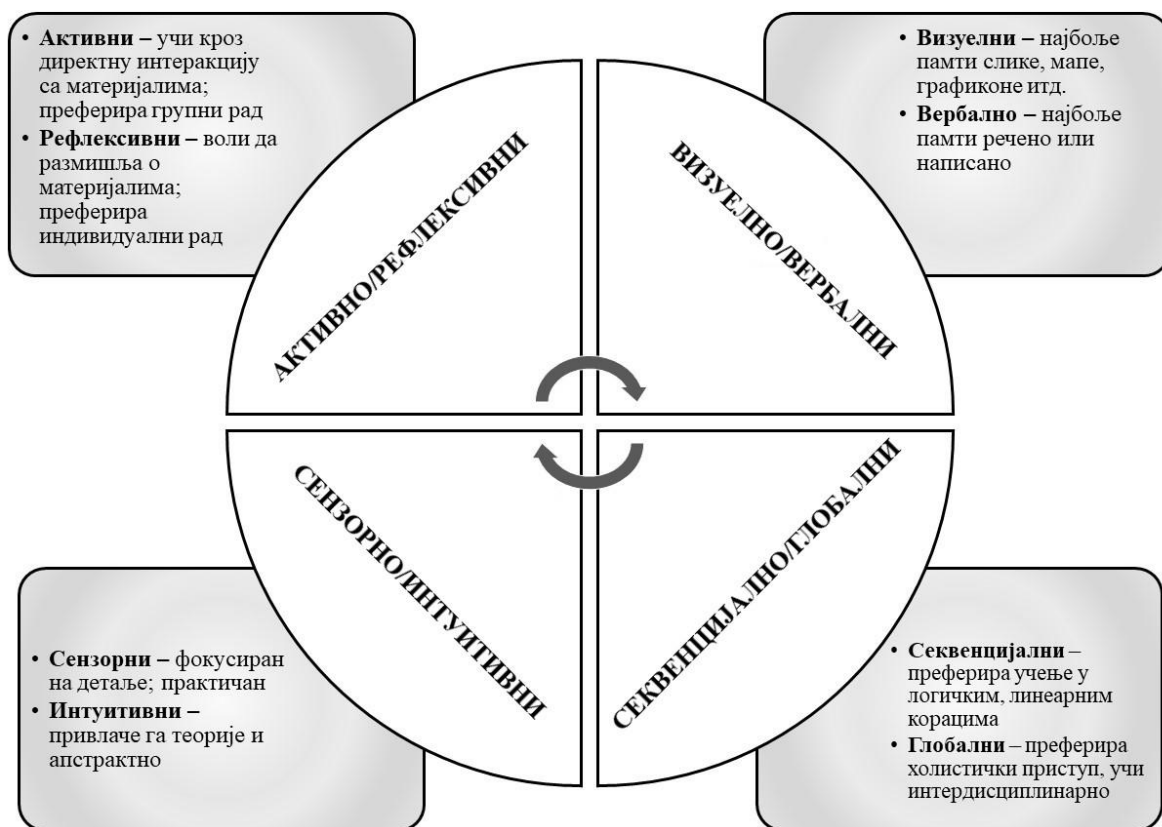
Felder-Silverman Learning Styles Model

Felder-Silverman Model (FSLSM) имплементације стила учења је један од највише коришћених модела у актуелним педагошким истраживањима. Овај модел се често користи када се анализирају стилови учења у окружењу карактеристичном за e-Learning (El-Bishouty, Aldraiweesh, Alturki, Tortorella, Yang, Chang & Graf, 2019).

По FSLSM моделу студентов стил учења се може дефинисати на основу четири питања:

- који тип информација студент фаворизује (најбоље прихвата)? Конкретне или апстрактне?
- који тип сензора најефикасније прихвата информације? Визуелни или вербални?
- како студент обрађује информацију? Активно или рефлексивно?
- која је студентова карактеристика напредовања ка разумевању материје? Секвенцијална или глобална? (Felder & Spurlin, 2005).

Наведена четири питања заправо имају основу у четири димензије, на основу којих је FSLSM модел скалиран. Ова типологизација стилова учења је креирана на основу психолошке експертизе и искуства у образовању (слика 9).

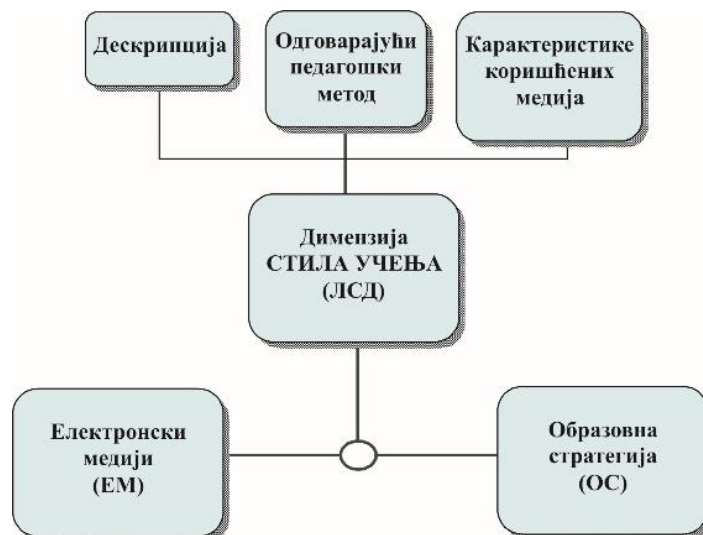


Слика 9: Felder-Silverman Model (FSLSM)

Овим моделом се сваки студент описује у складу са четири димензије и сврстава се у један од следећих стилова учења:

- активно/рефлексивни стил учења
- сензорно/интуитивни стил учења
- визуелно/вербални стил учења
- секвенцијално/глобални стил учења.

Свака од четири димензије (аспекта) стила учења пројектује одређени стил учења, са својим карактеристикама. Повезаност тих димензија и стилова, са пратећим карактеристикама видимо у табели 3 (Zagulova, Boltunova, Katalnikova, Prokofyeva & Synytsya, 2019). Сваки од наведених стилова учења је у релацији са одређеном наставном стратегијом, која би требала да буде усвојена и имплементирана у LMS, као подршка стилу учења студента. Релације између стила учења и наставних стратегија су дате у табели 4. Такође се препоручују одговарајући е-медији као канали представљања образовног садржаја, тако да тај садржај буде у форми која у потпуности одговара студенту и његовом стилу учења (Supangat & Mohd Zainuri, 2020).



Слика 10: Таксономија адаптивности учења у зависности од стила учења

На основу тако предложених категорија и димензија модела представљених у табелама 3 и 4, могуће је креирати модел образовног профила. Felder-Silverman модел је тесно повезан са стиливима учења и наставним стратегијама, што резултује приближавањем ових аспеката (Zagulova et al, 2019).

Табела 3: Felder-Silverman Learning Styles димензије (Felder & Silverman, 1998)

ДИМЕНЗИЈА СТИЛА УЧЕЊА	ТИП СТИЛА УЧЕЊА	ОПИС
ПЕРЦЕПЦИЈА	Сензорни	Воле рад са чиљеницама, конкретним подацима и експериментима. Стрљиви су у раду са детаљима, али не воле компликације.
	Интуитивни	Преферирају рад са принципима и теријски приступ. У суочавању са детаљима лако се замарају и досађују, али зато радо прихватају изазове и компликоване ситуације.
НАЧИН ПРИЈЕМА ИНФОРМАЦИЈА	Визуелни	Лако памте оно што су видели: дијаграме, слике, филмове, табеле и сл.
	Вербални	Памте оно што су чули, прочитали или сами изговорили.
ОБРАДА	Активни	Уче кроз рад у групама и при изради конкретних пројеката.
	Рефлексивни	Боље уче када могу да размисле о презентованим им информацијама. Боље раде сами или највише у друштву једне особе.
РАЗУМЕВАЊЕ	Секвенцијални	Приликом решавања проблема прате линеаран процес резоновања. Једном када неки материјал делимично или површно разумеју, у могућности су да раде са њим.
	Глобални	Имају велике интуитивне скокове у информацијама, тако да им може представљати тешкоћу када треба да објасне како су дошли до одређеног резултата. Потребна им је интегрална визија.

Табела 4: Релација стил учења-наставна стратегија

СТИЛ УЧЕЊА	НАСТАВНА СТРАТЕГИЈА	ОСОБИНЕ
Сензорни	конкретна	Битна је перцепција садржаја.
Интуитивни	абстрактна	
Визуелни	визуелна	Битан је формат презентације садржаја.
Вербални	вербална	
Активни	активна	Битна је партиципација студената у активностима.
Рефлексивни	пасивна	
Секвенцијални	секвенцијала	Битан је одговарајући редослед презентовања садржаја: корак-по-корак или приказ комплетног садржаја.

2.5. Моделовање студента

Моделовање студента подразумева проналажење/дефинисање оптималног модела за представљање битних информација о студентима у образовним апликацијама (потребно је приметити да се термин студент у литератури из ове области односи на свако лице које се јавља у улози ученика, без обзира да ли је формално студент или не). Модел, зависно од потреба конкретне апликације којој је намењен, може садржати информације о знању, вештинама, способностима, преференцама или неким другим битним карактеристикама студента. Модел студента је неизоставна компонента две врсте образовних апликација: Интелигентних туторских система (ITS) и Адаптивних (образовних) хипермедијалних система (AENS) који ће бити укратко објашњени у наредним подпоглављима.

Генерално, процес адаптације може се описати у три фазе: преузимање података о студенту, обрада информација ради иницијализације и ажурирања модела студента и коришћење модела за обезбеђивање адаптивности.

Кориснички модел је суштинска компонента у адаптивним системима е-учења. Прилагођавање система е-учења углавном укључује избор и представљање сваке узастопне наставне активности у функцији целокупног опсега знања студента о предмету који се предаје и других релевантних карактеристика студента, које се чувају у моделу студента. Стога се модел студента користи за модификовање интеракције између система и студента, у складу са потребама појединих студената.

Наводе се улоге модела студента (Biswas & Springett, 2018):

- асистира студенту током учења одређене теме
- даје информације прилагођене студенту

- прилагођава интерфејс студенту
- помаже студенту да пронађе информације
- даје студенту повратне информације о његовом знању и напретку
- подржати заједнички рад (колаборацију)
- пружа помоћ при коришћењу система.

Данас већ постоје и спецификације које дефинишу основну структуру модела студента и тип информација које би модел требало да садржи. Ове спецификације су сачињене са циљем да се:

- идентификују све информације о студентима које су потенцијално релевантне за персонализацију процеса учења
- дефинише јединствени начин представљања тих информација у e-Learning системима и тиме омогући размена информација о студентима између хетерогених образовних система.

Две најзначајније спецификације су: IEEE Public and Private Information (PAPI) for Learners (PAPI Learner) и IMS Learner Information Package (IMS LIP).

Међутим, потребно је напоменути да овим спецификацијама нису решени сви проблеми моделовања информација о студентима и примене креираних модела у образовним системима. Постоји још читав низ отворених питања које је потребно решити, а међу којима су (Truong, 2016):

- Иницијализација модела студента (cold start problem) – образовне апликације које примењују неки облик моделовања студента, суочене су са проблемом додељивања иницијалних вредности елементима студентског модела. Нека од питања која се овде отварају су: како одредити ниво познавања доменске области? Како проценити стил учења студента? Како идентификовати циљеве студента? У досадашњој пракси поменута питања су углавном решавана применом неког облика теста/упитника који студент решава при првој интеракцији са системом. На основу анализе одговора студента систем врши иницијализацију његовог модела. Међутим, овај приступ има више недостатака: непрецизна процена знања/циљева/стила учења; негативан утицај тестова на мотивацију за учење и сл.
- Индивидуалне разлике у погледу претходно стеченог знања и искуства. Један исти образовни садржај може имати различите ефекте на различите студенте зависно од њиховог предзнања. Образовне апликације морају узети у обзир претходно стечена знања и искуства сваког студента. Да би одговориле овом захтеву неке образовне апликације користе тзв. стереотипни модел студента (stereotype student model) и деле све студенте према нивоу знања у неколико категорија (најчешће три: почетници, средњи ниво знања, напредни ниво). Сваком студенту се нуде образовни садржаји, који по тежини одговарају категорији којој он припада. Основне замерке које се упућују оваквом приступу су везане за начин дефинисања категорија студената и начин процене припадности ученика некој од тих категорија. Ипак, као главни недостатак се истиче

то што је за аутора образовних садржаја готово немогуће да, при њиховом креирању, узме у обзир специфичне циљеве сваког појединачног ученика и да одреди све концепте на које ће се ученик у својим размишљањима позивати док буде покушавао да разуме градиво.

- Различитост циљева аутора образовних садржаја и студената. Многи образовни системи полазе од предпоставке да су циљеви ове две стране исти и не омогућују адаптацију према специфичним циљевима које студенти могу имати. Апликацијама су потребни механизми који ће омогућити јасно утврђивање циљева студената, како би биле у стању да обезбеде ефективну персонализацију процеса учења.
- Праћење промена циљева, преференци и знања студената током времена. Све образовне апликације поседују неки механизам праћења промене нивоа знања студента из доменске области за коју је апликација намењена (различите форме тестова, евиденција приказаних страница и сл.). Међутим, студенти стичу знања о неком домену и на друге начине: кроз комуникацију са другим студентима, читањем текстова у књигама, часописима који припадају том домену и сл. Образовним апликацијама је потребан неки механизам који ће им омогућити праћење промена овог типа. Текуће решење овог проблема заснива се на примени отвореног модела студента (open student model) (Zapata-Rivera, 2020) који подразумева да се студентима даје увид у текуће стање њиховог модела и да им се дозвољава да га сами, по својој процени, едитују. Наравно, и овде се сусрећемо са низом отворених питања, као што су: колико су студенти у стању да сами процене своје знање? У којој мери су способни да јасно формулишу своје циљеве? Јесу ли свесни свог стила учења?

2.6. Различити приступи персонализацији учења

Постоји више приступа и начина адаптирања наставе и учења. Описаћемо четири основна теоријска приступа: макро-адаптивни приступ, приступ интеракцијског неговања талената (способности), микро-адаптивни приступ и конструктивистичко-колаборативни приступ. У зависности од тога који тип персонализације, тј. адаптивности користе и системи се разврставају у различите типове.

Теоријски приступи описују различите могућности адаптивне наставе. Како је историја адаптивне наставе дужа од сто година, то су описани приступи приказани хронолошким редом.

Макро-адаптивни приступ

Рани покушаји персонализације наставе и учења се заснивају на такозваном макро-нивоу. Студенти су груписани или класификовани по оценама. Овакво груписање резултира хомогеном евалуацијом ученика, има најмањи ефекат на адаптацију, јер су групе веома ретко изложене различитим обукама. У циљу бољег прилагођавања различитим потребама и могућностима студената, макро-адаптивни приступ је осмишљен почетком XX века када се адаптација наставе разматрала на макро-нивоу. По овом приступу, алтернативне обуке се осмишљавају на основу неколико главних компоненти, као што су образовни циљеви, степен детаљности и начина одржавања наставе. Одабир прикладне наставе се првенствено заснива на студентским образовним циљевима, општим

способностима и нивоом успеха у програмској структури. Према (Hardy, Decristan & Klieme, 2019), одабир наставе (тј. активности) зависи од образовних циљева као што су исправљање студентских слабости или развијање нових способности и талената. Ови таленти су категоризовани у три типа: интелектуалне способности и претходна постигнућа; когнитивни стил и стил учења; и академска мотивација и личност (карактер).

Приступ интеракцијског неговања талената

Приступ интеракцијског неговања талената (АТИ – Aptitude-treatment Interaction) прилагођава наставне стратегије према студентовим талентима. Ова стратегија препоручује различите типове активности студентима са различитим карактеристикама. Најважније карактеристике су: интелектуалне способности, когнитивни стилови, стилови учења, претходно стечено знање (предзнање), жеље, мотивација за успешност и самоефикасност.

АТИ кориснику нуди и потпуну или делимичну контролу над процесом учења. Корисник је у могућности да контролише стил наставе или начин одвијања образовног курса. Дефинисана су три нивоа контроле: потпуна независност, делимична контрола у оквиру сценарија задатка и утврђени задаци са контролом темпа рада. Испитивања су показала да таленти студената утичу на резултате учења, када су студентима понуђени различити нивои контроле наставног процеса. На пример, студент са slabим предзнањем постиже боље резултате уколико му је контрола процеса учења ограничена и смањена (Hardy et al, 2019).

Микро-адаптивни приступ

Микро-адаптивни приступ користи образовне потребе током наставног процеса да би се постигла адаптација наставе. Ове потребе су испитане и генерисана је одговарајућа прескрипција. У поређењу са мерењима пре извршења задатака, која се врше у макро-адаптивном и АТИ приступу, микро-адаптивни приступ се више базира на мерењима у току извођења самог задатка. Понашање и перформансе студента се посматрају кроз мерења као што су нпр. одзиви на грешке и емоционална стања.

Први модел за микро-адаптивни приступ јесте идеја програмиране наставе, коју је првобитно применио Pressey 1926. године. Са употребом модерних технологија, развијао се и већи број различитих микро-адаптивних наставних модела. Ови модели се разликују од идеје програмиране наставе по примени специфичног модела или теорије учења. Постојећи модели су: математички модел, модел трајекторије, модел Бајесове вероватноће и структурни и алгоритамски приступ.

Према (Mödrtscher et al., 2016), у случају микро-адаптивног приступа e-Learning се дели на два основна процеса – дијагностички и прескриптивни. Први корак (дијагностички процес) служи да се карактеризује ученик путем идентификовања талената или предзнања и да се формулише задатак. Затим се интеракција међу ученицима и задатак оптимизују адаптирањем образовног садржаја према ученичким талентима и тренутним перформансама.

Конструктивистичко-колаборативни приступ

Педагошки конструктивистички приступ се фокусира на то како се e-Learning систем може интегрисати у наставни процес. Према конструктивистичкој теорији учења, ученик има активну улогу у процесу учења, где се знање ствара кроз искуства стеченим у специфичним доменама знања.

Друга битна страна овог приступа је примена колаборативних технологија, где је интегрисан педагошки приступ колаборативног учења. Reis и сарадници (Reis, Isotani, Rodriguez, Lyga, Jaques & Bittencourt, 2018) идентификују пет карактеристика ефикасног колаборативног учења: партиципација, социјално понашање, анализа перформанси, групна обрада и способности конверзације, и примитивна интеракција. Да би се омогућило успешно учење путем колаборативних технологија, потребно је да ових пет карактеристика буду доступне ученику.

2.7. Типови адаптивних образовних система

У овом делу су описани типови образовних система на основу претходно изложених теоријских приступа персонализацији наставе.

Макро-адаптивни образовни системи

Као што је већ речено у претходном поглављу, макро-адаптација је најстарији начин приступа персонализацији, где се студенти једноставно прате и надзиру на основу оцена и тестова способности. Макро-адаптивни образовни системи су развијени у циљу прилагођавања наставе способностима ученика. Park и Lee (Lee & Park, 2008) помињу Бурков, Далтонов и план Winnetka, као најраније системе који примењују макро-адаптивни приступ. У овим системима, студенти су могли да пролазе кроз образовне материјале у сопственом темпу, брзином која им одговара.

Током 1963. на Колумбија универзитету, развијен је Келеров (Keller) план, који је такође макро-адаптивни систем у коме се образовни процес персонализује према сваком студенту (Fletcher, 2019). То је био први макро-адаптивни систем који је коришћен на бројним универзитетима широм света. До 1985. је развијено неколико других макро-адаптивних образовних система.

Досадашњи макро-адаптивни системи би требали да демонстрирају историју адаптивних e-Learning система и њихове примене. Ови системи су примењивани у многим школама и факултетима иако су омогућавали слабу и адаптацију ниског нивоа.

Рачунарски управљиви образовни системи (CMI)

Посебно место заузимају рачунарски управљиви образовни системи (енгл. Computer-Managed Instructional Systems – CMI). CMI системи нуде бројне макро-адаптивне карактеристике, омогућавајући инструкторима да прате и контролишу образовне активности студената (Bakhouyi, Dehbi, Talea & Najoui, 2017). Шта више, CMI системи интегришу и карактеристике микро-адаптивних модела (као што је предвиђање образовних потреба ученика). Ово чини CMI системе ефикаснијим (у смислу e-Learning система) у односу на чисто макро-адаптивне системе.

Интелигентни турски системи

Интелигентни турски системи (енгл. *Intelligent Tutoring Systems – ITS*) су софтверски системи који применом технологија вештачке интелигенције усклађују процес наставе/учења са знањем/потребама/склоностима појединаца.

Основни елементи архитектуре ITS-а су: експертни модул са инструкционим садржајима ITS -а; педагошки модул који садржи различите педагошке стратегије на основу којих ITS управља процесом наставе/учења; модел студента намењен представљању

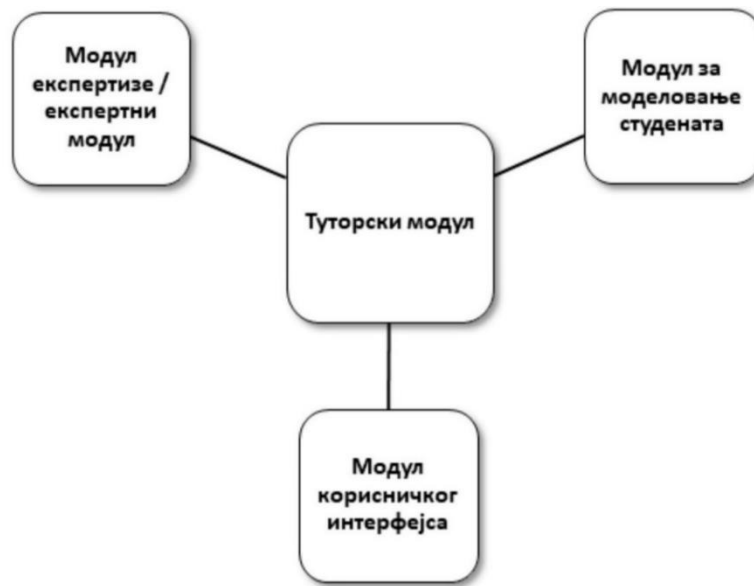
знања студента о доменској области која је предмет учења; интерфејс модул посредством кога се остварује интеракција са студентом (Devedžić, 2006). Очигледно је да је основна архитектура АЕHS и ITS система врло слична.

Већина ITS система је намењена индивидуалном учењу, што подразумева да један студент учи уз помоћ система који преузима улогу татора. Остали ITS системи подржавају колаборативно учење, и тиме омогућују групи студената да учи како кроз интеракцију са системом (татором), као и међусобну интеракцију. Неки ITS системи укључују тзв. другара за учење (енгл. *learning companion*). Реч је о програмима (најчешће реализованим у форми интелигентних агената) који упоредо са студентом (корисник система) уче од татора исте оне теме које и студент учи и имају улогу да му пруже помоћ, да представе конкурента или да на неки други мотивишу студента на учење.

Различити ITS системи користе различите технике представљања знања (модел студента, експертни модул) и закључивања (педагошки модул).

Од средине 1990-тих, почиње развој ITS система намењених учењу посредством Web-а. Комбиновањем карактеристика LMSs и ITSs, развијен је концепт интелигентних LMS-а (ILMSs). Очекивање је да се комбиновањем предности ове две врсте e-Learning апликација, може развити систем који представља потпуни одговор на захтеве који се постављају пред модерне e-Learning апликације. На пример, ILMS је у могућности да пружи наставницима увид у модел студента, путање учења, стил учења, брзину напредовања, проблеме са разумевањем градива и на тај начин им омогући да управљају процесом учења на што бољи начин.

Једна од првих предложених архитектура овог типа је Knowledge Tree архитектура (Brusilovsky, 2004). По њој се ITS систем састоји од модула експертиза, модула за моделовање студента, таторског модула и модула корисничког интерфејса. Модул експертизе процењује перформансе студента и генерише образовни садржај. Модул за моделовање студента представља тренутно знање студента и процењује његове стратегије резоновања и концепције. Ову информацију ITS користи да би одредио као ће се наставити процес учења и подучавања. Таторски модул садржи информације за селекцију образовних материјала. Ова информација описује начин и време презентовања материјала. Модул корисничког интерфејса је комуникацијска компонента, која контролише интеракцију између студента и система. Ови системи су још увек у фази истраживања.



Слика 11: Компоненте ITS

Адаптивни хипермедијски системи

Адаптивна хипермедија (енгл. *Adaptive Hypermedia* – АН) представља правац истраживања који настоји да повеже и даље унапреди достигнућа остварена у доменима хипермедијских система (енгл. *Hypermedia Systems*) и моделовања корисника (енгл. *User Modeling*). АН систем се базира на моделу циљева, склоности и знања сваког појединачног корисника система и користи тај модел током интеракције са корисником како би интеракцију прилагодио специфичним потребама тог корисника (Brusilovsky, 2017).

АН настоји да превазиђе основно ограничење традиционалних хипермедијалних апликација које се огледа у чињеници да ове апликације нуде исте садржаје и исти скуп линкова свим корисницима, без обзира на различитост њихових потреба, циљева и нивоа познавања области која се проучава. АН има за циљ да унапреди ефективност хипермедијалних апликација тиме што ће их учинити персонализованим (Khan, 2018).

Развој адаптивних хипермедијских система (АНС) се може пратити уназад до раних 1990-тих година. Хипермедијски модел је проширен коришћењем модела корисника. АНС инспирисани ITS системима су покушали да комбинују адаптивне образовне системе и системе засноване на хипермедији. Брусировски (Brusilovsky, 2004) даје дефиницију АНС система:

„Под адаптивним хипермедијским системима подразумевамо све хипермедијске и хипертекстуалне системе који рефлектују неке карактеристике корисника у моделу корисника, и примењују овај модел за прилагођавање бројних видљивих аспеката система према кориснику.“

Дакле према (Brusilovsky, 2004) да би се један систем могао сматрати АН системом, он мора да задовољи следећа три критеријума: да је хипертекстуални или хипермедијални систем; да поседује модел корисника; да има способност адаптације хипермедије/хипертекста према том моделу. За сада АНС се користе у образовним системима, е-пословању, информационом системима и help системима.

Брусиловски (Brusilovsky, 2004) разликује два различита типа АНС система, у зависности од метода адаптације. Прва група прилагођавање обавља помоћу адаптивне презентације, омогућавајући адаптацију садржаја, који може бити презентован на различите начине и по другом редоследу. Адаптација садржаја се може обавити према различитим детаљима, степену сложености и коришћењу медија, а све у циљу задовољења различитих потреба корисника, различитих нивоа претходног знања, стила интеракције и когнитивних карактеристика. Адаптација навигације се постиже кроз тзв. подршку адаптацији навигације. Подршка адаптацији навигације може бити имплементирана као директно упуство, променљиви линкови (скривање или промена редоследа доступних линкова на страни), анотација линкова, адаптација мапе, онемогућавање линкова и уклањање линкова.

Може се закључити да постоје два основна облика адаптације у АН системима:

- адаптација на нивоу садржаја (content adaptation (Khan, 2018), adaptive presentation (Brusilovsky, 2004) – садржај се обликује тако да задовољи потребе и очекивања сваког појединца, нпр. сакривањем одређених информација или додавањем објашњења.
- адаптација на нивоу линкова (link-adaptation (Khan, 2018), adaptive navigation (Brusilovsky, 2004) – основна идеја је да се корисник усмери на оне линкове који воде ка њему интересантним и/или релевантним информацијама. Циљ је комплексну структуру линкова учинити једноставнијом и тиме елиминисати (или бар ублажити) проблем оријентације у хипермедијалном простору, а при томе ипак кориснику остави што већи степен слободе при навигацији.

Увођење хипермедија и web технологија је имало великог утицаја на адаптивне наставне системе, али ипак постоје нека ограничења за АНС системе. Према неким истраживањима мало је емпиријских доказа ефикасности АНС система. Де Бра тврди да уколико су претходно дефинисане релације изостављене или су само погрешне, корисник ће можда бити упућен на страну коју неће разумети због недостатка захтеваног предзнања из те области. Друга битна ставка је то да иста страна може изгледати другачије приликом поновне посете. Када се документ прилагођава моделу корисника у развоју, онда је могуће да нека страна изгледа другачије сваки пут када је корисник наново посети. Ово може збунити корисника и проузроковати његову дезоријентацију у систему.

Де Бра (De Bra, 2000) закључује да АНС системи имају потенцијал да кориснику омогуће слободу путем навигације кроз образовне садржаје и наставне материјале. Дакле, корисници могу бити уверени да је представљени образовни материјал релевантан и сасвим разумљив.

Адаптивни образовни хипермедијски системи

Средином 1990-тих појављују се први АНС системи намењени домену образовања. Услед све интензивнијег интересовања истраживачких кругова за овај домен примене АНС система, развила се и посебна дисциплина истраживања под називом Адаптивна Образовна Хипермедија (Adaptive Educational Hypermedia - АЕН).

Подтип АНС система су адаптивни образовни хипермедијски системи (Adaptive Educational Hypermedia Systems – АЕНС). Као што сам назив говори, АЕНС се примењују у домену образовања. Овај тип система се заснива на АНС. Хиперпростор за АЕНС је

врло мали јер се документа односе на специфичне теме. Фокус моделовања корисника је на домену знања корисника (Brusilovsky, 2017).

АЕНС системи врше адаптацију на три нивоа: конективност, садржај и културолошки аспекти. Ова три нивоа у литератури на енглеском језику позната су као 3С: Connectivity, Content & Culture (Papadimitriou & Gyftodimos, 2017):

- конективност је оно што разликује хипермедију од класичних књига: информациони сегменти међусобно повезани на различите начине омогућују студентима избор између мноштва различитих путања кроз образовне садржаје. Адаптација на овом нивоу подразумева да систем прави визуелну разлику између линкова зависно од њихове погодности и/или релевантности за конкретног ученика.
- адаптација садржаја подразумева давање додатних информација студентима којима су оне потребне (како би се компензовао недостатак потребног предзнања) као и уклањање оних информација које студенту нису потребне (има потребна знања о концептима које описују или није још увек припремљен за њих). Процес адаптације базиран је примени једне или комбиновању више метода и техника адаптације на нивоу садржаја (Brusilovsky, 2017).
- културолошки аспекти адаптације односе се на чињеницу да се ученици разликују и са аспекта тога како најбоље уче – тзв. стил учења. Свака АЕН апликација мора у процесу адаптације узети у обзир и специфичност стила учења сваког ученика.

Генеричку архитектуру АЕН система чине следеће четири основне компоненте (Khan, 2018):

- доменски модел (енгл. domain model) дефинише структуру доменске области за коју је АЕХ апликација намењена, односно, применом одређеног формализма, описује доменске концепте и њихове међусобне релације.
- модел ученика (енгл. student model) описује основне карактеристике ученика, а међу њима првенствено ниво знања ученика о концептима доменског модела.
- педагошки модел (енгл. pedagogical model) садржи педагошка правила која дефинишу услове „приступа“ ученика појединим деловима апликационог домена. Велики број ових правила произилази директно из структуре доменског модела. Остала правила су одређена изабраним инструкционим приступом.
- механизам адаптације (енгл. adaptive engine) је конкретно софтверско окружење које врши креирање и адаптацију садржаја и линкова. Адаптациони механизам користи информације из доменског модела, модела студента и педагошког модела да би од расположивих сегмената едукативних садржаја креирао једну кохерентну целину прилагођену потребама конкретног ученика.

Персонализација у контексту Семантичког Web-a

Педагошки агенти

Педагошки агенти су аутономни софтверски ентитети који обезбеђују подршку процесу учења кроз интеракцију са студентима, наставницима и осталим учесницима процеса учења, као и колаборацију са другим сличним агентима. Приступу персонализацији засновани на технологији интелигентних агената подразумевају да сваки студент има свог личног (педагошког) агента, који га заступа у систему агената (Hussein & Al-Chalabi, 2020). Улога таквог агента је да прикупља, одржава и анализира податке о студенту, коме је додељен, и да на основу тих података врши адаптацију садржаја/линкова/активности који ће бити понуђени студенту. Агент је често у обавези да коминира са агентима других студената, и кроз ту комуникацију омогући свом студенту да нађе најбољу особу за рад (Wang, Xia, He, Tian, Qin, Zhai & Liu, 2019). Као и у осталим приступима персонализацији, и у случају агената, целокупан процес је базиран на моделу студента.

Значајна карактеристика педагошких агената је то што су они на мала врата увели онтологије у област персонализованог учења (Devedžić, 2006; Jovanović, 2006; Jeremić, Jovanović & Gasević, 2013). Рад педагошких агената зависи не само од постојања онтолошког модела студента, већ и од расположивости других релевантних онтологија – доменске онтологије, онтологије инструкционог приступа и сл. – које ће им омогућити да разумеју захтеве студената и одговоре на њих на персонализован начин (Hussein & Al-Chalabi, 2020).

Онтологије

Примена онтологија за реализацију персонализованог учења већ неколико година представља врло актуелан правац истраживања у AIED (Artificial Intelligence in Education) заједници. Онтологије се користе за представљање: области која је предмет учења (доменске онтологије), података о студентима (онтологија модела студента), инструкционих/педагошких приступа (онтологија инструкционог дизајна) и сл. У даљем тексту су укратко описана два приступа коришћењу онтологија за динамичко креирање персонализованих образовних садржаја.

Dynamic Assembly Engine је систем који омогућује динамичко креирање једноставних, кратких курсева фокусираних на специфичне информационе потребе корисника. Поступак креирања персонализованих курсева обухвата: претраживање репозиторијума образовних објеката у складу са формулисаним захтевом корисника, повезивање резултата претраге и формирање иницијалне путање учења (*learning path*), затим дефинисање редоследа релевантних LOs у оквиру путање и на крају, формирање једне организоване, кохерентне целине за учење (Јовановић, 2006; Jovanović et al, 2006a) . Адаптација се заснива на постављеном упиту корисника, што указује да је реч о реактивном систему.

Конкретно, систем полази од: 1) кључних речи које описују област о којој корисник жели да учи, 2) време које корисник има на располагању за учење и 3) степен детаљности (*overview* и *indepth* као две могуће опције) (Jovanović et al, 2006; Wang, Luo, Lin & Wang, 2017). Карактеристика овог система је да се студенту препушта иницијатива, јер аутори сматрају да се већим ангажовањем студента, односно његовим директним укључивањем у поступак креирања курса, студент подстиче на размишљање о томе шта би требало да научи и/или уради. Услед тога, овај систем је у стању да динамички креира курс који ће омогућити превазилажење недостатака у знању студента, али само у оном

степену у коме је студент свестан постојања тих недостатака, тј. свог незнања. За описивање семантике LOs, аутори (Wang et al, 2017) користе концепте доменске онтологије (домен: WebSphere и њој сродне IBM технологије).

TANGRAM је Web апликација намењена адаптивном учењу домена интелигентних информационих система (IIS) (Jeremić et al, 2013) . Адаптација се у овом систему огледа у креирању садржаја прилагођених текућем нивоу знања ученика о доменској области (IIS), његовом стилу учења и преференцама по питању аутора и језика.

Такође, омогућен је брз приступ образовним садржајима задатог типа, који обрађују задати доменски концепт, на пример, приступ дефиницијама (тип садржаја) Семантичког Web -а (доменски концепт). TANGRAM је у потпуности заснован на технологијама Семантичког Web-а, и то првенствено онтологијама. Конкретно, систем је базиран на следећим онтологијама: 1) ALOCoM Content Structure Ontology – онтологија структуре садржаја која представља основу за декомпозицију LOs у TANGRAM-у; 2) ALOCoM Content Type Ontology – онтологија којом су формално дефинисане потенцијалне инструкционе/педагошке улоге образовних компоненти; 3) IIS Domain Ontology – доменска онтологија која формално описује концепте IIS домена и њихове међусобне релације; 4) Learning Paths Ontology – онтологија којом се формално дефинише оптимални начин кретања студента кроз концепте доменске области, односно путања коју би требало следити да би учење било што успешније; 5) User Model Ontology – онтологија модела корисника TANGRAM-а, која обједињује формализме за представљање информација о студентима и ауторима образовних садржаја. Такође, систем дефинише и користи IEEE LOM профил намењен описивању LOs и њихових компоненти метаподацима (Јовановић, 2006; Premlatha & Geetha, 2015; Jeremić et al, 2013).

Web сервиси

Развој персонализованих e-Learning система коришћењем технологије Web сервиса представља један је од тренутно најактуелних праваца истраживања у овој области. Флексибилност и модуларност коју Web сервиси обезбеђују су од изузетног значаја за креирање система способних да се прилагоде различитим корисницима и ситуацијама. У наставку текста описане су два система која кроз композицију Web сервиса остварују персонализацију.

Personal Readers представља софтверску архитектуру намењену креирању и одржавању e-Learning апликација које кориснику пружају персонализоване информације о тренутно приказаном садржају, као што су препоруке додатних, потенцијално релевантних садржаја, приступ општијим/детаљнијим информацијама, приступ примерима, задацима за вежбу, тестовима провере знања и сл (Henze, 2005). Основни принцип на коме је заснована ова архитектура је да се различити облици персонализације које систем обезбеђује реализују у форми Web servisa које координира сервис медиатор. Сваки од сервиса извршава један специфичан облик персонализације LOs, и то на основу метаподатака којима су LOs описани, информација о кориснику (студенту) и одговарајућој доменској онтологији.

Због своје дистрибуиране природе, ова архитектура се ослања на стандарде. Тако, на пример, метаподаци којима су описани LOs морају бити потпуно усклађени са IEEE LOM стандардом како би их систем могао користити.

Доменска онтологија се користи за описивање семантике LOs. Још један интересантан приступ персонализацији заснован на примени Web сервиса развијен је у оквиру

iClass25 пројекта (Bachari, 2011). Ова софтверска архитектура састоји се од већег броја e-Learning (Web) сервиса, међу којима Selector, LO Generator и Presenter имају централну улогу у персонализацији учења. Selector сервис креира персонализовану путању учења која обухвата скуп доменских концепата (тј. сегмент доменске онтологије) о којима би студент требало да учи, ораганизованих у складу са изабраним педагошким приступом. LO Generator сервис је одговоран за селекцију/агрегацију LOs који одговарају путањи учења коју је Selector сервис претходно креирао. Овај поступак је заснован на расположивим информацијама о студенту (на пример, преференце у погледу начина учења), наставнику (на пример, преферирани педагошки приступ) и контексту учења (на пример, тип уређаја). Последњи у низу, Presenter сервис приказује креирани курс студенту. Ова софтверска архитектура је још увек у фази развоја, услед чега описани сервиси још увек не користе пуне потенцијале које онтологије омогућују – на пример, LO Generator сервис није у могућности да врши семантичку претрагу (тј. претраживање засновано на доменској онтологији), већ се претраживање заснива на кључним речима и њиховом упаривању са метаподацима којима су LOs описани.

Док је у описаним софтверским архитектурама композиција Web сервиса унапред дефинисана (тј. испрограмирана), у случају семантичких Web сервиса то није потребно, с обзиром да су ови сервиси, захваљујући експлицитно дефинисаној семантици (улаза, излаза и процеса који извршава), у могућности да се сами међусобно проналазе и комбинују. Истраживања везана за семантичке Web сервисе су тек у повоју, тако да је персонализација заснована на самосталном комбиновању Web сервиса у једну кохерентну целину још увек само визија (Јовановић, 2006; De, Zhou & Moessner, 2017).

Хибридно учење

Са порастом образовне ICT технологије, школе су усвојиле нове наставне моделе, које се разликују од типичног, традиционалног окружења у учионици. Учење на даљину, првенствено е-учење, се користи на глобалном нивоу, а многе образовне институције примењују хибридне моделе учења.

Хибридно учење (мешовито учење, енг. blended learning) је образовни модел у коме неки студенти похађају наставу традиционално, док се други придружују настави онлајн. Наставници подучавају и једне и друге студенте, користећи различите хардверске и софтверске алате (за видео конференције, LMS, онлајн платформе, Skype итд.).

У неким случајевима хибридно учење укључује асинхроне елементе учења, попут онлајн вежби и унапред снимљених видео упутства, како би се подржале наставне сесије лицем-у-лице (енг. face-to-face, F2F) (Goodyear, 2020). Хибридно окружење за учење комбинација је свих модела класичне наставе. Хибридни приступ учењу надовезује се на позитивне особине ових модела, како би се циљано створило окружење усмерено на студента, које је значајно персонализовано, релевантно и привлачно.

Када се добро планирају, хибридни курсеви комбинују најбоље аспекте класичног и онлајн е-учења, док многим студентима чине образовање доступнијим. Да би хибридно учење било успешно, елементи образовног хибридног курса морају бити прилагођени формату учења, било да је оно класично или онлајн (Арсовић, 2012).



Слика 12: Хибридно учење

Хибридно учење флуидно комбинује оно најбоље из класичног и онлајн е-учења, са ангажовањем ИСТ. То је начин да се побољша и оснажи учење, обезбеђивањем приступа усмереног на студенте, а ради поштовања компетенција и задовољавања њихових различитих образовних потреба. Да би се такво окружење за учење створило, образовне институције морају створити како физичко, тако и виртуелно образовно окружење, које погодује динамичним интеракцијама са студентима, који су било присутни или физички удаљени (Evans, Yip, Chan, Armatas & Tse, 2020).

Наставници су навикли на лично подучавање, имају успостављене протоколе, процедуре и очекиване моделе понашања студената, установили су наставне активности и задатке. Укратко, управљање наставом и ток рада у класичној настави су добро устаљени. У хибридном моделу, наставници морају да презентују курс двомодално, како би могли да изађу у сусрет и присутним студентима и онима који наставу похађају даљински. При преласку у хибридно окружење за учење, неопходно је створити виртуелна образовна окружења, помоћу разних платформи за е-учење, које су добро средство за обезбеђивање континуитета и флексибилности. Такве платформе и LMS, као дигитална чворишта за хибридне учионице, омогућавају наставницима да се повежу са студентима у онлајн позивима, креирају и прикупљају задатке, деле ресурсе и олакшавају сарадњу свих учесника, било да присуствују лично или виртуелно (Rasheed, Kamsin & Abdullah, 2020). Наставници такође могу да интегришу друге ресурсе и апликације у оквиру LMS, чинећи га централизованим простором за учење.

Табела 5: LMS као платформа за хибридно учење – особине и предности

ПЛАТФОРМА		СТУДЕНТИ	НАСТАВНИЦИ	ШКОЛСКО ОСОБЉЕ	ПОРОДИЦА
<i>LMS</i>		<ul style="list-style-type: none"> • Сарадња на часу • Сарадња међу студентима • Задаци и задужења 	<ul style="list-style-type: none"> • Сарадња на часу • Професионално усавршавање • Задужења студентима 	<ul style="list-style-type: none"> • Сарадња особља • Састанци уживо 	<ul style="list-style-type: none"> • Седмични извештаји о напредовању студента
<i>Email</i>		<ul style="list-style-type: none"> • Формална комуникација 	<ul style="list-style-type: none"> • Формална комуникација 	<ul style="list-style-type: none"> • Формална комуникација 	<ul style="list-style-type: none"> • Формална комуникација
<i>Stream</i>		<ul style="list-style-type: none"> • Сигурни и проверени видео снимци 	<ul style="list-style-type: none"> • Сигурни и проверени видео снимци 	<ul style="list-style-type: none"> • Сигурни и проверени видео снимци 	
<i>Cloud disc drive</i>	<i>лични</i>	<ul style="list-style-type: none"> • Лично складиште података 	<ul style="list-style-type: none"> • Лично складиште података 		
	<i>школски</i>	<ul style="list-style-type: none"> • Web сајт и платформа 	<ul style="list-style-type: none"> • Дељено складиште података • Web сајт 	<ul style="list-style-type: none"> • Дељено складиште података • Web сајт и платформа 	
<i>Forms</i>		<ul style="list-style-type: none"> • Истраживања, анкете • Квизови, тестови 	<ul style="list-style-type: none"> • Истраживања, анкете • Повратне информације 	<ul style="list-style-type: none"> • Истраживања, анкете • Повратне информације 	<ul style="list-style-type: none"> • Истраживања, анкете • Повратне информације
<i>Алати за учење</i>		<ul style="list-style-type: none"> • Translator • Reader 	<ul style="list-style-type: none"> • Translator – за комуникацију са студентима и родитељима 	<ul style="list-style-type: none"> • Translator – за комуникацију са студентима и родитељима 	<ul style="list-style-type: none"> • Translator – за комуникацију са студентима и родитељима

Квалитетно учење се гради, првенствено на интересима студената, поштујући аспекте: повезивања са сврхом и значењем, охрабривања студената да имају висока очекивања, постављање циљева учења који су изнад основа, коришћење ангажоване педагогије, изградња релација и припадности и пружање прилика за друштвени допринос (Pittich & Tenberg, 2020). Како образовне институције прелазе на хибридне моделе образовања и наставе, то им се пружа прилика да премоделују образовни процес и изграде окружење за учење које укључује све димензије квалитетног искуства учења.

Наставници се могу припремити за хибридно виртуелно окружење за учење применом специфичних стратегија за сваки елемент хибридног учења:

- образовно окружење
- радна група
- дизајн лекција
- ангажовање и интерактивност
- процена и повратна информација.



Слика 13: Имплементација стратегија сходно елементима хибридног учења

3. ПРЕГЛЕД РАЗЛИЧИТИХ ТИПОВА И МОДЕЛА АДАПТИВНИХ СИСТЕМА ЗА Е-УЧЕЊЕ И НАПРЕДНУ АНАЛИЗУ ПОДАТАКА

3.1. Креирање адаптивних образовних e-Learning система

Адаптивни, образовни системи представљају актуелну и, тренутно, најмодернију технологију, која даје јединствену предност у односу на традиционални образовни систем, а то је могућност адаптирања према корисничким потребама, циљевима, могућностима и захтевима. Адаптивни образовни системи све више постају део стандардног, свакодневног образовања, али ипак не постоји тачно одређен, дефинисан начин за њихово дизајнирање – већина их се развија ad-hoc.

Адаптивни e-Learning систем се, према (Stoyanov & Kirschner, 2017), описује као: „Адаптивни e-Learning систем је интерактивни систем који персонализује и прилагођава (адаптује) e-Learning садржаје, педагошке моделе и интеракцију међу учесницима у окружењу, да би на тај начин изашао у сусрет индивидуалним потребама и склоностима корисника ако и када се оне појаве.“

Према томе, адаптивни e-Learning систем има све одлике адаптивних система. Као што је већ описано у поглављу 2.5 поједине информације о кориснику су неопходне да би се променило понашање система, у циљу задовољења потреба тог корисника. У адаптивним системима се ове информације похрањују у профилу или моделу корисника (ученика, студента). Отуда је детаљан профил корисника, тј. модел корисника неопходан да би се обезбедила адаптивност система.

У контексту е-учења, адаптација наставе је подржана. Настава је форма образовања ученика. Постоји више могућности и начина адаптирања, прилагођавања наставе, а теоријски приступ адаптацији наставе је детаљно описан у делу 2.4 и 2.6.

Адаптивни Web оријентисани образовни систем (Adaptive Web Educational System - AWES) је динамичка web апликација, која омогућава стварање образовног окружења по мери корисника/студента, а кроз прилагођавање како презентације садржаја, тако и навигације кроз исти. Такав систем се састоји од образовних ресурса, као и од скупа алата који омогућавају процес изучавања/учења (као што су тестови/упитници, речници, комуникациони алати итд.) (Sweta, 2021). Образовни садржај, динамички генерисан, се заснива на педагошким правилима, којима се комбинује модел садржаја (домена) са моделом корисника. AWES су актуелна тема истраживања у домену адаптивних хипермедијских апликација. AWES системи обезбеђују персонализован, један-на-један турски систем, прилагођен специфичним карактеристикама сваког појединачног студента, а не излаже један те исти садржај свим корисницима. Неке образовне институције теже развијању сопствених AWESs у циљу имплементирања и тестирања сопствених теорија о учењу или метода наставе.

Међутим, дизајнирање и имплементација система је комплексан задатак. У тај задатак су укључени експерти из различитих области, као што су софтверски стручњаци, Web-апликатор експерти, креатори садржаја, експерти за ресурсе, наставници, моделинг експерти и педагози...

Ови системи имају презентационе, бихевиористичке, педагошке и структуралне аспекте, који се морају узети у обзир приликом њиховог креирања. Да би све било компликованије и сложеније, већина AWESs се развија и дизајнира на основу скица, без узимања у обзир искустава из претходно дизајнираних система; јер њихови дизајни нису кодирани или документовани. Решење које се намеће је коришћење дизајн-шема (образаца), тако да се ови системи у будућности више не дизајнирају и развијају из скица, већ да се заснивају на искористивим искуствима из области дизајна, добијеним током рада на претходним пројектима (Ennouamani & Mahani, 2017). Шта више, добар дизајн се може направити експлицитно и може бити доступан целој заједници дизајнера, тако да постаје уобичајена пракса. На овај начин, дизајнери нових или постојећих AWESs, поготово они неискусни, могу искористити искуства из претходних дизајна и на тај начин уштедети и време и ресурсе.

Као што је већ, кроз претходно изложено, напоменуто, главни проблем у развоју адаптивног e-Learning система, представљају сложеност процеса, високи трошкови и дуг временски период који су потребни за развој оваквог система. Тренутно су за развој типичног адаптивног e-Learning система потребни високо стручни тимови који се састоје од технолога, програмера, експерата из изучаване/обрађиване области. Захтева се значајан труд у интеграцији адаптивних техника, педагогије и наставног плана. Према томе, процес развијања и креирања адаптивног e-Learning система, захтева и претпоставља сарадњу више експерата.

Методологија развоја и креирања

Развој ма ког e-Learning курса обично прати документација са ауторизованим процесом, који доноси регулисан наставни план циљева учења и техника процене, преко којих се ови циљеви процењују. Наставни план затим регулише концепте везане за предмет, који су прикладни за курс, са израженим циљевима и проценама. На крају се креирају наставне стратегије, које одговарају регулисаном плану и стратегија развоја која осигурава континуално унапређивање курса (Kukartsev, Chzhan, Tynchenko, Antamoshkin & Stupina, 2018).

У циљу креирања адаптивног e-Learning система, неопходно је идентификовати главне фазе и захтеве. Процес развоја регулисаног наставног плана је итеративан, што значи да обично постоји филтрирање циљева, процена, наставних стратегија и предмета да би се осигурао конзистентан и добар курс (Mudrák, Turcani & Burianová, 2018). Овај итеративни процес приказан је на слици 14.

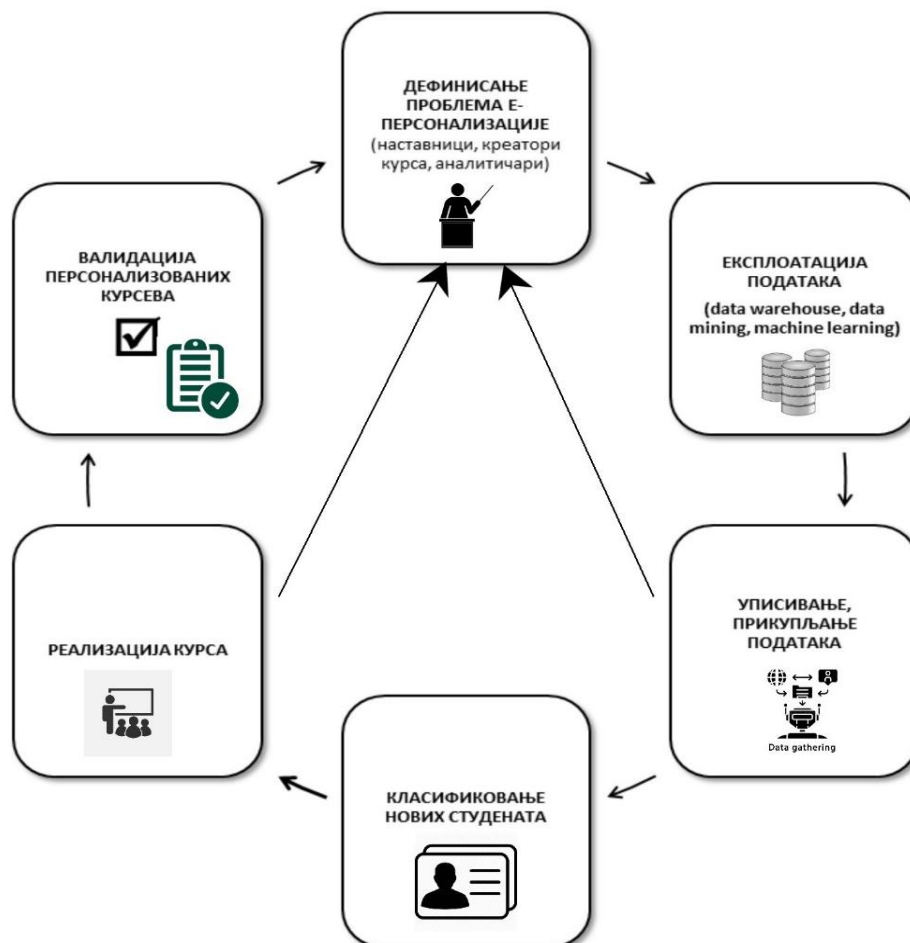


Слика 14: Методологија конструкције адаптивног e-Learning курса

Методологија конструисања адаптивног система за е-учење мора:

- олакшати специјализацију различитих типова адаптивности који треба да се уграде у сам дизајн
- олакшати поновну употребу и модификацију једног или више наставних планова
- олакшати идентификацију појмова предмета
- охрабрити предности вишеструке употребе садржаја или употребу модела елемената (Shershneva, Vainshtein, Kochetkova & Esin, 2019).

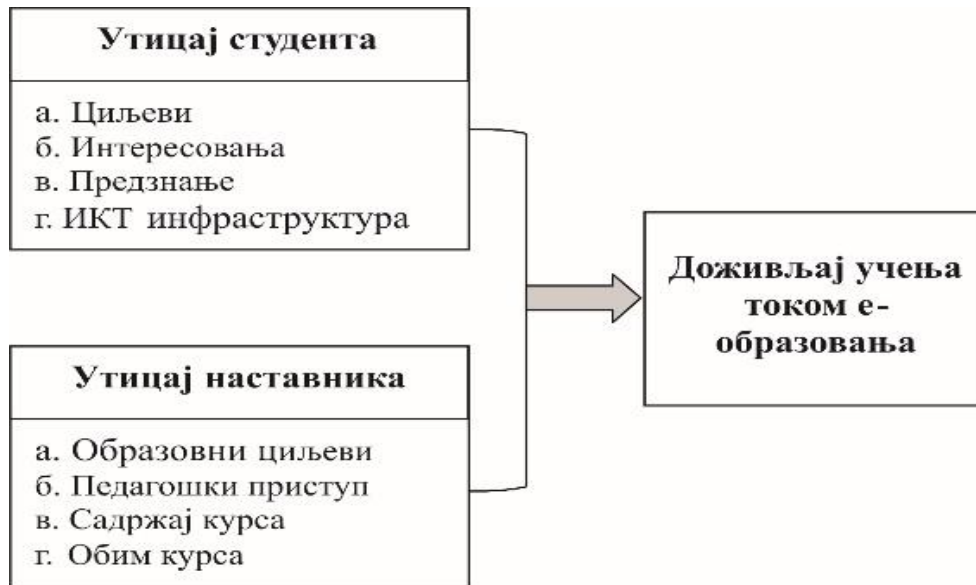
Методологија за конструкцију адаптивних курсева не спецификује тачан садржај курса, али дефинише појмове везане за предмет и адаптивне особине на којима би требало да се заснива избор садржаја. Ова методологија би требало да подржава аутора курса у идентификовању оних делова курса који треба да се адаптирају, као и критеријума који би требало да се користи за адаптацију (Shershneva et al, 2019). На пример, креатор курса би требало да специфицира цео курс тако да он буде базиран на претходном знању корисника, али специфичне активности би требало да буду базиране на комуникационом и колаборативном стилу студента. На слици 15 су приказани кораци/фазе могуће развојне методологије, које треба посматрати као интегрисане елементе итеративног и динамичког процеса развоја адаптивног е-Learning система.



Слика 15: Фазе у развоју адаптивног elearning система

Композиција адаптивног e-Learning система/курса

Композиција адаптивног e-Learning курса захтева улаз различитих моделираних ентитета. Ентитети, као што су студент, наставник, ширина појмова, педагошке стратегије, активности учења, садржај и адаптивни механизми, имају утицај на композицију и реализацију адаптивног курса (Terzieva & Rahnev, 2018). На пример, структура и обим курса, као и циљеви курса могу бити под утицајем и студента и наставника. Наставна стратегија курса може бити под утицајем природе наученог градива, циљева курса и особина студента који ће да похађа курс. Сви ови модели могу бити коришћени као механизми закључивања персонализованог курса. Улога сваког модела се разликује унутар процеса композиције адаптивног курса (Ahmed, Sangi & Mahmood, 2018).



Слика 16: Фактори утицаја на субјективни доживљај током образовног процеса

Саставни део процеса креирања курса је представљање поља знања. То омогућава експерту из дате области да моделира знања и праксу у вези предмета учења и формира логичку таксономију за поље знања. Током процеса креирања курса, одлуке се доносе на основу информација добијених у овом моделу. Сваки елемент у моделу је појам. За сваки појам постоји име, опис, листа сличних појмова и листа ресурса потенцијалних кандидата. На пример, информације ускладиштене у оквиру појма се могу користити при доношењу одлука базираних на способностима студената.

Слика 16 показује тип улаза, заснован на укључености студента и наставника који утичу на процес учења. Модел студента садржи информације о способностима, циљевима, предзнању, и могућностима студента, а модел наставника садржи информације о стратегијама предавања и циљевима.

Главни циљ мулти-моделског приступа персонализованом e-Learning-у подразумева оспособљавање студента за разумевање градива (Ahmed et al, 2018). Студент треба да контролише своје учење и да може да мења начине учења. Модел студента је дефинисан као шема која представља карактеристике студента.

Кроз online учење повећана је активност и самомотивација код студента. Са порастом online учења, учења на даљину и адаптивног учења, развија се парадигма наставног дизајна. Активности учења се обично састоје од неколико формалних захтева, повезаних

са алатима који извршавају ове захтеве и одговарајућег садржаја учења. Активности учења могу бити структурно моделоване тако да омогуће јединице инструкција које се могу виšekратно користити. У циљу безболног и ефикаснијег укључивања активности учења у процес креирања персонализованог курса, важно је направити флексибилан и дескриптиван модел активности учења. Модел се састоји од описа активности учења, типа активности, типова излаза које може да произведе и типова комуникацијских алата који су доступни (e-mail, chat, инстант поруке, итд.). Ове активности могу имати облик атомске или сложене активности. Овакав флексибилан приступ моделовању повећава потенцијал вишеструке употребе, приступачности и интероперабилности активности учења (Elmabaredy, Elkholy & Tolba, 2020).

Припрема, развој и креирање образовних објеката и садржаја

Данашње e-Learning системе карактерише једносмерни тока података, што представља недостатак. Када је реч о недостацима ту су и недостаци актуелних e-Learning спецификација и стандарда. Потребно је истаћи да су недостаци идентификовани првенствено са аспекта реализације напредних e-Learning сервиса који би требало да:

- обезбеде виши степен персонализације процеса учења,
- повећају ефикасност и ефективност размене образовних садржаја између e-Learning система,
- допринесу подизању нивоа интероперабилности између хетерогених e-Learning система и алата (Peng, Ma & Spector, 2019).

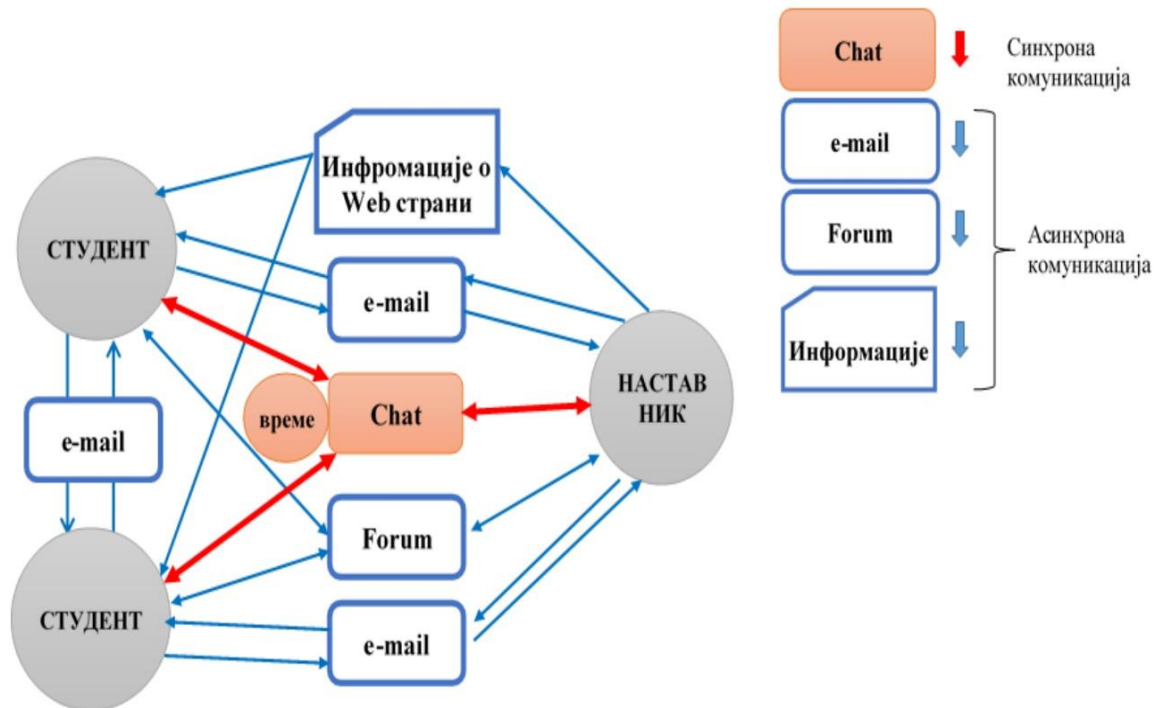
Уколико нам је циљ омогућавање реализације ових напредних сервиса, онда је поред придруживања прескриптивних метаподатака (попут IEEE LOM метаподатака) образовним објектима, потребно на неки начин омогућити и експлицитно представљање релевантних карактеристика свих оних ситуација у којима су LOs били коришћени, као додатног, а врло релевантног извора информација. Другим речима, потребно је располагати информацијама о *контексту образовног објекта* (енгл. *learning object context*) – специфичном контексту коришћења одређеног LO (Musumba & Wario, 2018).

Подаци о контексту коришћења LO су од изузетног значаја и за наставнике. Приликом креирања наставног садржаја и асемблирања LOs у веће наставне целине (тј. инструкционе планове), наставници увек полазе од одређених претпоставки везаних за студенте и сам процес учења: претпоставки које се односе на искуство, знање и вештине студената, на њихове преференце, стил учења, циљеве и мотивацију; претпоставке које се тичу расположивог времена и опреме и сл. Ове претпоставке чине оно што ми овде називамо *контекстом* – јединствени скуп “ситуационих“ података који имплицитно одређује начин на који би образовни садржаји требало да буду организовани за конкретног студента (или групу студената сродних карактеристика) (Musumba & Wario, 2018).

Потребно је истаћи и то да подаци о контексту омогућују успостављање кружног тока информација у једном e-Learning систему и на тај начин доприносе константном унапређењу процеса учења. Конкретно, ови подаци се могу користити за генерисање релевантних повратних информација за све учеснике у процесу учења – ауторе образовних садржаја, наставнике и студенте.

Да би одговорио на изложене захтеве, концепт контекста образовног објекта мора да обухвати податке о следећим чиниоцима процеса учења:

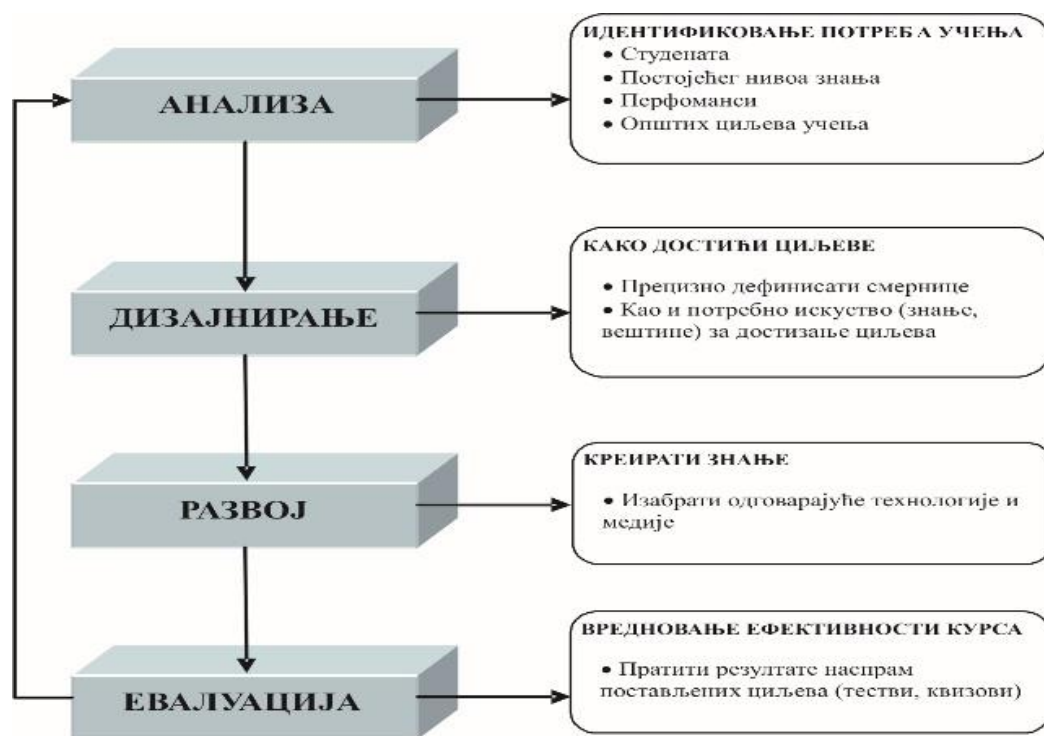
- садржајима намењеним учењу (представљеним у форми LO),
- активностима учења,
- актерима (студентима и наставницима) (Raj & Renumol, 2018).



Слика 17: Двосмерна комуникација

Укратко, контекст се односи на студента (или групу студената) који ступа у неки облик интеракције са образовним садржајима, кроз одређену активности учења (нпр. читање, решавање тестова, ћаскање у причаоницама) и то ради остваривања одређеног циља.

После горепоменутог разматрања, може се рећи да су образовни садржаји можда најважнији елемент е-Learning образовања. Код традиционалног образовања, они представљају само подршку наставном процесу, у коме главну улогу има наставник. Код е-Learning образовања, образовни садржаји представљају главни извор нових знања и вештина. Истовремено су и контролори тока наставног процеса, јер сваког студента воде кроз процес обуке и усмеравају ка жељеном циљу. Њихова улога је веома комплексна, а утицај на квалитет и резултат е-Learning образовања пресудан. Процес припреме и развоја е-материјала за потребе е-Learning образовања је циклус од четири фазе: анализа, дизајнирање, развој и евалуација (слика 18).



Слика 18: Припрема и развој електронских образовних материјала

У процесу израде електронских образовних садржаја, треба узети у разматрање особености е-предавања и учења (Rozo & Real, 2019):

- предавања у договорено време
- потпуно индивидуализовано учење
- учење у произвољном термину
- учење на било ком месту
- учење уз одговарајући уређај.

Када су у питању трошкови, технологија и потребни ресурси, може се закључити да су главне карактеристике образовања на даљину у односу на класично образовање следеће:

- нижи трошкови реализације образовања
- виши трошкови развоја уџбеника
- брже учење
- потребна су нова знања и вештине
- неопходан развијен одсек за подршку
- јефтинији хардвер и софтвер
- нема путовања и одсуства са радних места

- могућност вишекратне употребе знања. Конверзија традиционалног у електронски уџбеник врши се постепено, проширујући у свакој итерацији ниво примене е-садржаја и интеракцију између учесника у образовном процесу:
- репликација материјала без интерактивности
- подршка аудио и видео записима
- интеракција типа вредновање одговора на постављена питања
- интеракција кроз евалуацију савладаног, лимитирање даљег приступа док се не савлада задатак, доношење одлука у симулацији реалне ситуације
- потпуна интеракција и вођено учење кроз подршку решавању конкретних задатака – симулације, сценарија, практичне вежбе, оцена решења и одлука (Rozo & Real, 2019).

Друга основна функција је складиштење података. Када се говори о складиштењу, не мисли се на класично одлагање информација, већ на њихово постављање у јавни домен, објављивање и стављање на располагање свим посетиоцима Интернета. Не постоји ограничење у типовима података и информација које се могу постављати на Интернет, тако да буквално све што може да се преведе у дигиталну форму, може и да се постави на Интернет. Наиме, због природе Интернета као интерактивног виртуелног медија, сваки појединац који има приступ Интернету може да објави своје личне садржаје различите природе. Образовни садржаји не морају да буду у текстуалној форми, већ управо због особине дигитализације, могу да буду и визуелни и звучни - мултимедијални. Овај додати сегмент образовних садржаја представља линију која раздваја процес образовања у локалној мрежи и преко Интернета. Образовни садржаји могу бити доступни и преко локалних мрежа, интранета. То значи да је количина доступних информација ограничена на већ прочитане и прегледане садржаје и самим тим окарактерисана као корисна.

Колаборација у процесу креирања

Сматра се да дигитализовани, електронски наставно/образовни материјали нису довољни, јер су дидактички материјали постали више од садржаја и укључују наставни дизајн, који управља процесом наставе и учења. Из свега до сада реченог и размотреног овакав став се намеће као логичан закључак.

Потребно је темељно размотрити скуп аспеката, технолошких дисциплина и спецификација, које су укључене у развој дидактичких материјала за elearning. Све те чињенице и форме, које називамо садржајем технолошки подржаних наставних материјала, су представљене на слици 19. Контекст технолошко подржаних дидактичких материјала је анализа структуре, којом се технолошки подржани наставни материјали разматрају као коњункција садржаја и процеса учења/наставе, којом управља наставна концепција.

Образовни процес се може посматрати као процес од два дела: планирања и примене. Први се односи на анализу образовних захтева, дизајна и планирања, имплементацију и конфигурацију и а priori евалуацију свих активности и помоћних средстава, као и извора који ће се користити током другог дела образовног процеса – примене. Образовни материјали су директно укључени у оба процеса. Они су резултујући продукт процеса развоја (планирања), а користе се као подршка и помоћна средства у процесу остваривања наставе (процеса примене), током образовног процеса.



Слика 19: Шема развоја образовних е-материјала

Потребно је размотрити велики број аспеката, када говоримо о планирању, развоју и креирању наставних материјала. Ови аспекти обезбеђују пожељне карактеристике дидактичких материјала, који су битни током развоја (планирања) сваког наставног процеса.

Можемо их сажети у:

- вишекратност
- уклопљен или повезани семантички карактер
- колаборативна подршка
- и друге, као што су квалитет и корисност (Арсовић & Стефановић, 2010).

Вишекратност и семантичка интероперативност

Вишекратност као особина дидактичких материјала је заснована на могућности њихове употребе у различитим образовним ситуацијама и окружењима, као и у различитим образовним подручјима. Вишекратност и уклопљеност или повезаност семантичког карактера су блиско повезане особине. Вишекратност се може остварити, уколико материјал има уграђену или је повезан са неком врстом семантичке информације. То значи да би дизајнери и планери дидактичких материјала требали да укључе семантичке информације везане, између осталог, за употребу, формат, образовне циљеве, примаоце знања и научну област, током креирања таквих материјала. На тај начин, други дизајнери и креатори сличних потреба, могу поново добити и упоредити те семантичке информације са својим тренутним захтевима, а у циљу одлуке да ли могу поново искористити тај дидактички материјал.

Вишекратност се може постићи захваљујући коришћењу устаљеног, општег речника којим се описује образовни материјал, а као што су метаподаци (metadata) и

онтологије и технолошке инфраструктуре, која се користи за складиштење и повраћај материјала. Складишта и претраживачи су та инфраструктура која омогућава складиштење (чување), управљање и повраћај дидактичких материјала, заснованих на тумачењу њихових метаподатака. Доступни су различити типови складишта: централизована наспрот подељеним; са бесплатним коришћењем или са претплатничким (плаћеним) коришћењем (Jovanović, 2006).

С друге стране, IEEE Learning Object Metadata (LOM) спецификација обезбеђује ауторима скуп метаподатака, који су класификовани у неколико категорија (тј. General, Lifecycle, Rights, Relation, Technical, Educational и Classification¹). Ове категорије олакшавају опис различитих особина ма ког дидактичког материјала, при том дозвољавајући њихову дељивост (sharing), управљање њима, размену, селекцију и локализацију, а на такав начин да се могу наново користити у различитим образовним контекстима и научним подручјима.

Иако метаподаци могу обезбедити такве описне информације, они нису довољни за добијање жељене семантичке интероперативности за постизање вишекратности. Често се захтева објашњење (коментар) дидактичких материјала. Тај задатак је тежак и обично се сматра необавезним током развоја материјала. Стога су дидактички материјали често слабо објашњени или уопште и нису објашњени. Из тог разлога, једино је исправно аутоматски или полуаутоматски обавити коментарисање током развоја и постићи одговарајућу интерпретацију метаподатака. Срећом, Онтологије и софтверске апликације као што су софтверска средства и Web сервиси, могу се користити за решавање ових питања.

Онтологије дају средства за представљање постојећег, реалног модела, из неког специфичног подручја, на рачунарско користан и разумљив начин (та средства су: софтверска средства, софистицирани претраживачи или Web сервиси), што олакшава аутоматску обраду елемената те области. На тај начин, софтверска средства или Web сервиси могу користити онтологије с циљем стварања јаснијег и лакшег семантичког објашњења, током планирања дидактичких материјала (Jovanović, 2006) .

Онтологије у образовању

Онтологије дефинишу формалне и стварне семантике за информације, чинећи их смисленим садржајима погодним за електронску обраду. Такође обезбеђују и корелацију између информационог модела и реалног подручја које он представља, обезбеђујући вокабулар (тј. језик типова и термина, који има одговарајућу формалну семантику) и допуштајући изражавање ентитета и релација концептуалног модела за уопштен или одређен домен.

Истраживање образовних онтологија није ретко. Познати су примери: Murgia-ов предлог и Mizoguchi-јев прилаз. Посебан помен заслужује предлог образовне онтологије који је направио Leidig, а која дефинише модел заснован на концептуалним графовима дидактичких појмова, скупу релација и бројним обрасцима. Обрасци описују типичне случајеве коришћења појмова и релације међу њима. Онтологије, такође, укључују и правила која дефинишу ограничења између концептуалних графова и трансформишу дидактичко знање у навигацијски план између дидактичких материјала (Jovanović, 2006). Сходно томе, обезбеђена је таксономска организација дидактичких појмова.

¹ уопштени, стални, права, релације, технички подаци, образовни и класификације

Образовне онтологије обезбеђују елементе неопходне за креирање шаблона, асистената (wizards) и алата за проверу конзистентности, који помажу ауторима током развоја дидактичких материјала (Jovanović, 2006). Они обезбеђују исправну семантичку интерпретацију претраживачима, током локализације и поновног добијања дидактичких материјала из дељивих складишта. Они такође олакшавају аутоматизацију и конфигурацију образовног процеса, док год концептуални модел садржи релације између задатака, способности и знања. Онтологије, такође, могу обезбедити уобичајени вокабулар потребан за исправну и ваљану комуникацију међу учесницима током колаборативног развоја дидактичких материјала (Wang et al, 2017).

Колаборативна подршка

Други важан аспект, који треба имати на уму током планирања и развоја дидактичких материјала јесте колаборација. Ако узмемо у обзир мултидисциплинарни карактер дизајна дидактичких материјала, као и природу и образовне захтеве научних области које се излажу у ма ком наставном материјалу, јасно је да један експерт тешко може да генерише целокупан образовни материјал. Штавише, у развој дидактичких материјала треба да је укључена група специјализованих експерата (тј. састављена од аутора садржаја, учитеља, татора, медијских експерата, систем и наставних дизајнера, педагошких саветника, па чак и ученика). Све те различите улоге обезбеђују различите идеје током развоја и планирања наставних материјала, као и то да материјали буду развијени са различитим позицијама о томе како они треба да изгледају и да буду креирани и сачињени. Њихове идеје представљају њихова експертска знања из различитих научних дисциплина, и установљују различите погледе на сам ток развоја (уметнички, наставни, образовни, психолошки и уско стручни, везан за дотичну област обрађивану тим материјалима). Значи, за развој је потребна колаборативна подршка, помоћу које се идеје учесника размењују, оцењују, изводе се закључци и као резултат таквих закључивања стварају се и сачињавају дидактички материјали (Арсовић & Стефановић, 2010).

Други битан аспект за адекватну колаборативну подршку је и уобичајени језик и семантичка интерпретација међу учесницима, која је неопходна за исправну и ваљану комуникацију, која може бити обезбеђена онтологијама (Wang et al, 2017). Такође, постоји потреба за координативним механизмом различитих активности, учесника и управљања задацима међузависности. Коначно, важно је контролисати и пратити све активности укључене у колаборативни ток развоја.

Други аспекти

Постоје друге особине, као што су квалитет и употребљивост, које такође треба узети у обзир током планирања и развијања дидактичких материјала.

Према општој дефиницији квалитета, коју је поставио Taguishi. Квалитет дидактичких материјала се може дефинисати као “степен у коме карактеристике материјала могу подмирити жељене или више жељене потребе корисника током временског периода”. Квалитет дидактичких материјала се мора анализирати са две тачке гледишта: материјал, као сам продукт и развојни процес.

Са тачке гледишта производа, да би олакшали мерење задовољења корисника, морају бити обезбеђене: формална спецификација корисничких потреба, захтеване особине дидактичких материјала и неки аналитички алати. Са тачке гледишта тока развоја, морамо да анализирамо протоколе који воде изградњу дидактичких материјала, и то како они

могу да побољшају ефикасност и смање трошкове. Неке иницијативе које стављају акценат на дефиницију квалитета конструкције дидактичких материјала су Essen Learning Model и Australian Flexible Learning Framework.

С друге стране, употребљивост дидактичких материјала је особина блиско повезана са квалитетом. Према дефиницији Rosson-а и Carroll-а (Rosson & Carroll, 2009), употребљивост дидактичких материјала се заснива на њиховој способности за: *лаку употребу* (уколико постоје различити начини размене информација са циљним аудиторијумом); *лако учење* (уколико има доследан, повезан и разумљив дизајн, који омогућује новим корисницима да лако разумеју као треба радити са материјалом); и *ефективну подршку* корисничких циљева и задатака. Како би било обезбеђено да ће дидактички материјали ефикасно подржавати образовни процес и да ће образовни циљеви бити постигнути, потребна је изузетно битна ствар током развоја дидактичких материјала - евалуација употребљивости (Premlatha & Geetha, 2015).

Као што се на основу претходно изложеног може видети, развој дидактичких материјала није тривијалан задатак. Захтева уигране, образоване пројектанте, као и подршку развојне методологије и моћно стваралачко окружење. Ауторско окружење и алати су кључни фактори за развој одговарајућих, ваљаних образовних материјала.

3.2. Контрола и критеријуми квалитета

Контрола квалитета и евалуација адаптивних е-Learning система је кључна да би се добила употребљива апликација. Међу детерминантама плана евалуације у сваком случају треба, да се нађу (Hadullo, Oboko & Omwenga, 2017; Арсовић, 2010):

- фаза дизајна (почетна, средња, завршна),
- иновативност пројекта,
- број искусних корисника,
- коришћење система и интерфејса у критичним ситуацијама,
- цена производа и средства намењена за тестирање,
- расположиво време,
- искуство дизајнерског тима и тима за евалуацију.

Чак и ако се евалуација спроведе по свим планираним фазама, током животног циклуса апликације, и испитају се сви могући аспекти дизајна, неизвесност увек постоји. Зато и постоји мноштво метода за евалуацију корисничког интерфејса и адаптивних е-Learning система, које могу да испитају детаљно сваку фазу апликације, тип и потребе корисника система, као и различите ситуације у којима се софтвер може користити. Неке од метода, биће обрађене у наставку.

Стручна контрола и ревизија

Стручна контрола се може спровести у почетној или завршној фази дизајна. Она подразумева ангажовање стручњака из области за коју се креира апликација, или стручњака за евалуацију e-Learning система, који могу и не морају бити чланови дизајнерског тима. Посао стручњака је да евидентирају проблеме у корисничком интерфејсу и систему, а да решавања тих проблема оставе дизајнерима/ауторима. Постоји више метода стручних контрола:

- хеуристичка евалуација,
- преглед смерница,
- провера доследности,
- когнитивни пролаз,
- формална контрола употребљивости (Al-Fraihat, Joy & Sinclair, 2020).

Тестирање употребљивости

Тестови употребљивости развијени су са циљем проналажења проблема у корисничким интерфејсима и апликацијама, а већа пажња посвећује се испитивању потреба корисника (Abuhlfaih & Quincey, 2018). Учесници у тестирању се могу снимати на видео касети или неки други медијум, а пожељно их је охрабривати да размишљају наглас о ономе што раде и проблемима на које наилазе током извршавања акција задатих корисничким интерфејсом. Постоји мноштво облика тестова употребљивости (Gunesequera, Bao & Kibelloh, 2019):

- прављење папирних модела екрана – које дизајнер листа и очекује од учесника решавање типичних задатака. Овај неформални облик тестирања је продуктиван, а јефтин и брз;
- дисконтно тестирање употребљивости – препоручује се мањи број учесника (3-6) ради бржег и лакшег проналажења и исправљања грешака;
- компетитивно тестирање употребљивости – подразумева поређење апликације са њеним претходним верзијама или са сличним производима различитих произвођача;
- универзално тестирање употребљивости – апликацију тестира већи број корисника у различитим хардверским, софтверским и мрежним окружењима;
- тестирање на терену и преносиве лабораторије – нова апликација се тестира у реалном окружењу, у неком задатом временском периоду, или се достављају корисницима, тзв. бета верзије које они коментаришу;
- тестирање употребљивости на даљину – омогућава тестирање великог броја корисника различитих профила и на различитим платформама (кућни рачунари корисника) путем Web-a. Проблем који се јавља приликом овог начина тестирања је немогућност контролисања тока тестирања и увида у корисникове реакције током тестирања elearning система;

- тестови разбијања – смислили су их дизајнери видео игара, где корисници треба да пронађу фаталне грешке у системима.

Тестирање употребљивости има много предности, али и недостатака (тестирање се скоро никада не врши непосредно после коришћења софтвера, а и често не покрива све функције апликације), тако да га треба допунити неком од наведених метода евалуације.

Инструменти за анкетирање

Писане анкете најчешће представљају допуну тестова употребљивости. Анкетни листићи се морају пажљиво припремити, прегледати и тестирати на малом узорку корисника. Корисницима се постављају питања о утисцима о конкретним аспектима апликације као што су:

- објекти и радње за обављање конкретног посла;
- метафоре и акције у оквиру конкретне апликације;
- синтакса улаза и дизајн корисничког интерфејса (Tjong, Sugandi, Nurshafita, Magdalena, Evelyn & Yosieto, 2018).

Упитником се, такође, могу добити веома важне информације о корисниковом:

- профилу (полу, старости, образовању)
- искуству при употреби рачунара
- типу личности
- утиску о сложености задатака и времена за њихово решавање (довољно, недовољно)
- целокупном утиску приликом употребе софтвера за који је дизајниран кориснички интерфејс
- утиску о томе како софтвер који је креиран утиче на повећање његове информисаности...

On-line и анкете/упитници на Web-у су далеко практичнији, јер се на тај начин једноставније испита далеко већи број корисника, брже се припремају (нема штампања) и прегледају, само што се на тај начин смањује репрезентативност узорка. Шнајдерман је развио *Упитник о сатисфакцији корисника током интеракције (Questionnaire for User Interaction Satisfaction, QUIS)*, а потом су га допунили Чин, Дил и Норман 1988. године (<http://www.lap.umd.edu/quis>) који се односи на:

- детаље интерфејса као што су, нпр. читкост знакова и концепција екрана,
- интерфејсне објекте (нпр. значење икона),
- акције (нпр. пречице за честе начине коришћења),
- пословне аспекте (нпр. одговарајућа терминологија),
- редослед екранских прегледа (Nokelainen, 2004).

Упитник садржи два нивоа питања (општи и детаљни), а састоји се из 12 делова који испитују:

- искуство са системом који се испитује
- претходна искуства (са оперативним системима, хардверским компонентама, софтверским системима)
- свеукупну реакцију корисника
- екран (фонтови, треперење, количина и распоред информација, редослед екрана и повратак на претходни екран)
- терминологију и системске информације (повратне информације и поруке друге врсте на екрану)
- учење (савладавање система, сложеност задатака)
- карактеристике система (брзина, поузданост, лакоћа при раду)
- упутства за кориснике и online помоћ
- online упутства за учење
- мултимедијални материјал (квалитет слика, фотографија, звука, анимација, коришћене боје)
- телеконференције (подешавање, распоред прозора, распознавање гласова, замена података)
- инсталацију софтвера (Nokelainen, 2004).

Тестови прихватљивости

Аспекти који се испитују у тестовима прихватљивости су следећи:

- време које је корисницима потребно да савладају конкретне функције;
- брзина извршавања задатака;
- учесталост грешака;
- задржавања усвојених знања током времена;
- субјективно задовољство корисника (Abuhlfaia & Quincey, 2018).

Тестови прихватљивости често могу довести до непријатних ситуација, јер им је циљ проверавање да ли су одређени услови испуњени, а не, као код тестова употребљивости, уочавање грешака.

Евалуација током активног коришћења

Адаптивни e-Learning систем који се креира, а самим тим и његов кориснички интерфејс, потребно је евалуирати и након одређеног времена активног коришћења. У тај процес евалуације потребно је укључити што више корисника, а свако ко је користио

апликацију, може давати коментаре о њој. Постоји неколико облика евалуације током активног коришћења (Al-Fraihat, Joy & Sinclair, 2020):

- интервјуи и дискусије у фокус групама (организују се серије индивидуалних разговора, па се у фокус групама у разговору постиже универзалност коментара);
- континуирано евидентирање података о перформансама корисника (у бази података, чувају се поруке о корисниковим грешкама, учесталости употребе);
- online или телефонске консултације (корисници се бесплатним телефонским сервисима обраћају стручним консултантима, који током разговора могу да посматрају шта се дешава на корисниковом рачунару);
- бокс за online предлоге и пријављивање проблема електронском поштом (корисници своје предлоге шаљу email-ом);
- дискусионе групе (форуми) и електронске конференције (корисници размењују искуства приликом коришћења софтвера, расправљају о конкретним проблемима на које наилазе приликом рада у апликацији, нуде своја решења...).

Критеријуми квалитета адаптивних e-Learning система

Сем претходно изложених начина и алата контроле квалитета и евалуације осмишљене апликације за електронско (адаптивно) учење, намеће се потреба за дефинисањем критеријума који карактеришу квалитетан и ваљан адаптивни e-Learning систем.

Могу се издвојити следећи општи критеријуми квалитета адаптивног образовног курса (Ајмера, 2014):

- наставне активности и електронске лекције се прилагођавају потребама и могућностима појединачних студената.
- напреднији студенти се упућују на неке нове делове лекције, са додатним објашњењем појединих појмова.
- садржај је усклађен са нивоом предзнања, вештина и искуства студената.
- студент треба да буде усмераван кроз електронску лекцију на такав начин да:
 - буде очуван његов интерес за презентовани садржај
 - усваја потребна знања брзином која њему одговара
 - добија повратну спрегу о својим достигнућима на време (повратна спрега је релевантна за студента и позитивна).

Сем наведених уопштених, препознају се и следећи (изведени) критеријуми, који карактеришу адаптивно e-Learning окружење:

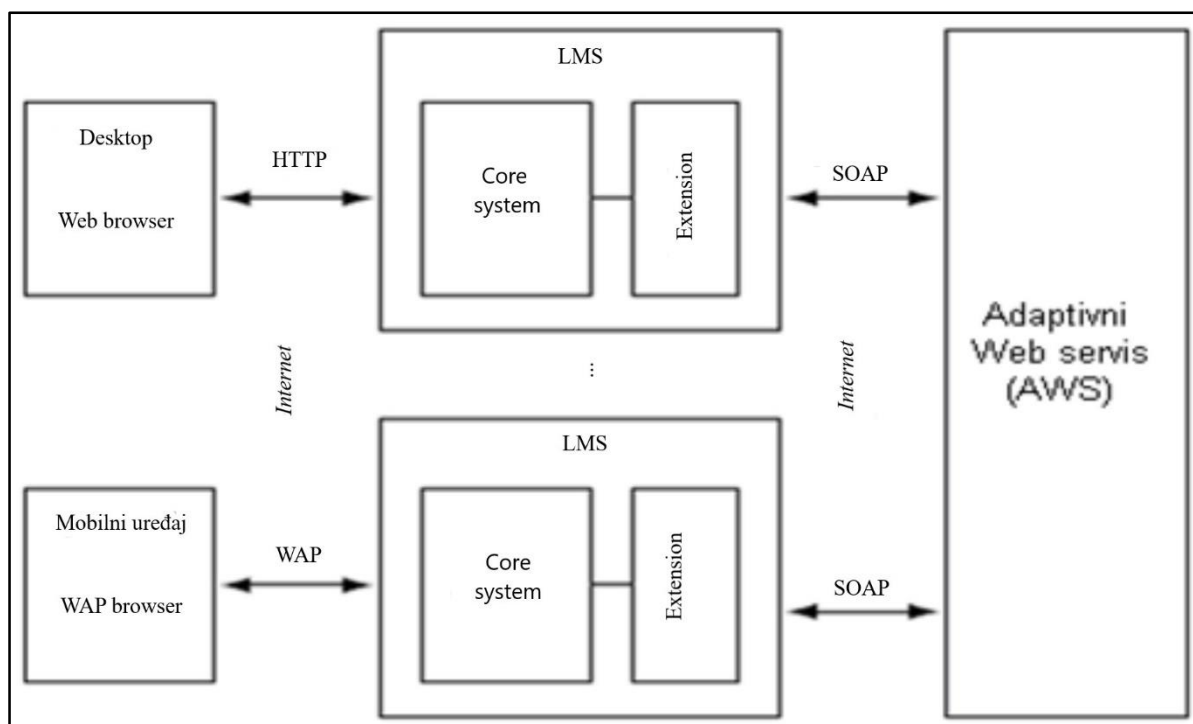
- садржај је структуриран у смислена поглавља
- наставни објекти (LOs), који чине електронске наставне јединице, су за појединачне студенте различито структурирани и распоређени (зависно од кластера ком студент припада)

- дати редослед електронске лекције мора бити довољно флексибилан да омогући студенту да следи различите путање кроз наставну јединицу, а све у складу са индивидуалним предзнањем, конкретним способностима и могућностима појединаца у брзини савлађивања градива
- све странице морају имати наслов, који јасно дефинише место у оквиру електронске наставне јединице
- главни мени лекције треба да буде лако доступан
- када је навигација у питању, електронска наставна јединица обавезно мора имати могућност кретања унапред и уназад, могућност преласка на главни мени, као и могућност напуштања курса/лекције
- студијски примери, сценарији, симулације, примери и проблеми који се разматрају су од значаја и реални
- провера знања се врши током трајања електронске лекције. Методе су:
 - питања након (сваког) наставног објекта (питања са вишеструким одговорима, питања тачно/нетачно, отворена питања...). И у овом случају, мора се извући корист и поука од добијеног одговора. Он може послужити да се дозволи избор даљег пута кроз лекцију, да се евентуално прескоче неки делови лекције, или да студент буде враћен на делове лекције које није довољно добро савладао. Наравно, напредније студенте треба упутити на неке нове делове лекције, са додатним објашњењем појединих појмова.
 - не треба сва питања која наставник креира искористити за вежбе – требало би да постоји довољно велика колекција питања на располагању за касније испитивање и оцењивање студената
- адаптивни курс је креиран тако да га је једноставно осавременили и ажурирати, те по потреби сразмерно увећати или умањити (Ajmeza, 2014; Drozdova & Guseva, 2017).

3.3. Општа архитектура адаптивног e-Learning LMS-a

Један од често коришћених модела за архитектуру адаптивног e-Learning LMS-a јесте дистрибуиран систем (Al Muhaideb, Hammami & Mathkour, 2010), који се састоји од три компоненте:

- Web browser – читач Web-a
- систем за управљање процесом учења (LMS)
- Web сервис за адаптацију (Adaptation Web Servis - AWS).

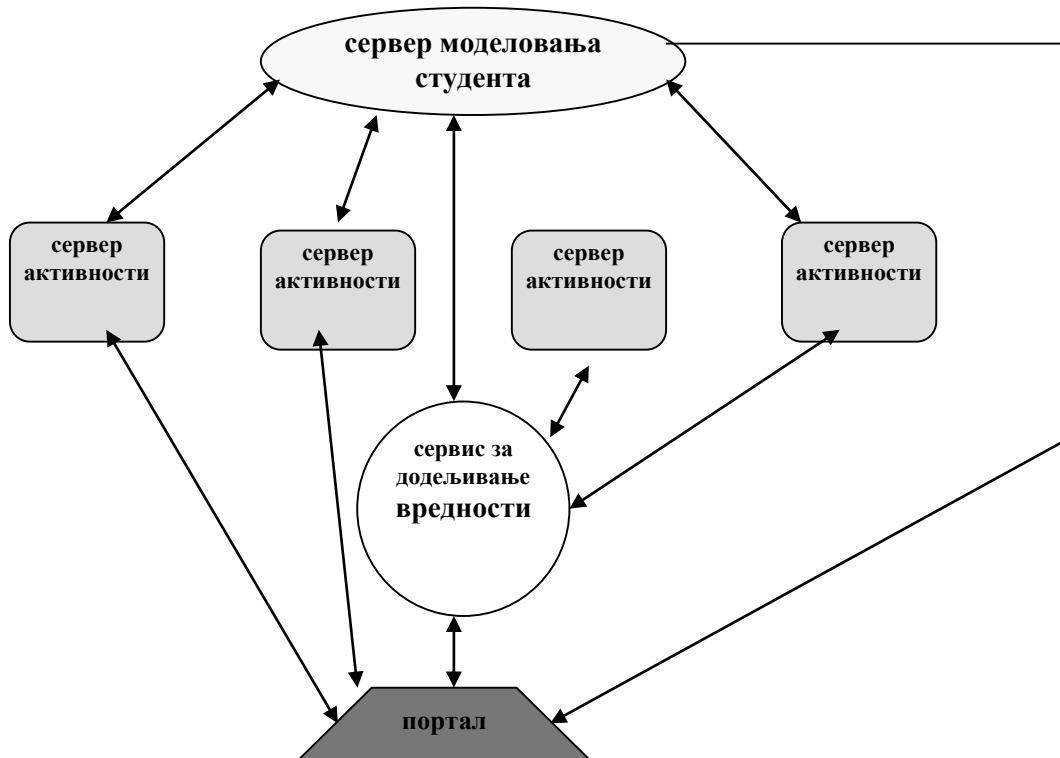


Слика 20: Архитектура адаптивног е-Learning LMS-а

Слика 20 приказује три компоненте које чине структуру система: Web читач; LMS - софтвер који управља свим елементима е-Learning -а, пружа информације о току процеса наставе и омогућује комуникацију међу корисницима LMS и AWS. Читачи приказују садржај и представљају интерфејс корисника са којим су у интеракцији, а преко комуникационог протокола за пренос хипертекста HTTP (HyperText Transfer Protocol) су повезани са системом за управљање процесом учења.

У циљу постизања адаптивности, потребно је да AWS добије информације из LMS-а и да га контролише. Комуникација између LMS-а и AWS-а је реализована преко SOAP (Simple Object Access Protocol) који обезбеђује основни слој за размену порука преко рачунарских мрежа. На овај начин читач, LMS и AWS могу бити имплементирани у различитим програмским језицима и функционисати у различитим окружењима (под различитим оперативним системима).

Knowledge Tree (стабло знања) је други пример дистрибуиране архитектуре адаптивних е-Learning система, засноване на виšekратној (поновној/поновљеној) употреби интелигентних образовних активности (Brusilovsky, 2004). Користећи предности и успех интегрисаних LMSs, Knowledge Tree се труди да обезбеди непрекидну, разумљиву подршку према потребама као наставника, тако и студената, који користе е-Learning. Идеја је да се монолитни LMS замени са скупом дистрибуираних комуникационих сервера (или сервиса). Архитектура предвиђа постојање најмање четири врсте сервера: сервер активности, сервис додељивања вредности, образовни портал и сервере модела студента (слика 21).



Слика 21: Основни концепт дистрибуиране архитектуре стабла знања

Ове врсте сервера представљају три главна носиоца модерног е-Learning процеса: провајдера садржаја и услуга, провајдера курса и студената.

Образовни портал репрезентује потребе провајдера курса – наставнике и образовне установе. Портал има улогу сличну модерном LMS-у, у два аспекта: као прво, он обезбеђује приступно место за централизовано, појединачно пријављивање (log in) студената који су пријављени на курс, чиме стичу могућност рада са свим расположивим образовним алатима и садржајима понуђеним на курсу; као друго, портал омогућава наставнику, задуженом за одређени курс, да структурише приступ различитим дистрибуираним фрагментима, у зависности од потреба тог курса. На тај начин, портал је компонента архитектуре, која је усмерена на подршку комплетног курса. Копирајући сличну функционалност као код LMS-а, портал обезбеђује наставницима интерфејс за ауторизацију курса², и обезбеђује текући интерфејс за студенте.

Разлика између овако дефинисаног портала и LMS је у архитектурној сепарацији јединствене структуре курса, креиране од стране наставника или аутора, на основу садржаја курса и услуга/сервиса који се могу виšekратно користити. У стаблу знања, и образовни садржаји и сервиси за образовну подршку (заједно названи активности), се обезбеђују путем портала, кроз вишеструке, дистрибуиране сервере (сервисе) активности. Портал поседује способност претраживања сервера активности по релевантним активностима, и способност покретања активности одабраних од стране студената или самог портала.

Сервер активности је компонента фокусирана на могуће потребе провајдера садржаја и услуга. Усмерен је на садржаје и услуге (сервисе) за виšekратну употребу. Његова

² интерфејс за управљање курсевима, додавање садржаја, мењање и сл.

улога је слична улози коју имају образовни репозиторијуми у курсевима са модерним приступом вишекратног коришћења, а у смислу да је складиште образовних садржаја за вишекратну употребу. Разлика између сервера активности и традиционалног образовног репозиторијума је двојака. Прво, за разлику од репозиторијума који су базени (pools) за похрањивање једноставних, углавном статистичких, образовних објеката; сервер активности похрањује високо интерактивне и адаптивне образовне садржаје. Такође може сачувати интерактивне образовне сервисе, као што су нпр. дискусионни форуми. Друга разлика је то што сервери активности предвиђају различите начине вишекратне употребе својих садржај. Док се једноставни образовни објекти поново користе простим копирањем и уметањем у нове курсеве, активности се наново користе упућивањем на њих, а затим и достављањем путем поменутог сервера.

Потреба за серверима активности потиче из саме природе адаптивних и других напредних образовних активности. Овакаве активности не могу бити само копиране као датотеке, већ морају бити уручене са посебног web сервера, одржаваног од стране провајдера садржаја. Дужност сервера активности јесте да одговори на захтеве за специфичним активностима, доспелим са портала и сервиса за додељивање вредности; и да, при том, обезбеди комплетну подршку за рад студената са било којом активношћу понуђеном на серверу. Концепт активности за вишекратно коришћење, подстиче провајдере садржаја да развијају високо напредне, интерактивне образовне садржаје и сервисе (услуге). Шта више, садржаји и услуге, доступне на серверу, могу бити интелигентне и адаптивне. Свака активност може прибавити актуелну информацију о ма ком студенту, а од сервера модела студента; и на тај начин омогућити персонализацију процеса учења, високог нивоа. Сервер активности надзире и бележи напредак студената, промену студентских циљева, знања и интересовања; а затим шаље ажуриране податке серверу модела студента.

Сервис за додељивање вредности комбинује одлике портала и сервера активности. Овај сервис је способан да пропусти необрађене садржаје и услуге, додељујући им неке вредне функционалности – као што су нпр. адаптивно распоређивање, тумачење/коментар, визуализација или интеграција садржаја. Као и портал, овај сервис може претражити сервере активности и приступити активностима. Попут сервера активности, може бити претражен и може му се приступити преко портала. Сервис додељивања вредности одржава провајдер услуга. Како је овај сервис неутралан по питању курса, то може бити више пута коришћен у више курсева.

Сервер модела студента (за моделовање студента) је компонента којом су представљене потребе и профили студената. Ова врста сервера дозвољава да дистрибуиран e-Learning буде крајње персонализован. Идеално, сервер модела студента може подржати учење студента на неколико различитих курсева. Одржава га провајдер (тј. универзитет, факултет) или чак и сами студенти. Сервер сакупља податке о перформансама студента, са сваког портала и сервера активности; и снабдева адаптивне портале и сервере активности са информацијама о студенту (а портали и сервери активности су тада у могућности да прилагоде образовни материјал јединственим студентовим потребама и могућностима).

Очигледно је да постојање вишеструких адаптивних активности захтева централизовану архитектуру моделовања студента, која омогућава да свака образовна активност има приступ свим информацијама о напретку студента. Општа проблематика моделовања студента је размотрена у поглављу 2.5.

Са предложеном архитектуром дрвета знања, наставник развија образовни курс, користећи један портал и бројне сервере активности и услуга (сервиса). Студент приступа курсу и ради у њему преко портала, али је у интеракцији са бројним образовним активностима, које су му испоручене директно путем бројних сервера активности. Сервер модела студента обезбеђује базу за праћење и надзор перформанси, као и за прилагођавање у овом дистибуираном контексту.

Архитектура Knowledge Tree је отворена и флексибилна (Brusilovsky, 2004). Дозвољава присуство више портала, сервера активности и сервера за моделовање студената.

3.4. Типови/моделу адаптирања e-Learning образовних система

Као што је већ поменуто, Web оријентисани образовни системи су променили парадигму самог система и процеса образовања и учења. Они су учинили учење и подучавање независним од времена и места, а образовне и наставне материјале и информације је могуће похранити на једно место, где су доступни на глобалном нивоу, у било које доба. Оваква организација доприноси уопштености садржаја система.

Међутим, у пракси, оваква организација не одговара свим нивоима корисника. Сви корисници (ученици, студенти) неће бити, нити су на истом нивоу знања, вештина, ни интелигенције. Web садржаји би требало да задовољавају различите кориснике, а у складу са њиховим способностима, вештинама и склоностима.

Статичан садржај, опште намене Web страну чини врло непривлачном и досадном, напорном за читање. Способности и склоности, па и интелигенција и могућност разумевања изложеног садржаја варирају од особе до особе, па чак и код исте особе ниво способности учења и разумевања зна да варира у неком периоду. Такође, корисник/студент напредује корак по корак кроз образовне нивое, чиме мења своја предзнања и спецификације. Све предочено чини адаптивни садржај система за учење не само пожељним, већ и неопходним.

Вршена су бројна истраживања по питању развијања и унашређивања презентовања и доставе образовних материјала и садржаја курсева, тако да образовање и учење постане ефикасније (Fatimah & Santiana, 2017). Показало се да је већина on-line образовних курсева типа “one-fits-all” и да је њихов садржај задовољавајући само за скуп корисника једног нивоа интелигенције, способности и/или склоности. Прилагођавање садржаја индивидуалним потребама студената чини систем за учење атрактивнијим. Доказано је да ученик много лакше и успешније постиже предвиђене образовне циљеве када се при излагању и испоруци образовних садржаја води рачуна о индивидуалним разликама ученика (Garrick, Pendergast & Geelan, 2017). Овакви закључци воде до неопходности персонализације и адаптивности у презентовању и начину испоруке образовних материјала.

Разлике међу ученицима су одређене њиховим предзнањима из разматране области, као и њиховим стилевима учења, општим погледима и ставовима, културним и језичким залеђем (Bartolomé, Castañeda & Adell, 2018). Обраћање пажње на све ове карактеристике повећава функционалност система за учење. У таквим системима модели циљева, приоритета и знања појединог корисника су изграђени и користе се за прилагођавање потребама корисника система.

Адаптивне технологије на различите начине могу додати адаптивне/интелигентне функционалности образовним системима. У даљем излагању посебно ће бити обрађено четири типа/модела адаптирања е-Learning образовних система: адаптирање према нивоу знања студента; адаптирање према стилу учења студента; адаптирање путем креирања адаптивног, персонализованог фидбека и адаптирање путем персонализованог интерфејса (Naoran, Chu, Hwang & Wang, 2019). Посебно ће бити размотрене карактеристике и предности (али и могући недостаци) сваког поменутог решења могућег адаптирања е-Learning образовних система у циљу предочавања најбољег решења за креирање конкретног мета-модела адаптивног е-Learning образовног система.

3.5. Адаптивни е-Learning LMS за студенте различитих нивоа знања

У овом делу рада је предложено нацрт решења за структуру Web оријентисаног е-Learning система, који омогућава креирање адаптивног образовног окружења. За побољшање и постизање адаптивности у е-Learning системима се користи техника адаптивних хипермедија. Дизајн домена садржаја заснива се на тзв. стаблу зависности и тако је представљен да је студентима омогућено да уче на различитим нивоима знања.

Већ је било речи о томе да се данас Web оријентисани курсеви развијају и презентују путем LMS система као што су Blackboard, WebCT или Moodle. LMS системи су моћни, интегрисани системи који подржавају бројне активности како предавача/наставника, тако и ученика, током процеса е-учења. Адаптивни хипермедијски ауторски системи су развијени да би потпомогли специјализацију оваквих Web заснованих курсева. Карактеристична особина адаптивних хипермедијских система је модел ученика/студента који је експлицитна репрезентација знања ученика, његових интересовања, циљева и других особина као што су ученикове перформансе (Sfenrianto, Hartarto & Akbar, 2018).

У даљем излагању биће представљен дизајн домена предмета (модела садржаја), коришћењем тзв. дрвета зависности за Web оријентисане е-Learning системе, а који укључује три технике адаптивне хипермедије: адаптивни дизајн предметног садржаја; адаптивну навигацију; адаптивну презентацију. У следећим деловима рада су објашњени детаљи техника адаптивне хипермедије, које су коришћене. Затим је дата и описана архитектура система којом се постиже адаптивност у учењу. Сем теоријских разматрања, на крају овог поглавља, илустрован је препоручени дизајн курса, коришћењем стабла зависности за прављење различитих категорија студената.

Технике адаптивних хипермедија коришћене у е-Learning окружењу

Адаптивни хипермедији се користе за уобличавање приказа предметне области (тј. образовног садржаја), а према личним захтевима ученика. Технике адаптивних хипермедија воде ученика кроз образовне материјале курса, помажући им у њиховом разумевању.

Дизајн адаптивног модела садржаја

Модел садржаја је дизајниран коришћењем дрвета зависности са вишеструким линковима (Li, Wang & Gu, 2019). Исти образовни садржај је презентован на три различита нивоа, растуће сложености. Овако адаптивна структура курса разликује различите категорије студентата: почетнике, просечне и надарене. Први ниво (ниво 1) пружа само кратак увод и увид у теме предмета, које могу упознати студенти нивоа почетника, а без неког захтеваног предзнања. Други ниво (ниво 2) је мало напреднији од првог нивоа и

пружа више детаља о обрађиваној теми, са пратећим објашњењима, примерима, вежбама, итд. које могу задовољити захтеве просечних студената. Трећи ниво (ниво 3) обезбеђује напредније карактеристике и опширнија, дубља знања из обрађиване области, за напредније студенте.

Адаптивна навигација

Током пријављивања и регистрације на курс, студент попуњава упитник (пред-тест). Модел ученика прати ученикове перформансе. На основу способности и знања испољених у овом пред-тесту, студенти се категоризују као почетници, просечни или напредни. Оваква категоризација се обавља у зависности од постигнутог фактора предзнања, који може варирати од 0 до 1. Стабло зависности, уз помоћ модела студента, асистира студенту током одговарајућих навигационих линкова, сугеришући пригодан, одговарајући ниво (Hamzah, 2020).

Адаптивна презентација садржаја у зависности од нивоа знања студента

Табела 5 илуструје класификацију студената засновану на њиховом фактору предзнања, добијеном у пред-тесту, током регистрације на сам курс.

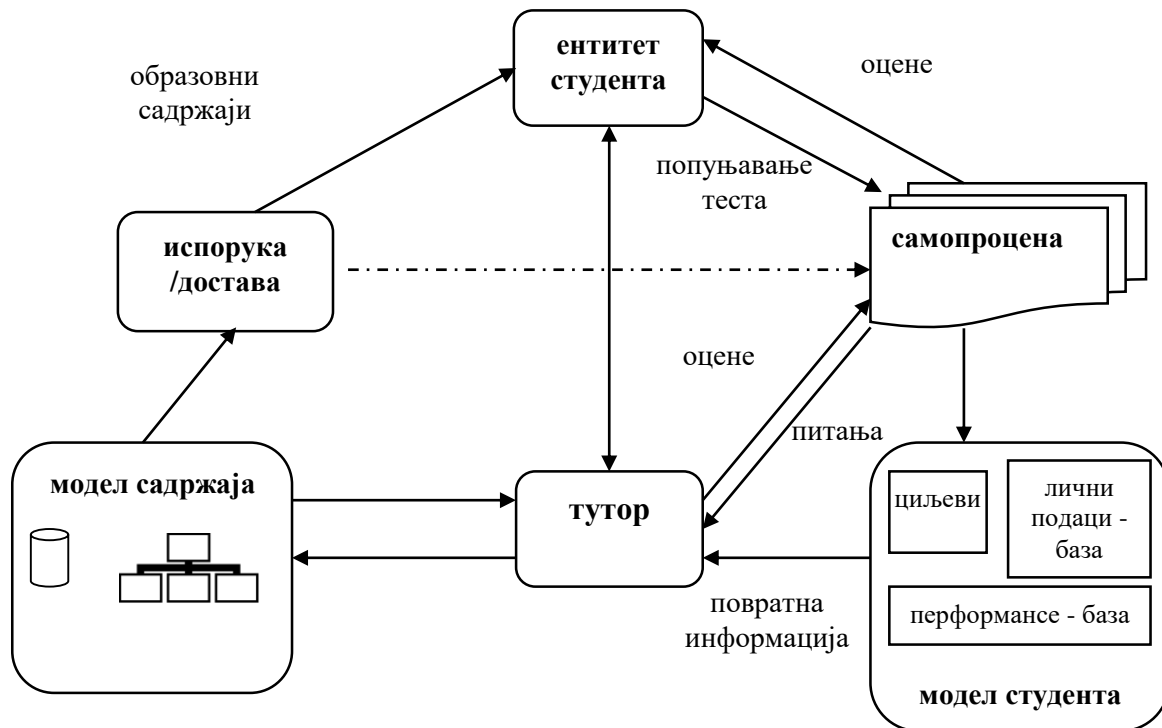
Табела 5: Класификација студената заснована на њиховом фактору предзнања

КАТЕГОРИЈА СТУДЕНАТА	ФАКТОР ПРЕДЗНАЊА
<i>Почетник</i>	0 – 0,4
<i>Просечан</i>	0,41 – 0,7
<i>Напредан</i>	0,71 – 1,0

Студенти почетници (са фактором 0 до 0,4) се упознају са садржајем курса првог нивоа. Просечни студенти (фактора 0,41 – 0,7) се прослеђују на садржај нивоа 2; док напредни студенти (фактора 0,71 -1,0) бивају упућени на садржајни ниво 3, путем кога продубљују знања из обрађиване области.

Могућа архитектура адаптивног e-Learning система

Сврха развијања e-Learning архитектуре јесте у томе да се добије разумљив модел помоћу којег би се креирао адаптивни оквир, пригодан за различите категорије студената на различитим нивоима стеченог знања (Ahmadaliev, Medatov, Jo'rayev & O'rinov, 2019). Слика 22 приказује архитектуру e-Learning система.



Слика 22: E-learning архитектура

Ентитет студента: може представљати једног студента или групу студената са различитим нивоима предзнања. Студенти добијају одређен образовни садржај курса, у зависности од свог нивоа знања.


Процес самопроцене: систем прати промене студентових перформанси током временаведеног на курсу. Питања су организована од стране скупа експерата или татора на датом предмету. То су обично питања вишеструког избора или питања са одговором (дужине једне речи - да/не). Перформансе студента се складиште у базу података која се прослеђује како студенту, тако и тотору, па на тај начин студенти могу да обратe посебну пажњу на оне предмете и области у којима им знања нису на адекватном, жељеном нивоу. Са друге стране, тотор има прилику да подеси курсеве према тренутној групи студената.

Модел студента: је експлицитна репрезентација знања студента. Модел студента садржи три компоненте: образовне циљеве студента, базу перформанси студента и базу личних података студента. Образовни циљеве студента су обично успешно завршавање курса, као и правилно разумевање сваког образовног материјала и стицање знања. База перформанси садржи confidence фактор студента, који је он освојио у пред-тесту, заједно са њиховом категоризацијом. Такође садржи и податак о томе какав успех студент остварује у сваком од делова (поглавља/јединица) курса. База личних података садржи све детаље о студенту (са именом, идентитетом, регистрационим бројем, датумом регистрације, статусом плаћених трошкова итд.).

Тотор: предметни садржај (образовни садржаја) је дизајниран од стране тима експерата. Тим експерата дизајнира и креира саджај курса на различитим нивоима, тако да нивои буду одговарајући различитим студентима, који су на различитим нивоима знања.

Модел садржаја: основни интерес овако предложене структуре складишта предметног домена за e-Learnin је дефинисање одговарајуће структуре, такве да студенти могу једноставно и логично пронаћи најбитније информације, опет у зависности од сопственог нивоа знања.

Образовни материјал је организован као скуп поглавља. Свако поглавље је класификовано у сопствени скуп подпоглавља, а опет свако подпоглавље је даље подељено у скуп подподглавља. Међу поглављима и подпоглављима постоје релације које их међусобно повезују. Слика 23 приказује пример дизајна модела садржаја.



Слика 23: Дизајн модела садржаја, коришћењем стабла зависности

Сваком нивоу образовног садржаја је додељена одређена тежина, која варира од 0 до 1. У табела 6 су дате различите тежине садржаја, дефинисане према различитим категоријама ученика (Hamzah, 2020).

Табела 6: Тежина образовног садржаја у односу на нивое

КАТЕГОРИЈА СТУДЕНАТА	ТЕЖИНА ОБРАЗОВНОГ САДРЖАЈА	НИВО
<i>Почетник</i>	0 – 0,4	ниво 1
<i>Просечан</i>	0,41 – 0,7	ниво 2
<i>Напредан</i>	0,71 – 1,0	ниво 3


Модел курса у адаптивном e-Learning систему

Слика 24 илуструје стабло зависности за хипотетички курс. Када студент посети курс, иницијално му се даје пред-тест и на основу постигнутог (освојеног) фактора предзнања, сврстава се у почетнике, просечне или напредне студенте.

Као што се на слици види, када корисник почетник, са фактором 0 – 0,4 стартује у курсу, образовни садржај са предметним нивоом тежине у распону од 0 – 0,4 се презент-

тује студенту. Навигациона путања за студента почетника је на слици означена испрекиданом линијом. На овај начин се презентује само садржај дизајниран за ниво 1, а који садржи само увод и кратке, сажете детаље.

Просечни и напредни студенти се упознају са садржајним нивоима 2 и 3, који имају предметне тежине у рангу 0,41 – 0,7 и 0,71 – 1,0 (тим редом).



Слика 24: Навигациона путања студента почетника у курсу (Кречетов & Романенко, 2020)

На основу претходно изложеног је изграђен модел садржаја за адаптивни е-Learning LMS систем. Стабло зависности, уз помоћ модела студента, омогућава студентима који су на различитим нивоима (пред)знања, да на курсу дођу до одговарајућег образовног садржаја.

3.6. Адаптивни е-Learning LMS за студенте са различитим стиловима учења

Бројна истраживања показују да је узрок неуспеха великог броја е-Learning курсева незадовољство и немотивисаност полазника, што је често последица неприлагођености курсева специфичним, личним потребама полазника, тј. студената (Kotecha, 2019). Примарни циљ даљег излагања јесте представљање адаптивног е-Learning LMS система у складу са различитим стиловима учења студената.

Стилови учења и њихов утицај на сам процес учења су објашњени и боље размотрени у поглављу 2.4. Већ у прегледу се види да је то једна комплексна и опширна истраживачка област. Упркос дугогодишњим истраживањима и даље се постављају бројна питања која остају без јасног одговора. Једно од тих питања јесте и то да ли је разложно и оправдано примењивати знања о стилу учења ученика, а у циљу побољшања исхода учења и самог процеса учења (Truong, 2016). На први поглед је сасвим логично да ће усаглашавање учениковог стила учења и примењених наставних метода побољшати ученичке перформансе. Међутим, резултати експеримената са различитим стиловима учења пружају двосмислене одговоре. Бројни експерименти потврђују и дају доказ о побољшању ученичких перформанси у усаглашеним окружењима, док неки други експерименти не показују никакав значајан напредак. Заправо, неки психолози (Bogomolova, Gorelova, Menshikov, Zalavina & Arpentieva, 2018) сматрају да је учење у неприлагођеним и отежавајућим околностима, у неким случајевима, практичније и боље, јер омогућава стицање

нових способности. Мишљења различитих истраживача варирају од пожељности адаптирања учења према стилу учења (Soltani & Izquierdo, 2019), па до потпуног игнорисања учениковог стила учења (Freedman, 1980).

Упркос овим контрадикторностима, аутор је мишљења да је примена стила учења приликом креирања адаптивних LMS система више него корисна и да заслужује даље истраживање. По ученика је добро да зна и да буде свестан свог стила учења, а самим тим и својих слабости, као и предности. Постоје модернизовани LMS системи, који подржавају различите стилове учења. Један од основних проблема са постојећим приступима је тај да аутори таквих система бирају одређене стилове учења (према преферираној, одабраној класификацији стилова учења) које имплементирају у своје софтверске системе.

Без обзира коју класификацију аутори разматрају и користе у LMS системима, уопштено је следеће: образовни стил обухвата и подразумева стратегије које студент уобичајено примењује у датим образовним ситуацијама. Сваки појединац се може сврстати (па макар и оквирно) у одређени, различит стил учења, који је узрок одређених, усвојених ставова и понашања, која се понављају у одређеним ситуацијама. Стил учења студента индукује студентов образовни профил. Образовни профил дефинише скуп карактеристика, које класификују студента у одређен, специфични модел, током процеса учења. Дакле, стил учења чине когнитивне, афективне и психолошке чињенице, које одређују начин интеракције и реакције студента на образовно окружење. Идеја је да се идентификују главне карактеристике студента, а тиме и како оне утичу на његов процес учења. Међутим да би се то учинило, потребно је тачно одредити које разматране релеванце треба пратити и посматрати у интеракцији студента са образовним окружењем. Да би се изашло у сусрет стилу учења, потребно је применити образовне стратегије које могу задовољити потребе различитих образовних перспектива.

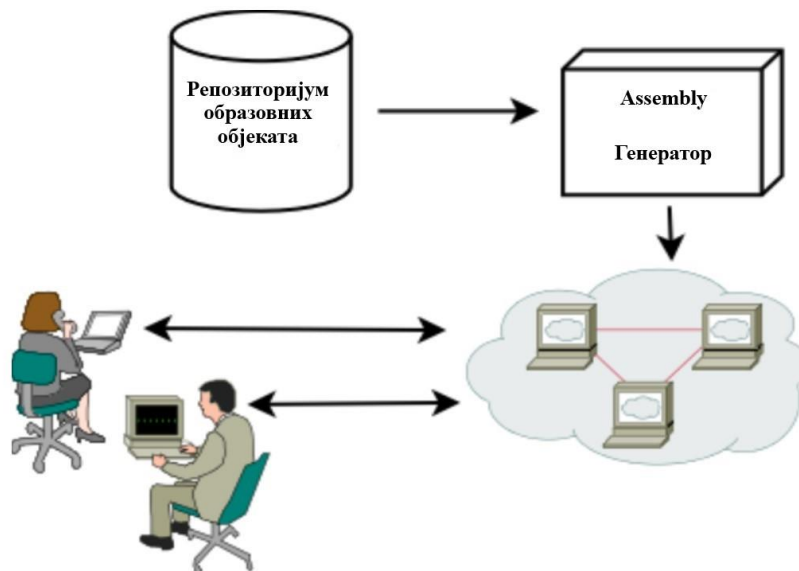
Без обзира за коју се класификацију стила учења аутор определи, потребно је, уколико жели да постигне персонализацију и адаптивност у свом систему, да одговори на следећа питања:

1. Које ће се карактеристике учениковог профила разматрати и узимати у обзир?
и
2. Како скупити те податке?

С обзиром на прво питање, најчешће имплементирана решења се заснивају на теорији стилова учења, а прикупљање неопходних података се обавља путем упитника, који је доступан на e-Learning платформи. Зато је веома важно укључити бар неке одлике персонализације директно у LMS, или у базу знања коју систем користи. Ово помаже креирање online образовних курсева који су прилагођени индивидуалним потребама и преференцама студената. Другим речима, то значи да се структура типичног LMS-а мора „обогаћити“ додатним подсистемом, који би могао да бира (у зависности од претходно дефинисаних правила одлучивања) одговарајуће образовне објекте из репозиторијума, окупља их у једну целину и од њих креира цео образовни курс (Alhawiti & Abdelhamid, 2017). Овај систем се може назвати Систем адаптације према стилу учења (енг. Learning Styles Based Adaptive Engine – LSAE). Подсистем LSAE би требало да може да испуни три основна и најбитнија задатка, која се дефинишу као: *прикупљање података у погледу стила учења студента; креирање скупа улазних фактора којима се описује очекивана форма и структура образовног садржаја који ће се испоручивати студенту; дизајнира-*

ње структуре базе знања, посебно методологије поделе образовног садржаја на образовне објекте, који скупа могу чинити комплетну образовну јединицу (Zajac & Piekarczyk, 2003).

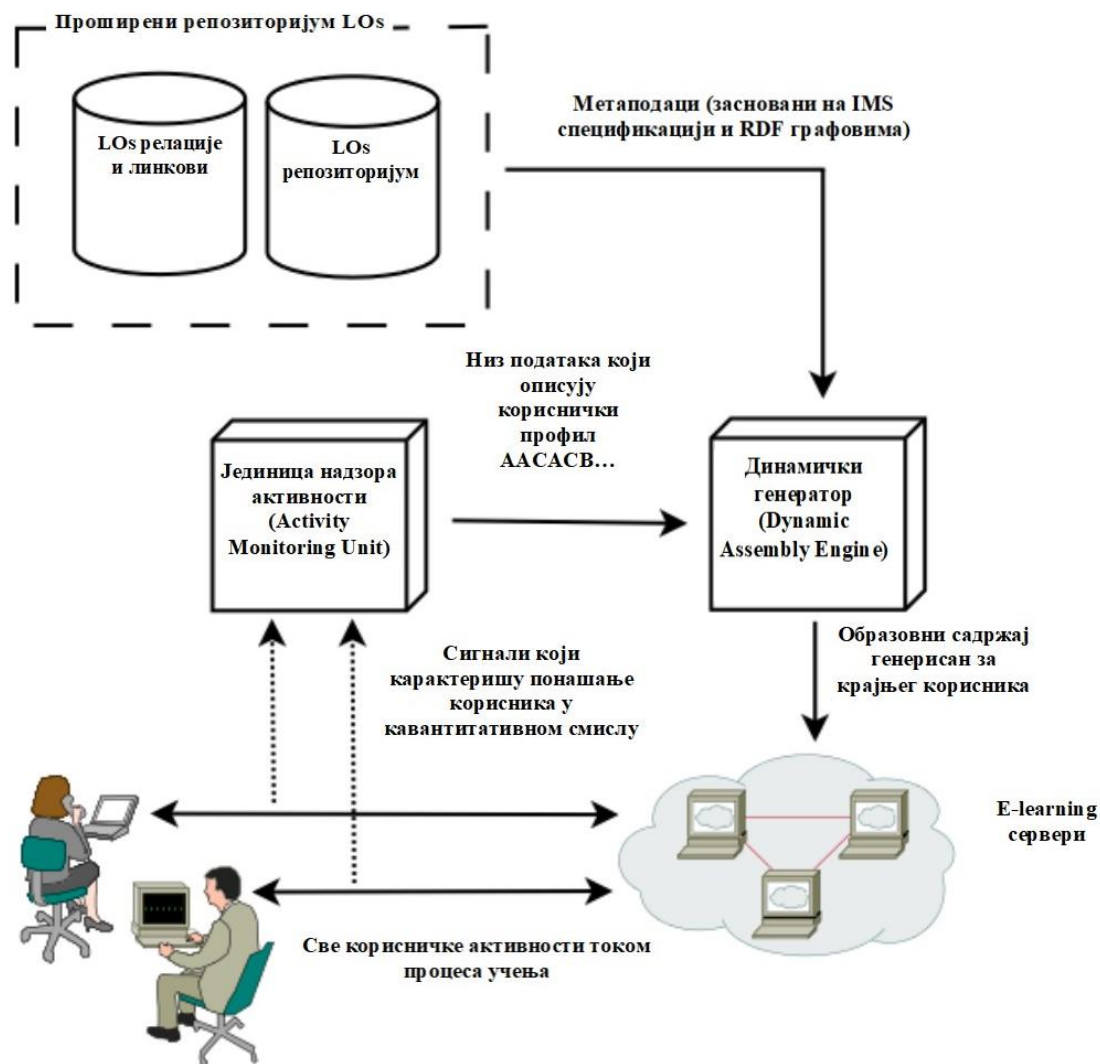
Структура типичног LMS са додатним подсистемом (генератором), који може да бира, према неким преддефинисаним правилима одлучивања, одговарајуће образовне објекте из репозиторијума, окупља их и креира курс, је дата на слици 25.



Слика 25: Основни модел достављања образовног садржаја путем образовних објеката (Zajac & Piekarczyk, 2003)

Ово решење има две битне предности – могућност коришћења дељивих ресурса и аутоматизацију креирања садржаја за учење. Основни недостатак оваквог система је да не узима у обзир индивидуалне образовне преференце појединца. Assembly Engine креира курсеве окупљањем свих образовних објеката везаних за тему која се обрађује. Тако студент, обично, добија материјале припремљене једнообразно и нема никаквог утицаја на коначну структуру садржаја који му се испоручује. У циљу обезбеђивања адаптивности курса, који ће бити креиран према потребама и очекивањима студента, неопходно је укључити и саме студенте у процес креирања курса. Кључно питање је укључивање корисничке интеракције као интегралног дела процеса креације курса, а без губитка ефекта аутоматског достављања образовног садржаја.

Измене би требале да буду уведене у зависности од активности појединог корисника. Одговарајућа јединица система треба да прати и надзире факторе, као на пример: редослед коришћења и тип ресурса који се користе, количину референци ка њима или чак и број повратака на већ коришћене изворе. Слика 26 представља идеју система унапређеног увођењем јединице надзора активности (енг. Activity Monitoring Unit – AMU), чији је задатак прикупљање горе поменутих података. Њено присуство у уопштеној структури система омогућава креирање повратне спреге и, последично томе, потпуно аутоматизовано креирање крајње персонализованог садржаја.



Слика 26: Структура система обогаћеног механизмом надзора активности корисника (Zajac & Piekarczyk, 2003)

Проток података у систему је у потпуности затворен. Шта више, ово решење допушта систематско побољшање нивоа компатибилности начина на који студент усваја нова знања и начина на који се она достављају студенту. То се постиже модификацијом путање учења, представљене низом особина које описују профил студента.

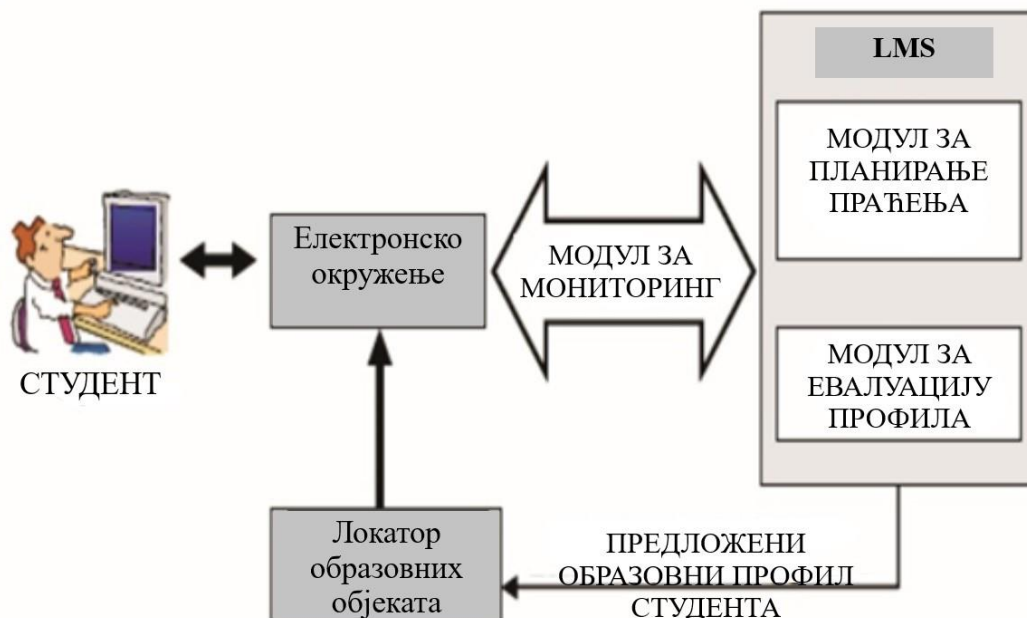
Dynamic Assembly Engine треба да интегрише одабране образовне објекте да би се испунили релацијски захтеви дефинисани моделом студента. Истовремено, ова јединица мора да узме у обзир и обавезне узајамне релације међу појединим компонентама курса, наметнуте образовним циљевима, као и самим програмом (силабусом) курса (Zajac & Piekarczyk, 2003).

Постоје бројни модели имплементације стилова учења, од којих је сваки одговарајући различитој образовној области. Према Фелдеру и Бренту (Felder & Brent, 2005), и поред бројних модела за адаптирање путем стила учења, могуће је издвојити пет модела, који су примењиви у области електронског образовања: MBTI – Myers-Briggs Type Indicator, Kolb's Experiential Learning Model, Hermann Brain Dominance Instrument – HBDI, Dunn & Dunn Model и Felder-Silverman Model.

Предложена архитектура система

LMS систем са адаптивним образовним окружењем, које је прилагођено наставним стратегијама, одговарајућим профилима студента, треба да има такву архитектуру која би омогућила праћење студента у процесу учења, као и идентификовање његовог образовног профила. Образовни профил се добија путем анализе података о интеракцијама студента, заснованим на моделу профила, који је претходно већ дефинисан од стране наставника (аутора система). Слика 27 приказује архитектуру која је начињена од модула.

Предложена архитектура омогућава наставнику да дефинише и одреди особине које ће пратити и посматрати, а које су по његовом мишљењу највише одговарајуће за обрађивани образовни домен. Могућност моделовања опсервације особина даје окружење веће флексибилности у евалуацији образовних профила. Ово се постиже модулом Module of Observation Planning (Supangat & Mohd Zainuri, 2020).



Слика 27: Могућа архитектура адаптивног e-Learning LMS за студенте са различитим стилем учења

Пре почетка дефинисања посматраних и праћених особина, неопходно је одредити модел стила учења који ће се користити. Могуће је дефинисати и извести бројне комбинације на основу модела FSLS, у које се може сврстати студент на основу процењеног стила учења. Архитектура система омогућава наставнику да дефинише модел образовног профила, који ће касније пратити понашање студента и који ће сугерисати образовни садржај на основу процене профила.

Питање које се поставља је „које податке о интеракцијама студента треба разматрати и узимати у обзир?“. У суштини, ти подаци зависе од циљева учења. Управо због тога, класификација образовних профила студената не може и не треба да је иста у различитим образовним аспектима и ситуацијама. Неопходно је дефинисати особине и податке који ће се пратити током интеракције студента у електронском образовном окружењу. Наставник то чини у модулу Module of Observation Planning. Подаци се могу добити на два начина: директним одговорима које студент даје на имплементираних тестове и вежбе (на тај начин је наставник у могућности да прати и проверава ток знања које се

формира код студента) или путем студендових интеракција (то су интеракције са системом, као што су склоности ка одређеном типу материјала, број приступа датим садржајима, интеракција са понуђеним алатима итд.).

Планирање праћења података би требало да буде употпуњено следећим подацима:

- опис особине која се прати – даје се опис шта се посматра и прати
- функција – свака од посматраних особина може имати додељену функцију, чија је сврха интегрисање добијених информација и праћених особина
- локација посматрања – место у образовном окружењу где се праћење/посматрање дешава
- време посматрања – када се дешава и бележи праћење/посматрање (Zagulova et al, 2019).

Једна праћена особина рефлектује склоности студента. Због тога наставник треба, током планирања праћења, да класификује сваку праћену особину у једну од категорија склоности: Перцепција, Формат презентације, Редослед презентације или Партиципација (Felder & Silverman, 1998). Ове категорије одговарају димензијама Felder-Silverman Learning Style модела. Тако, на пример, особина која је класификована као Перцепција указује на сензорно/интуитивни образовни профил.

Група посматраних особина чине Observation Model, који се прослеђује Monitoring Module на коришћење за праћење интеракција студента у e-Learning окружењу.

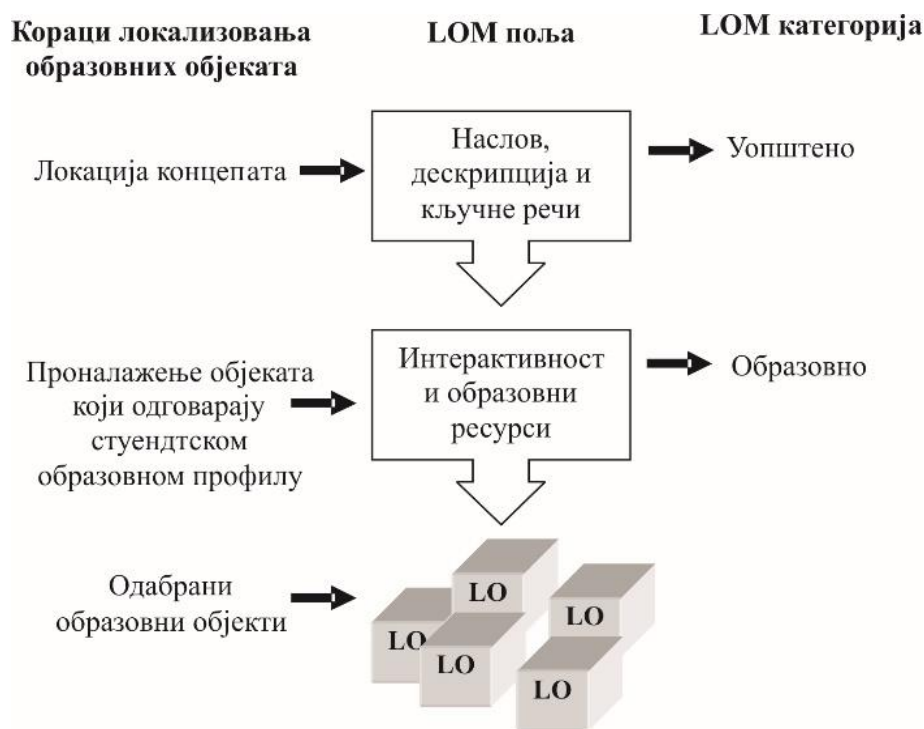
Следећи корак јесте одређивање вредности за сваку од посматраних особина, а у циљу одређивања типа образовног профила који ће се усвојити током процеса класификације. На основу вредности које дефинише и допушта систем, разликују се различити типови образовних профила (у зависности од варијетета праћених особина). Наставник може одредити карактеристике сваког типа образовног профила, за потребе категорија склоности које се користе у дефинисању посматраних особина. Један тип образовног профила може имати више посматраних особина, које ће се скупа процењивати, током процеса класификације профила студента.

Наредни корак је креирање репозиторијума у који ће се похрањивати информације добијене од мониторинг модула. Monitoring Module бележи податке и резултате студендове интеракције и шаље их систему који их складишти у репозиторијуму. Не постоји никаква анализа по питању студендове интеракције током процеса мониторинга, јер је битно добити што бројније податке, помоћу којих ће се анализирати различите студендове акције. Анализа података, добијених праћењем интеракција студента, се дешава када студент комплетира образовни модул. По комплетирању образовног модула, мониторинг модул то сигнализира систему (да је готов процес и да су прикупљене информације о интеракцијама). На основу тих информација Profile Evaluator Module повезује информације о интеракцијама студента (користећи функције додељене свакој од праћених особина) које су похрањене у репозиторијуму. Резултат оваквог повезивања ће одредити вредности сваког циља, описаног кроз посматрану особину, за конкретног студента и на тај начин пружити информацију за одређивање профила студента.

Profile Evaluator Module извршава алгоритам одређивања профила. Систем затим смешта одређеног студента у претходно дефинисани образовни профил, који му највише одговара. Из разлога што је профил заснован на неколико посматраних особина, врло је

вероватно да се неће наћи потпуно одговарајући профил, који ће имати исте вредности за посматране особине као што су оне код студента. Да би се овај проблем превазишао, модул Profile Evaluator прилагођава образовни алгоритам, тзв. 1-Nearest Neighbor. Овај алгоритам проналази објекте који сачињавају скуп системски познатих примера, који су најближи другом објекту који се посматра у датом тренутку. У разматраном систему, скуп примера је дат типом образовних профила, који су дефинисани током моделовања (Supangat & Mohd Zainuri, 2020).

Образовни објекти су дефинисани као ентитети који се могу применити у образовно-наставном процесу. Могу бити текстови, видео записи, шеме, слике, симулације итд. Основ је да су креирани у дигиталној форми и да се могу виšekратно користити, независно или као део конструкције неког другог образовног објекта. Главни проблем је како и које образовне објекте доделити студенту? Сваки од образовних објеката има свој опис, помоћу кога се лоцира и препознаје у репозиторијуму образовних објеката. За тај посао је дефинисан посебан модул – локатор образовних објеката (енг. Learning Object Locator). Learning Object Locator користи опис концепата тема које су повезане са образовним садржајем, а у циљу обављања првог корак у процесу локације. Да би се обавио овај посао, користе се уопштене категорије LOM спецификације, што подразумева поља: наслов, опис и кључне речи. Резултат претраге ће бити први избор могућих објеката, који се може презентовати студенту (Supangat & Mohd Zainuri, 2020). Други корак у локацији се састоји од проналажења одговарајућих објеката који одговарају студентовом образовном профилу, међу скупом објеката одређених у првом кораку. Ово се ради верификовањем студентовог образовног профила. Користећи образовне категорије LOM стандарда, локатор проналази објекте који одговарају преференцама везаним за образовни профил студента (од скупа објеката који су одређени првим кораком проналажења). Када карактеристике образовног профила студента индукују да ли је студент активан или рефлексиван, образовне стратегије које се могу усвојити су форуми, причаонице, дискусионе групе итд. По завршетку другог корака проналажења образовних објеката, образовно окружење прима све селектоване образовне објекте и презентује их студенту.



Слика 28: Процес одабира образовних објеката

3.7. Адаптирање e-Learning LMS путем креирања персонализоване повратне информације

Повратна информација (енг. Feedback) је одговор на корисникову акцију и проследи се кориснику да би могао да упореди своје перформансе са оним које је очекивао. Главна улога повратне информације у Web-оријентисаним образовним системима је информисање корисника на шта треба додатно да обрати пажњу, као и мотивисање корисника на повећање будућег напора. Повратна информација се може разликовати по садржају, времену и начину презентовања. Персонализација повратне информације пружа могућност њеног прилагођавања, тако да буде највише одговарајућа корисниковом знању, могућностима и когнитивним могућностима (уопштено посматрајући), а посебно према његовом тренутном расположењу и стању, као и према пажњи коју посвећује раду са системом.

У даљем излагању ће се размотрити и анализирати персонализација повратне информације према стилу учења корисника, и предлози дизајна повратних информација и начина адаптације у e-Learning LMS.

У e-Learning LMS системима, повратна информација има пресудну улогу у интеракцијама. Повратна информација је посебно важна у тестирању и оцењивању задатака у оквиру образовног процеса у LMSs. У оваквим системима повратне информације се могу разликовати по: *функцији* (потврдне, корисне или евалуационе); *комплексности* (без повратне информације, подаци о одговорима, подаци о тачним одговорима, понављање одговарања до тачног одговора или сложене); *времену дешавања* (тренутне или одложене повратне информације); *корисниковом напретку кроз задатак* (непосредно, непрекидно или збирно) и по *начину презентовања* (текстуалне, визуелне, аудио или видео) (Bimba, Idris, Al-Hunaiyuan, Mahmud & Shuib, 2017). На основу овога се закључује да овај вид персонализације пружа разнолике могућности снабдевања корисника са одговарајућим повратним информацијама, у горе поменутом контексту.

Као што је разматрано, према (Khamparia & Pandey, 2020) нема сагласности по питању потребе имплементације стилова учења у e-Learning LMS системима. Ипак, кроз бројна истраживања се показало да студенти из различитих група стилова учења показују посебне реакције у интеракцији са хипермедијалним образовним окружењем. Различити системи омогућују адаптивност према стилу учења кроз адаптацију садржаја, навигације или коришћењем вишеструког навигационог алата. Већина адаптивних e-Learning LMS, који имају имплементирани кластери стилова учења, се заснивају на чињеници да упаривање одговарајуће стратегије учења студента са кластером стила учења побољшава студентове перформансе.

Персонализација повратне информације (заснована на личном стилу учења) се може укратко изложити кроз две класификације (табела 7): 1) Field dependence/Field independence (област зависности/област независности) модел – FD/FI модел и 2) Четвородимензионим моделом Felder & Silverman стилова учења – F-S модел, (Felder & Silverman, 1998). Битно је истаћи два аспекта повратних информација: 1) *информациони* аспект (шта се презентује у повратној информацији) и 2) *мотивациони* аспект (када и како се повратна информација презентује).

Табела 7: Адаптација повратне информације у зависности од стила учења студента

АДАТАЦИЈА ПОВРАТНЕ ИНФОРМАЦИЈЕ ПРЕМА СТИЛУ УЧЕЊА	
FD, Секвенцијални	FI, Глобални
<ul style="list-style-type: none"> • увек пружа тренутну повратну информацију • представља повратну информацију у главном прозору (не у новом ро-џр прозору) • не користи хипервезе у тексту повратне информације • приказује тачан одговор и кратко образложење • увек похваљује тачан одговор • користи мултимедијске ефекте (звук, анимацију) за мотивисање студента 	<ul style="list-style-type: none"> • представља непрекидну повратну информацију и демонстрира напредак корисника у оквиру задатка • корист оцене за мотивисање • не користи медијске ефекте (аудио, анимације и сл.) • представља детаљну повратну информацију, која укључује хипервезе ка образовним материјалима који одговарају постављеном питању и задатку
Активни	Рефлективни
<ul style="list-style-type: none"> • даје и подноси одговоре до исправне повратне информације • користи екстерно награђивање у тестовима, да би мотивисао студента • приказивање анимираних елемената у повратној информацији 	<ul style="list-style-type: none"> • приказује повратну информацију у новом прозору и време обраде • пружа детаљне повратне информације • не користи аудио записе као главни извор повратних информација
Сензорни	Интуитивни
<ul style="list-style-type: none"> • приказује тренутну повратну информацију • не обезбеђује непрекидну повратну информацију • користи различите типове медија за повратне информације (вербалне, визуелне, аудио, тактилне...) • презентује корективне повратне информације или детаљну повратну информацију са кратким теоретским резимеом или практичним објашњењем 	<ul style="list-style-type: none"> • пружа тренутну корективну или детаљну повратну информацију, са кратким теоријским објашњењем само у случају нетачног одговора • презентује непрекидну повратну информацију • не користи мултимедијске ефекте (аудио, анимације или видео) у повратној информацији
Вербални	Визуелни
<ul style="list-style-type: none"> • приказује повратну информацију као текст, бројке или у виду дијаграма • користи повратне информације у форми аудио записа 	<ul style="list-style-type: none"> • користи више графичких информација у презентацији повратне информације (слике, дијаграме, анимације и кратке филмове)

FD/FI димензија је нарочито важна за e-Learning LMS, јер представља степен у коме студентове перцепције или разумевање информација зависе од околне перцептивне или контекстуалне области. FD оријентисани корисници захтевају додатна појачања и навигациону подршку, док FI оријентисани корисници захтевају минимално навођење и основна упутства.

F-S четворо-димензионални (активно/рефлективни, сензорно/интуитивни, визуелно/вербални и секвенцијално/глобални) модел се сматра за највише одговарајућу и најостварљивију теорију стилова учења у e-Learning окружењу.

Адаптација повратних информација у e-Learning окружењу је, до сада, врло селективно проучавана. Тако су претходно изложени резултати високо спекулативни, на нивоу претпоставки и потребна им је даља потврда, кроз неко шире и свобухватније истраживање. Такво истраживање је потребно да би се утврдила позитивна шема релација између појединих стилова учења и параметара прилагодљивих повратних информација, у циљу повећања ефикасности интеракције и образовног процеса.

3.8. Адаптирање e-Learning LMS путем персонализованог интерфејса

У модерним генерацијама e-Learning система би требало да буде омогућено персонализовање његовог интерфејса. Могућност презентовања on-line образовног окружења које покрива хетерогене потребе групе студената (различите нивое знања, културно залеђе, различите стилове учење итд.) је неопходно, као и могућност система да пружи персонализовани приказ / интерфејс (Herder, Sosnovsky & Dimitrova, 2017).

Персонализовано образовно окружење подразумева окружење у коме је студент у могућности да прилагоди своје образовно окружење према својим педагошким или личним захтевима и изборима. Сходно оваквом дефинисању прилагодљивог образовног окружења, лако је увидети значај могућности прилагођавања интерфејса. Персонализовани систем за учење треба да омогући такав кориснички интерфејс, који ће допуштати прилагођавање приказа образовних објеката и активности. Примери студентових приказа образовних објеката и активности могу бити засновани на:

- темама
- времену
- педагошким методама
- медијским типом/врста интелигенције
- нивоу (пред)знања и вичности
- образовним циљевима
- студентовој продукцији образовних објеката/активности
- ранг позицији
- списку образовних објеката препорученим од стране система, а на основу понашања и навика претходних корисника
- вођеним (диригованим) путањама учења, продуктованим од стране наставника
- претрази (текста) (Hariyanto & Kohler, 2017).

Многи данашњи LMS дозвољавају само један од наведених типова приказа, као нпр. тема структуре садржаја, или хронолошко структурирање садржаја курса. Ово није довољно у образовном окружењу које би требало да обезбеди индивидуализацију и диференцијацију.

Теме

Један од студентских приказа у корисничком интерфејсу се може заснивати на темама. Ово захтева кориснички интерфејс у коме су образовни објекти доступни кроз директоријуме наставних јединица, а са хијерархијском структуром тема. Као пример имамо курс Информатике (предмет у основним академским студијама, који је на првој години Педагошког факултета):

Информатика:

- Word
 - кратак преглед
 - постављање маргина и линија са алатима
 - креирање првог документа
 - напредне технике обраде текста
- PowerPoint
 - кратак преглед
 - прилагођавање радног окружења
 - креирање прве презентације
 - напредне технике едитовања мултимедијалних презентација
- Excel
 - увод, прилагођавање радног окружења
 - преглед основних алата
 - рад са подацима и формулама
 - креирање табела
- FrontPage
 - појам web презентације, кратак преглед
 - стратегије креирања web презентација
 - уграђени шаблони и чаробњаци (wizards).

Време

Време би требало да буде додатни приказ. Систем може презентовати образовне објекте хронолошки, где студент прво види најновије образовне објекте. Студентов приказ заснован на времену је посебно користан када студент жели да пронађе образовни објекат или материјал на основу тока курса и плана одвијања курса током семестра.

Педагошке методе

Образовни објекти такође могу бити доступни у зависности од педагошких метода коришћених за остваривање образовних циљева. Ово значи да, ако је студент радио у оквиру активности заснованој на нпр. педагошкој методи „игре“, онда би требало да може да одабере друге образовне активности типа „игра“.

По (Al-Chalabi & Hussein, 2020) категоризација поменутих педагошких метода је следећа:

- презентација – у методу презентације, извор казује или на неки други начин прослеђује информацију до студента. То је једносмерна комуникација контролисана од стране извора, без неких међуодговора или интеракције од стране студента. Извор може бити уџбеник, аудио или видео запис, образовни филм итд.
- туторијали – тутор (у форми особе, рачунара или посебних специјално штампаних материјала) излаже садржај (поступак), представља проблем и питања, захтевајући одговор студената, анализира њихове одговоре, обезбеђује одго-

варајућу повратну информацију и омогућава вежбање док год студент показује, претходно дефинисан, ниво компетности. Тудорски аранжмани укључују дијалоге типа: инструктор-студент (Sokrat дијалог), студент-студент (tutoring или програмирано тудорство), рачунар-студент (комјутерски подржан тудорски софтвер) и штампани материјали-студент (разграната програмирана настава). Прати се образац разгранате програмиране наставе, а то је да се информације презентоване у малим јединицама, пропрате питањем или задатком. Рачунар анализира студентов одговор (пореди га са одговорима које је већ понудио аутор-администратор) и даје одговарајућу повратну информацију. Компликована мрежа гранања се може испрограмирати. Што је више алтернатива доступно рачунару, то је тудоријал прилагодљивији индивидуалним разликама студената.

- демонстрација – у методу демонстрације, ученик види реалне, животне примере вештина, способности или процедура које треба да научи. Циљ за студента може бити имитирање (опонашање) физичких перформанси или усвајање ставова и/или вредности приказаних од стране некога, ко служи као узор/модел.
- дискусија – као метод, дискусија укључује размену идеја и мишљења међу студентима или између студената и наставника. Може се користити на ма ком нивоу образовног процеса, било у малим или великим радним групама.
- дрил и вежба – овом методом студенти се воде кроз низ практичних вежби, дизајнираних тако да повећају владање новим способностима или да обнове већ постојеће. Употреба овог метода претпоставља да су студенти претходно усвојили нека знања и представе о концептима, принципе или процедуре које ће бити практиковане... Практичне вежбе би требало да укључују повратну информацију која ће да потврди тачне одговоре и да исправи погрешне.
- учење кроз игру – играње пружа опуштено, нековенцијално окружење, у коме студенти прате унапред одређена правила, савлађујући препреке у покушају остваривања постављеног циља. Ово је високо мотивишућа техника, посебно за монотоне, понављајуће садржаје. Игре могу укључити једног или читаве групе студената.
- симулација – симулација подразумева сучељавање студената са ублаженом, прилагођеном верзијом стварне ситуације. Симулација може садржати и дијалог учесника, манипулацију материјом и опремом или интеракцију са рачунаром. Постоје различити типови симулација: физичке, итеративне, процедуралне и симулације ситуација, а све оне су корисне у обрзовном окружењу.
- откриће – то је наставна стратегија која се одвија на следећи начин: прво следи удубљивање у стварну или исконструисану проблемску ситуацију, затим се развијају претпоставке, тестирају се хипотезе и коначно се добијају закључци. Метода откривања користи индуктивни, испитивачки приступ учењу. Њоме се презентује проблем за решавање кроз низ проба и погрешака или кроз семантички приступ.
- решавање проблемских ситуација – решавање проблема подразумева довођење студената у активну улогу, приликом сучељавања са проблемом, смештеним у стварно окружење. Студенти стартују са ограниченим знањем, али кроз

међусобну сарадњу они граде, закључују, објашњавају и бране став по питању проблема или добијено решење. Студенти морају истражити и испитати податке или презентоване информације, тачно извести експерименте, а затим преиспитати податке и одредити решење. Рачунар може представити проблем, обрадити податке, креирати базу података и обезбедити повратну информацију када је то прикладно.

Медијски тип

Примери различитих медијских типова су: текст, бројеви, аудио, видео, илустрације итд. Студент би требало да буде у стању да одабере образовне објекте на основу медијског типа. Ово значи да би систем требало да презентује све аудио образовне објекте, видео образовне објекте, текстуалне објекте итд.

Вишеструки типови интелигенције ће захтевати различите типове образовних објеката, нпр. визуелни тип интелигенције ће захтевати презентацију, mind-мапе, мапе концепата и графиконе, док ће кинестатички тип захтевати симулације и алате осетљиве на покрет.

Ниво предзнања

На основу Dreufus-ове теорије нивоа стручности и вичности, раније описани систем такође мора да презентује образовне објекте сходно нивоу стручности, тј. предзнања (Williams, B. W., Burne, Williams, N. V. & Williams, M. V., 2017). Студент би требало да може да приступи образовним објектима на почетничком нивоу, ако је то потребно, док би неки други студент могао да приступи истим објектима али на напреднијем или експертском нивоу.

Образовни циљеви

Студент би, такође, требао да има приступ образовним објектима, сходно типу образовног циља (циљева). Различити образовни циљеви се могу наћи у основним категоријама знања (когнитивни образовни циљеви), способности (психомоторни образовни циљеви) и ставова (афективни образовни циљеви).

На основу добро познатих таксономија, такође се издвајају подтипови образовних објеката, који се могу размотрити приликом стварања персонализованог студентског интерфејса. Блумова таксономија за когнитивне домене има следеће подтипове: знање, разумевање, апликација, анализа, синтеза и евалуација. Kratwohl, у својој таксономији афективних домена разликује пет подтипова: пријем, одговор, вредност, организовање вредности и унутрашње вредности (Urgo, Arguello & Capra, 2019). Дејвова таксономија психомоторних домена има подтипове: имитација, манипулација, прецизност, артикулација, натурализација.

Као прилог, могуће је имати једну категоризацију образовног циља, звану мета-учење. Мета-учење је стање „свесности и преузимања контроле над сопственим учењем“.

Студентска продукција образовних објеката

Веома је важно да студент у образовном окружењу нема само улогу конзумента, већ и улогу аутора. Студенти често креирају текст, Web сајтове, mind-мапе и сл. који

могу користити другим студентима. У окружењу образовног кампуса, студенти размењују и деле белешке са предавања и сл., а у е-Learning окружењу би исто требало допустити размену материјала које су направили и креирали сами студенти. Због валидације квалитета образовних објеката, студентима мора бити очигледно које су објекте креирали студенти, а које наставници.

Ранг позиција

Уколико е-Learning систем допушта студентима да рангирају образовне објекте, онда такође може презентовати објекте према ранг позицији. На пример, образовни објекти на високој ранг позицији се приказују пре оних са нижом ранг позицијом.

На основу ранг позиције, систем може препоручити образовни објекат одређеном студенту, а из искуства сличних склоности других студената. Уколико студент високо рангира образовни објект, систем приказује друге објекте који су студенти са истом оценом тог објекта већ прегледали и добро оценили.

Образовни објекти препоручени од стране система, сходно понашању претходних студената

Систем би требало да може да препоручи објекте сходно понашању студента. Систем може препоручити образовни објект студенту у зависности од претходног понашања и избора других студената.

Дириговане путање учења

У неким случајевима може бити корисно за студенте да имају приступ образовним објектима, презентованим као дириговане (вођене) путање учења, које су креирали наставници. Путање учења подразумевају осигурање квалитета, док год су их креирали наставници.

Претрага текста

Додатни (допунски) начин приступа образовним објектима би требало да има могућност слободне претраге текста.

Имплементација различитих корисничких интерфејса (приказа), претходно описаних, захтева технолошка решења којима би се сачували образовни објекти, а у таквом маниру да су ти објекти сачувани на једном месту и виšekратно доступни у различитим семантичким контекстима. Претходно описани кориснички интерфејси, показују да је неопходно више се фокусирати на педагошке метаподатке.

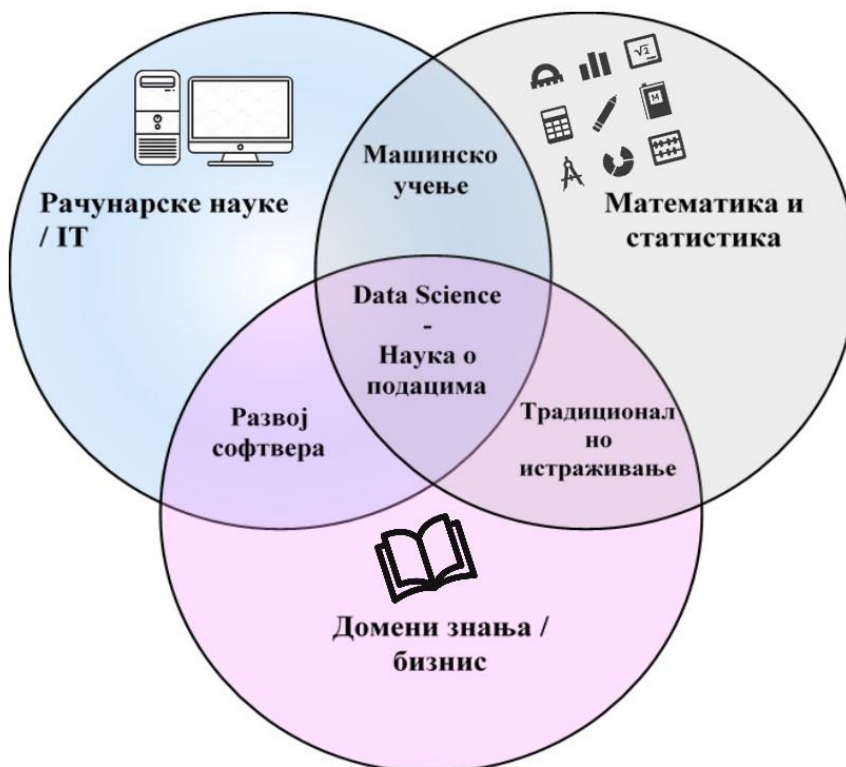
Према извештају LOM испитивања, метаподаци који описују интелектуални садржај (кључне речи, класификацију) и карактеристике ресурса као медија и интернет фајлове (технички формат, тип образовног ресурса) су добро искоришћени. Метаподаци који теже описивању ресурса као софтверских објеката, или повезивању са образовним контекстом или нивоом, се много ређе користе.

Кориснику прилагођен (User-friendly), индивидуализовани и диференцирани интерфејс је важан елемент е-Learning система. Уместо презентовања образовних објеката и активности кроз један стандардни интерфејс, који је исти за све студенте, мапа напреднијег е-Learning система би требало да покаже постојање више начина приказивања садржаја, подржавајући потребе хетерогене групе студената.

3.9. Методе и технике науке о подацима у e-Learning системима

Адаптивно учење се може посматрати као педагошка иницијатива и акција, заснована на анализи података образовног окружења, добијених током процеса учења студента. Овај мониторинг, познат као аналитика учења, омогућава прилагођавање процеса учења образовним потребама сваког студента. На тај начин, адаптивно или персонализовано учење строго зависи од архитектуре система за е-учење, који реагује према потребама сваког ученика. Генерисање адаптивног модела учења, усмереног на преференце студента, подразумева више компоненти као што су врста података и њихови извори, окружење у коме се модел примењује, архитектура анализе података и њена примена. Интеграција ових компоненти омогућава идентификовање потреба ученика кроз препознавање образаца у прикупљеним подацима и кроз њихову каснију класификацију. Приметна је потреба обраде великих, често вишедимензионалних прикупљених података (о навикама и склоностима студената, образовном и радном окружењу итд.), у сврху препознавања разних врста образаца, а ради бољег процеса одлучивања и вођења учења у самом LMS (Villegas-Ch, Roman-Cañizares, Jaramillo-Alcázar & Palacios-Pacheco, 2020a; Sorokina, 2020). Дисциплина која се, у ту сврху, примењује је наука о подацима (енг. *Data science*).

Због примене науке о подацима, у бројним доменима, различите су саме њене дефиниције, али све упућује на једно – добијање информација из прикупљених података неким одређеним методама. Првенствено то је наука која се користи за откривање скривених образаца из прикупљених података. Може се рећи да је *Data science* процес примене научних прорачуна, како би се, помоћу одговарајућих статистичких метода, издвојили и препознали значајни обрасци, релације и увиди из великог броја сложених података.

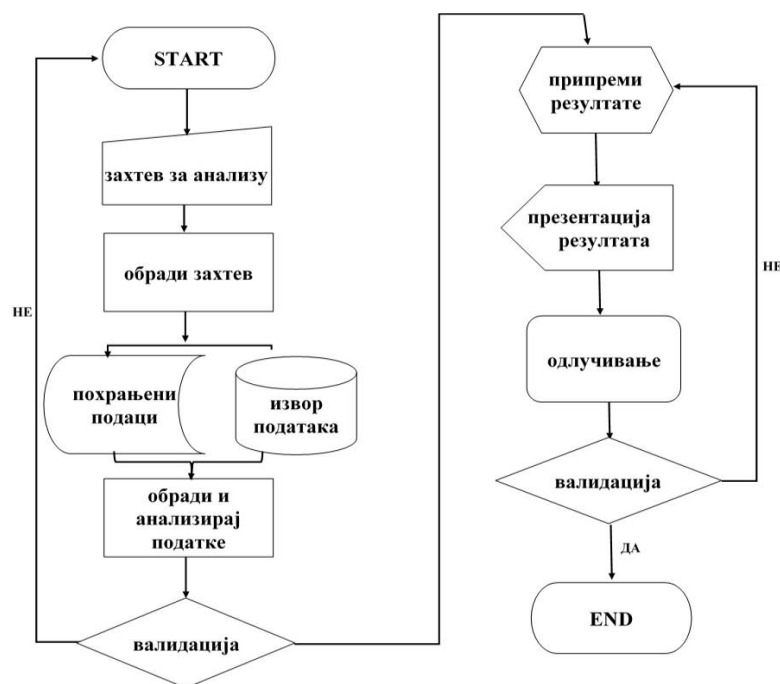


Слика 29: Data science – наука о подацима

Наука о подацима је синтеза математике и статистике, машинског учења, познавања домена, ИТ (информационих технологија), традиционалих истраживачких метода и развоја софтвера. Математика и статистика представљају језгра, јер све, од истраживања података до израде модела, захтева бављење бројевима, векторима, вероватноћом итд. Машинско учење се даље може поделити на дубинско учење (енг. Deep Learning) и вештачку интелигенцију (енг. Artificial Intelligence). Поред тога, сматра се да су развијање софтвера и ИТ вештине неопходне за примену у тим областима.

Адаптивно учење има директну везу са употребом ИСТ, јер их користи за складиштење и прикупљање информација. ИСТ омогућава стварање специфичних стаза учења за сваког ученика, комбинујући податке генерисане учениковом активношћу са статистичким информацијама и генеришући обрасце и унапред дефинисане одговоре, на основу проучавања степена ефикасности и учесталости са којима студент обавља своје задатке. Свака активност коју студент обавља оставља лични отисак, који је представљен у подацима. Адаптивни модел, за обезбеђивање персонализованог учења, мора у својој архитектури бити скалабилан и са способношћу да обрађује, не само велику количину података, већ и велики број њих, а управо то омогућавају методе и технике науке о подацима (Villegas-Ch et al, 2020a). Анализа података је веома важна за идентификовање потреба ученика, јер већ под тог корака започиње адаптивно учење. Однос између резултата добијених анализом података и персонализованог модела учења лежи у важности откривања елемената које треба побољшати (Sarıyalçınkaya, Karal, Altınay & Altınay, 2021).

ИСТ омогућава дизајн генеричке архитектуре за анализу података, усмерену на управљање великим обимом разноврсних података. Ове архитектуре се могу употребити за идентификовање и задовољење потреба ученика у моделу који гарантује скалабилност у управљању подацима. Даља анализа омогућава идентификацију образаца који су представљени у подацима; са овим резултатима могуће је класификовати појединце помоћу алгоритама за Data Mining који детаљно откривају могуће проблеме који постоје у одређеној популацији студената (Gajwani & Chakraborty, 2021).



Слика 30: Дијаграм тока модела анализе података примењен на адаптивно учење

Горњи алгоритам је ток модела анализе података у адаптивном систему е-учења (Villegas-Ch et al, 2020a). Различите променљиве, које омогућавају израду пројекција у вези са могућим решењем, се могу додати кроз утврђене форме анкета и разних упитника, који се спроводе међу студентима. Поред тога, модел аутономно комуницира са сваким студентом и, путем нотификација и обавештења, ставља у сврху развоја учења како њихове перформансе, тако и показане понављајуће неуспехе. Са презентацијом резултата, следећи корак алгоритма се фокусира на доношење одлука. Генерално, ово је задужење наставника, који су задужени за прилагођавање ресурса и активности потребама ученика. На крају, врши се валидација резултата добијених од ученика у новим активностима, који су прилагођени на основу спроведене анализе. Ако нема промене у учењу, процес се враћа на корак презентације резултата, где верификује активности и ресурсе резултатима, прилагођава их и наставља са главним током. Ако се проценом утврди да су активности учења прилагођене потребама ученика унапређивањем учења, процес се завршава.

Машинско учење (Machine Learning)

У другој половини XX века машинско учење (machine learning) се развија као подобласт вештачке интелигенције (AI – artificial intelligence) и укључивало је алгоритме самоучења, који изводе знања из података за предвиђање. Машинско учење је, уствари, одменило ручно извођење и утврђивање правила приликом креирања модела, а све то путем анализирања велике количине података. Машинско учење је ефикаснија алтернатива за чување знања у подацима, за постепено побољшавање перформанси предиктивних модела и доношење одлука вођених подацима (Gupta & Batra, 2021; Nagy, 2018).

Машинско учење већ има значајну улогу у свакодневном животу – на његовим принципима се заснивају филтери садржаја (непожељне поште, циљаних рекламних садржаја нпр.), софтвери за препознавање гласа и текста, web претраживачи...

Постоје три типа машинског учења:

- надгледано учење
- ненадгледано учење
- учење условљавањем (Villegas-Ch, Román-Cañizares & Palacios-Pacheco, 2020; Janiesch, Zscheck & Heinrich, 2021).

Табела 8: Типови машинског учења

ВРСТА МАШИНСКОГ УЧЕЊА	ОСОБИНЕ
НАДГЛЕДАНО УЧЕЊЕ	<ul style="list-style-type: none"> • Означени подацима • Директне повратне информације • Исход/будућност предвиђања
НЕНАДГЛЕДАНО УЧЕЊЕ	<ul style="list-style-type: none"> • Нема ознака • Нема повратних информација • Откривена скривена структура у подацима
УЧЕЊЕ УСЛОВЉАВАЊЕМ	<ul style="list-style-type: none"> • Процес одлучивања • Систем награђивања • Серије акција за учење

Надгледано учење

Главни циљ надгледаног учења јесте да се модел обучи, а на основу означених прикупљених података (током коришћења система и модела), који омогућавају да се изврши предвиђање о будућим подацима и акцијама модела.

На следећој слици је резимиран типичан ток рада надгледаног учења, у којем су прикупљени подаци прослеђени у алгоритам машинског учења за усклађивање предиктивног модела, који може да изврши предвиђања и одлучивања на новим, неозначеним подацима (Villegas-Ch et al, 2020).



Слика 31: Надгледано машинско учење

Поткласа надгледаног учења је *класификација*, која за циљ има предвиђање категоријске класе ознаке нових инстанци, а на основу ранијих опажања. Ознаке класе су дискретне, неуређене вредности, које дефинишу припадност инстанци некој групи. Алгоритам машинског учења, учи скуп правила да би разликовао различите класе инстанци (ако су у питању две класе, онда имамо бинарну класификацију; ако је у питању више ознака, онда имамо вишекласну класификацију).

Други тип надгледаног учења јесте предвиђање непрекидног исхода, и назива се *регресиона анализа*. У овом случају дат је број предиктор променљивих (истраживање) и непрекидна циљна променљива (исход) и покушава се пронаћи однос између тих променљивих, које омогућавају предвиђање исхода (Borkar, 2020).

Учење условљавањем

Још један тип машинског учења је учење условљавањем, у коме је циљ развити систем (агент), који побољшава своје карактеристике на основу интеракција са окружењем. Постоје бројни, различити подтипови ове врсте машинског учења, међутим основна шема је да агент у учењу условљавањем покушава да максимизује награду кроз серије интеракција са окружењем (Villegas-Ch et al, 2020).



Слика 32: Машинско учење условљавањем

Ненадгледано учење

За разлику од надгледаног учења, где се унапред зна тачан одговор приликом обучавања модела, или од учења условљавањем, где се дефинише мера награде за одређене акције које извршава агент, то се у ненадгледаном учењу користе неозначени подаци или подаци непознате структуре. Употребом техника ненадгледаног учења се може истражити структура података за издвајање значајних информација, без смерница познате променљиве исхода или функције награде (Villegas-Ch et al, 2020).

Кластеровање је једна истраживачка техника анализе података, која омогућава организовање групе информација у значајне групе (кластере), а без потребе постојања неког предзнања о члановима групе. Још једна подобласт овог типа машинског учења јесте *редукција димензионалности*. Коришћење високодимензионих података представља изазов за ограничавање простора за складиштење и перформансе израчунавања за алгоритме машинског учења. Редукција димензионалности је приступ који се користи као претпроцесирање атрибута, за уклањање шума из података (небитних или мање битних карактеристика) и за компресовање података у мање димензионалне подобласти са задржавањем најбитнијих информација (Bogkar, 2020).

Технологија моделирања заснована на машинском учењу, постала је моћна техника и алат за развој модела који објашњавања, предвиђа и описује понашање и релације човек/систем (Yang, Chiang, Cheng & Ji, 2021). У развоју интелигентних образовних система и технологија, нека истраживања се фокусирају на примену јединствених алгоритама машинског учења за изградњу модела студента, за потребе одређених образовних система (Raschka & Mirjalili, 2017). Из предочених карактеристика машинског учења, разумљиво је да представља битан концепт, алат и ставку у предиктивном моделовању, које је основни концепт адаптивних система за е-учење (Fri & Elouahbi, 2021).

Data Mining

Data Mining, које се у рачунарским наукама назива и откривање знања у базама података, је процес откривања занимљивих и корисних образаца и релација у великим количинама података (Kadam, 2020). Ова област комбинује алате из статистике и вештачке интелигенције (попут неуронских мрежа и машинског учења), са управљањем базама података, а у сврху анализе великих дигиталних колекција – скупова података. Data Mining је распрострањено у пословању (осигурање, банкарство, малопродаја), научним истраживањима (астрономија, образовање, медицина...) и државној безбедности (откривање криминалаца и терориста). Data Mining је првенствено усмерен на утврђивање општег знања о групи, а не на знање о одређеним појединцима, мада се

анализа узорака такође може користити за уочавање аномалног понашања појединца као што је превара или друга непожељна или криминална активност.

Комплетни процес Data Mining-а укључује више корака, од разумевања циљева пројекта и доступних података, до спровођења промена процеса на основу коначне анализе.

Три кључна корака су:

- процес учења модела
- евалуација модела и
- употреба модела.

Ова подела је најјаснија приликом класификације података. Учење модела се дешава када се један алгоритам примени на податке, о којима је познат атрибут групе (или класе), да би се произвео класификатор или алгоритам научен из података. Затим се класификатор тестира са независним скупом процене, који садржи податке са познатим атрибутима. У којој мери се класификације модела слажу са познатом класом циљног атрибута, у тој мери се може користити за одређивање очекиване тачности модела. Ако је модел довољно тачан, може се користити за класификацију података за које је циљни атрибут непознат.

Постоји више врста Data Mining-а, детерминисаних према врстама информација (атрибута) које су познате и врстом знања које се тражи из Data Mining модела.



Слика 33: Четири типа анализе Data Mining

Дескриптивно моделовање – моделовање засновано на кластеровању

Дескриптивна, описна аналитика статистички гледа на податке, како би описала и дефинисала шта се догодило у прошлости. Описна аналитика помаже разумевање тока дешавања неког процеса који се обавља, пружајући контекст који помаже

заинтересованим странама да тумаче информације. То може бити у облику визуелизације података као што су графикони, графици, табеле, извештаји и сл..

Дескриптивно (описно) моделовање или кластерисање, дели податке у истородне групе. Одговарајуће групе нису унапред познате, већ се обрасци откривени анализом података користе за одређивање група - кластера (Rajagopalan, 2021). На пример, наставник може да анализира општу популацију студената како би их класификовао у различите кластере, а затим развио засебне образовне стратегије и курсеве, циљано за сваку групу. Откривање превара такође користи груписање како би се идентификовале групе појединаца са сличним обрасцима понашања.

Дијагностичко моделовање

Дијагностичка аналитика иде корак даље и, узимајући у обзир дескриптивне податке, пружа дубљу анализу како би одговорила на питање: Зашто се догодило, то што се догодило? Често се дијагностичка анализа назива анализом основног узрока. То укључује употребу процеса као што су pattern mining (откривање образаца), Data Mining и детаљно анализирање. Дијагностички аналитички алати оснажиће процену дескриптивних података и, на тај начин, омогућиће изоловање основног узрока неког процеса и дешавања.

Предиктивно моделовање

Три кључне тачке предиктивне аналитике су анализа и оптимизација одлука, профилисање трансакција и предиктивно моделирање. Предиктивна аналитика користи обрасце у трансакционим и већ постојећим, добијеним подацима, како би идентификовала ризике и могућности. Предиктивно моделовање се користи када је циљ процена вредности одређеног циљног атрибута и ако постоје узорци података о обуци за које су вредности тог атрибута познате. Пример је класификација која узима скуп података који су већ подељени у унапред дефинисане групе и тражи обрасце у подацима који те групе разликују. Ови откривени обрасци тада се могу користити за класификацију других података где је припадност правој групи за циљни атрибут непозната (мада могу бити познати други атрибути) (Khan & Ghosh, 2021; Lal & Sachi, 2021).

Предиктивно моделовање подразумева све у вези са предвиђањем. Другим речима, предиктивна аналитика узима историјске податке и уноси их у Data Mining модел, који узима у обзир кључне трендове и обрасце. Модел се затим примењује на тренутне податке да би се предвидело шта ће се следеће догодити.

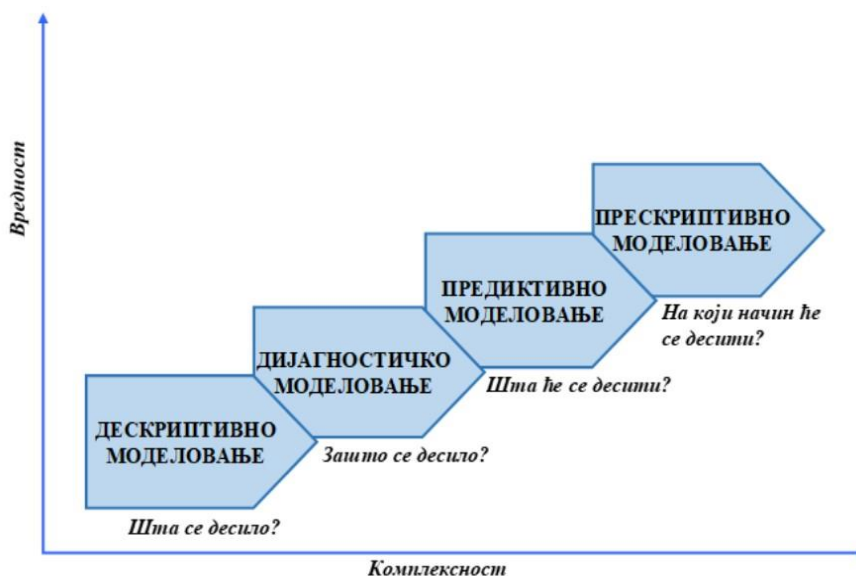
На пример, развијање предиктивног модела који детектује и препознаје склоности студената који под одређеним условима могу напустити студије. Друга техника која се користи у предиктивном моделовању је регресијска анализа, која се може користити када је циљни атрибут нумеричка вредност, а циљ је предвидети ту вредност за нове податке.

Прескриптивно моделовање

Прескриптивна аналитика је дисциплина у настајању и представља напреднију употребу предиктивне аналитике. Прескриптивна аналитика надилази једноставно предвиђање опција у предиктивном моделу и заправо сугерише низ прописаних радњи и потенцијалне исходе сваке радње.

Прескриптивни (прописани, предложени) модел користи разумевање онога што се догодило, зашто се то догодило и низ анализа „шта се може догодити“, да би помогло

кориснику да одреди најбољи курс даље акције. Прескриптивна анализа, за резултат, обично не даје само један појединачан одговор, већ је то заправо низ радњи. Прописани модел је способан, не само, да предвиди могуће последице на основу различитог избора акције, он такође може препоручити најбољи начин деловања за било који унапред одређени исход. Одличан пример је саобраћајна апликација, која помаже одабир најбоље руте до жељене деситнације, узимајући у обзир, при том, удаљеност сваке руте, брзину којом се може путовати на сваком путу и, што је најважније, тренутна саобраћајна ограничења.



Слика 34: Data Mining моделовање - 4 најзаступљенија типа

Табела 9: Особине 4 врсте моделовања

ТИП DATA MINING МОДЕЛОВАЊА	ОСОБИНЕ
ДЕСКРИПТИВНО	<p><i>Шта се десило?</i></p> <ul style="list-style-type: none"> • Разумљиви, тачни и постојећи подаци • Ефикасна визуелизација
ДИЈАГНОСТИЧКО	<p><i>Зашто се десило?</i></p> <ul style="list-style-type: none"> • Способност досезања основног узрока • Могућност изоловања свих збуњујућих информација
ПРЕДИКТИВНО	<p><i>Шта ће се десити?</i></p> <ul style="list-style-type: none"> • Стратегије остају доследне током времена • Историјски обрасци се користе за предвиђање одређених исхода помоћу алгоритама • Одлуке се аутоматизују помоћу алгоритама и ИТ-а
ПРЕСКРИПТИВНО	<p><i>На који начин ће се десити?</i></p> <ul style="list-style-type: none"> • Препоручују се акције и стратегије на основу претходних тестирања и анализа • Примењују се напредне технике анализирања податка за креирање прецизних препорука

Pattern mining

Pattern mining (откривање образаца/података) концентрише се на идентификовање правила која описују одређене обрасце у подацима. Иако је тестирање таквих правила

изводљиво и често их је једноставно уочити и препознати у малим скуповима података, Data Mining је омогућило откривање мање очигледних асоцијација у великим скуповима података. Најзанимљивије је откриће неочекиваних правила, која могу отворити потпуно нове правце за истраживања. Још једна важна употреба pattern mining-а је откривање секвенцијалних образаца; на пример, секвенце грешака или упозорења која претходе заказивању рада неке опреме, се могу користити за планирање превентивног одржавања или могу пружити увид у недостатак саме опреме (Lal & Sachi, 2021).

Откривање аномалија

Откривање аномалија може се посматрати као процес инверзан кластеровању – то јест проналажење инстанци података које су необичне и не одговарају ниједном утврђеном обрасцу (Pang, Shen, Cao & Hengel, 2021). Пример откривања аномалија је откривање превара. Иако се откривање превара може сматрати проблемом за предиктивно моделовање, релативна реткост преварантских трансакција и брзина којом криминалци развијају нове врсте превара значе да је вероватно да ће било који предиктивни модел бити ниске тачности и да ће брзо застарети. Стога се откривање аномалија, уместо тога, концентрише на моделовање уобичајеног понашања како би се идентификовале необичне трансакције. Откривање аномалија се такође користи са разним системима за надзор.

Образовни Data Mining (EDM – Educational Data Mining)

Образовни Data Mining (EDM) је дисциплина у настајању, која се бави развојем метода за истраживање јединствених и све већих података који потичу из образовног окружења, и коришћењем тих метода за боље разумевање студената и околности у којима они уче (Dhika, Destiawati & Jaya, 2021). Без обзира да ли су образовни подаци добијени од активности студената у интерактивним образовним окружењима, рачунарски подржаног колаборативног учења или административних података из школа и универзитета, они често имају више нивоа смислене хијерархије, које чешће треба одредити сходно својствима самих података, него унапред. Питања времена, редоследа и контекста такође играју важну улогу у проучавању образовних података.

Анализа и интерпретација података генерисаних у LMS-има ствара потешкоће, јер захтева од наставника да има вештине у коришћењу техника Data Mining и интерпретације истих. На пример, добијени подаци могу садржати временски уређену листу курсева које је студент похађао, оцену студента из сваког предмета и када је студент изабрао или променио академски смер. EDM користи ове податке како би открио значајне информације о различитим склоностима и навикама студената и начину њиховог учења и структури знања; о домену и ефекту стратегија подучавања уграђених у различита окружења за учење. Ове анализе пружају нове информације које би било тешко распознати обрађујући добијене податке стандардним статистичким анализама. На пример, анализа података о студенту може открити везу између оцене из одређеног предмета и студентовр одлуке да промени свој академски смер или чак напусти студије. Такве информације пружају увид у дизајн образовног окружења, што омогућава студентима, наставницима, администраторима и институцијама, које спроводе образовну политику, да доносе утемељене одлуке о начину интеракције са, достављањем образовних ресурса и управљању њима (Şahin & Yurdugül, 2020; Salloum, Alshurideh, Elnagar & Shaalan, 2020; Sáiz-Manzanares et al, 2021).

4. МОДЕЛ АДАПТИВНОГ СИСТЕМА Е-УЧЕЊА

Као резултат анализе постојећег LMS система, може се створити скуп ресурса, који би били на располагању полазницима е-Learning курсева. Ови ресурси припадају интелигентним рачунарским системима. Овакав тип организације LMS је заснован на могућности складиштења карактеристичних информација о ученику/студенту у електронску базу података. Понашање корисника LMS система директно утиче на интерактивну комуникацију корисник – систем. Да би се постигла индивидуализација образовног процеса, а сходно томе и адаптивност, овакве информације би требале да се разматрају и чувају. Касније, овакве информације се анализирају и мењају приликом даљег коришћења система, током напретка кроз учење. Овакве измене у LMSs се називају адаптирање (адаптација) LMS-а на основу учења, док се похрањивање информација о кориснику назива индивидуализација.

Представљени е-Learning системи и теоретски рад о адаптивном електронском образовању, дефинишу моделе LMSs који имплементирају тачно дефинисане категорије и структуре личних информација о ученику и образовним материјалима.

У овом поглављу ће бити представљена уопштена структура интелигентног е-Learning система, којим се процес учења дели на етапе (нивое), који су високо програмирани и, на тај начин, независни од одређених предефинисаних педагошких категорија и парадигми. Представљени LMS поседује флексибилност како у дефинисању категорија индивидуалних информација, тако и у структури образовног материјала.

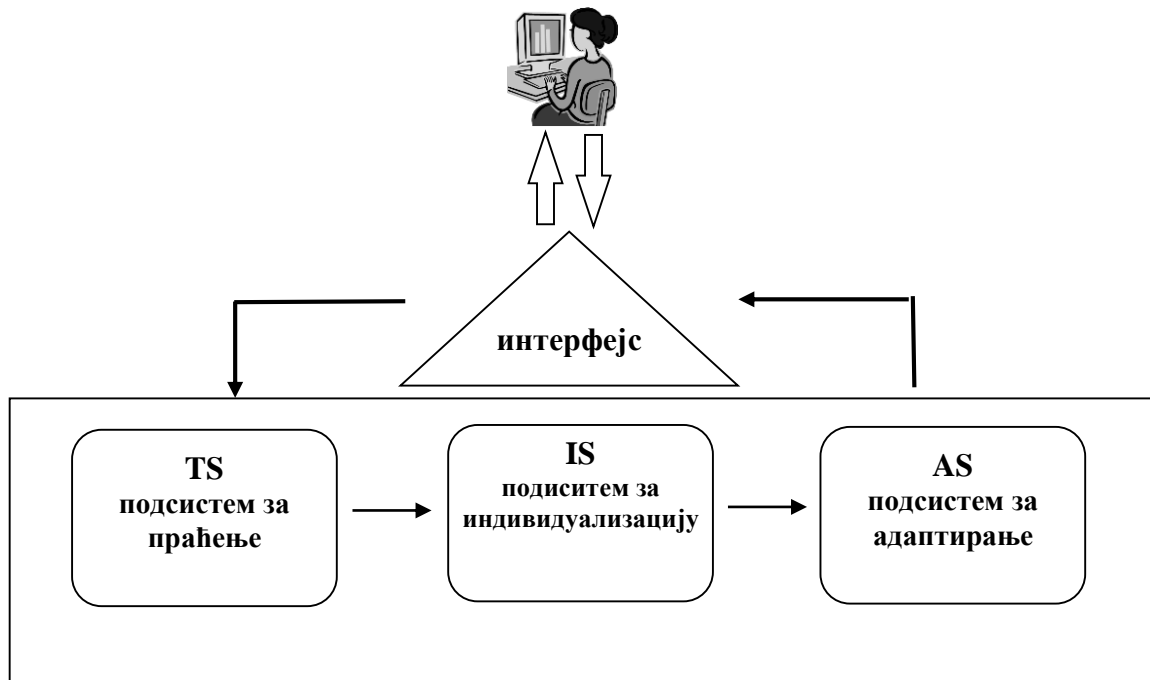
На предложено решење се може гледати као на уопштени модел адаптивног е-Learning система који омогућава структурирање образовних материјала, функционалност праћења и програмирање индивидуализационог и адаптивног подсистема.

4.1. Општа основна структура

Интелигентни LMSs треба да омогућавају бројне функционалности које обезбеђују персонализацију учења. Понашање LMS се прилагођава навикама ученика, а у циљу постизања најбољих задатих резултата. Бихевиорална адаптација се постиже помоћу подсистема за адаптацију (AS – Adaptive subsystem). AS прилагођава одговор LMS-а према кориснику, узимајући у обзир сачуване информације о ученицима. Ове информације су организоване у индивидуалне профиле – један профил за сваког ученика. Процес адаптације је немогућ без прелиминарне индивидуализације. Индивидуализација LMS се постиже кроз подсистем за индивидуализацију (IS – Individualizing subsystem). IS је одговоран за креирање индивидуалних профила ученика. Профил садржи карактеристичне информације, које се сакупљају током процеса интеракције између корисника и LMS система. Да би се обезбедило да LMS прати понашање, навике ученика, потребан је систем за праћење догађаја, који би прикупљао карактеристичне информације. Овакав систем се назива подсистем за праћење (TS – Tracking subsystem). TS садржи дефиниције и прати бројне догађаје (функционалне догађаје) који носе карактеристичне информације. Коначно, да би се омогућила комуникација корисника и система потребна је помоћна јединица интерфејса.

Значи, структура интелигентног, адаптивног, индивидуализованог система се већ назире. Такав систем се назива IALMS (Individually Adaptive Learning Management System), а основна структура једног таквог система је дата на слици 35. На слици су, такође, приказани и токови података у кружном току кроз процес образовања и кроз сам систем.

Ток података у IALMS се одвија, са једне стране, између система и ученика, а са друге стране, између различитих јединица система (Mudrák,2017). На тај начин, ток података је подељен на нивое. Сваки ниво је представљен типом пренетих информација.



Слика 35: Основна структура IALMS

Јединица интерфејса семантички не обрађује информације које пролазе кроз њу, већ само форму њихове презентације. Отуда интерфејс не припада језгру IALMS, које се састоји од подсистема за семантичку обраду информација. Информација прослеђена ученику и добијена назад од њега се назива образовни материјал. У овом случају, овакав концепт је уопштенији него у његовом стандардном смислу. Образовни материјал се састоји од сесија, сесија је сачињена од образовних блокова, а блокови могу бити пасивни и активни. Како представљају ток података између ученика и система, образовни материјали би требали двосмерно да носе информацију:

- од IALMS ка ученику (излазне информације)
- од ученика ка IALMS (улазне информације).

Сви блокови могу пренети излазне информације, али само неки од њих могу пренети и улазне информације. Потоњи се називају активним блоковима, док су остали пасивни.

Подсистем за праћење

Подсистем за праћење је предвиђен за улазну јединицу тока података ка IALMS језгру. Систем за праћење обрађује само активне блокове сваке сесије. Блокови образовних материјала су одређених типова, дефинисаних IALMS-ом. У зависности од свог типа, сваки активни блок се обрађује одговарајућом интерпретацијском функцијом. Резултат рада интерпретацијске функције се састоји од скупа вредности атрибута. Њихово значење је имплементирано у атрибуте, формирајући профил сваког корисника. Вредност датог атрибута одговара квантитативној мери дате ученикове карактеристике.

Подсистем за индивидуализацију

Овај подсистем се бави складиштењем карактеристичних информација сваког ученика у базу података. Повратне вредности интерпретирајућих функција се користе као извор тих, карактеристичних информација. Ове функције су дефинисане у подсистему за праћење. Карактеристичне информације су организоване у профиле – за сваког корисника се креира један профил. У почетку је овај профил празан. Профил се састоји од атрибута, а њихове дефиниције се раде у подсистему за индивидуализацију. Да би се одредиле нове вредности датих атрибута, њихова стара вредност се узима у разматрање, заједно са новом вредношћу добијеном од текуће интерпретационе функције. Нова вредност се израчунава, тј. одређује, акумулационом функцијом. Акумулационе функције су дефинисане у подсистему за индивидуализацију, као што је и за сваки атрибут дефинисана акумулациона функција.

Информациони круг, од корисника до подсистема за индивидуализацију, протиче према следећој шеми:

- Корисник завршава рад у датој сесији
- Интерфејс–јединица декодира резултате у долазећој сесији, која се састоји од активних блокова
- Сесија достиже подсистем за праћење. TS процесуира долазећу сесију, тако што за сваки активни блок одређује интерпретацијску функцију одговарајућу његовом типу
- TS извршава интерпретацијску функцију и, као резултат, добија сет вредности атрибута. Ове вредности атрибута се, затим, прослеђују подсистему за индивидуализацију
- IS процесуира сваку вредност атрибута из сета, прослеђујући их акумулационој функцији дефинисаној за дати атрибут
- Акумулациона функција обавља актуелизацију вредности атрибута у корисниковом профилу (Забунов & Гайдарова, 2010).

Подсистем за прилагођавање

Циљ AS је генерисање образовних материјала. Пошто је образовни материјал генерисан, предаје се кориснику путем јединице интерфејса. Образовни материјал је структурална композиција сесија. Свака сесија одговара класичној, традиционалној лекцији (из уџбеника). Главна разлика је у томе да алтернирајући садржај сесије циља на адаптацију према квалитету и знању ученика, за разлику од лекција које имају сталан, непроменљив садржај.

Образовни материјал „уоквирен“ лекцијом одређује степен варијације садржаја сесије. Тачан степен алтернације се одређује према дефиницији садржаја образовног материјала (EMC – Educational material content). Садржаји образовних материјала, заједно са гемнеришућом структуром образовних материјала (GSEM – Generating structure of the educational material) су главне мационе јединице подсистема за адаптацију. EMC је потпуно програмибилна. Дефинише се за сваку сесију образовног курса. Са друге стране, GSEM се дефинише само једном за цео курс и сталан је за све сесије.

Сваки курс, који је у оквиру IALMS-а, претпоставља да су GSEM и EMC дефинисани. Када корисник стартује са радом у систему, или завршава рад у некој од сесија и хоће да настави са учењем, IALMS генерише нову сесију кроз три нивоа:

1. бирајући нову радну сесију
2. бирајући садржај сесије
3. генеришући садржај сесије.

Прва два нивоа износи GSEM, док се трећи постиже кроз EMC. EMC се састоји од два типа компоненти: генератора и евалуатора. Они су функције. За сваки тип блока у GSEM-у, постоји одговарајући пар функција (један генератор и један евалуатор). Генератор је функција која генерише образовни материјал за дати блок сесије. Она има један параметар – идентификатор сесије, којој дати блок припада. Као резултат враћа образовни садржај за дати блок сесије. Функција евалуатора такође има један параметар – идентификатор сесије, којој дати блок припада. Као резултат враћа релативну вредност важности датог блока сесије.

GSEM има структуру реверзибилног стабла. На сваком огранку је дефинисан одговарајући тип – блок. GSEM одређује структуру свих сесија образовног курса. Тип – блок је информациона структура која одговара одређеном типу блокова из образовног материјала. Као што је већ речено, образовни садржај се састоји од сесија, а сесије су састављене од блокова. Блокови су најмањи, видљиви делови образовног материјала. Тип-блоку су додељени генератор и евалуатор. Оба припадају EMC-у.

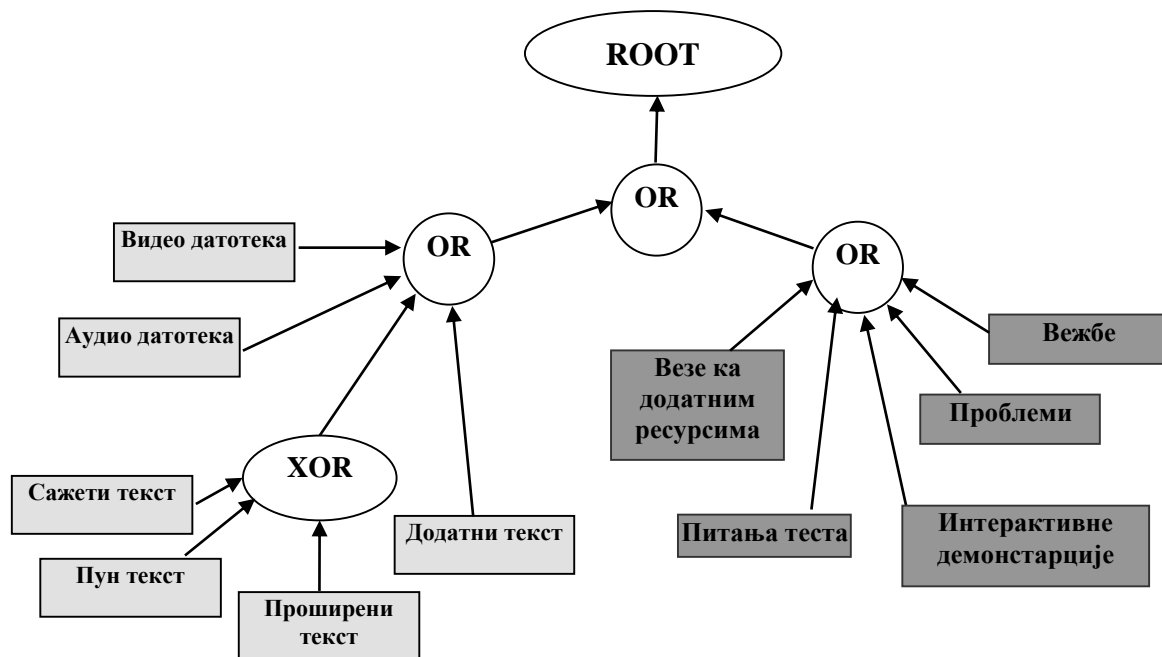
На првом нивоу генерисања образовног садржаја (одабир нове радне сесије) процењује се значајност сваке сесије образовног курса. Бира се она са највишим нивоом значајности. Евалуатор оставља одређену вредност значајности у GSEM-у, за сваки блок, сваке сесије. Средишњи „чворови“ (кораци) у GSEM стаблу, представљају функције релација са више аргумената и једном резултујућом вредношћу, коју враћа (слика 31). Да би се проценила потреба за асимилацијом дате сесије, резултати евалуатора, градијентски иду према врху стабла, пролазећи кроз релацијске чворове, све док не доспеју до рута (корена) GSEM стабла. На овом нивоу функције релације извршавају операцију додавања (сабирања) над својим улазним аргументима. Сума се враћа као резултат и користи се као почетни унос за следећу функцију релације. Вредност која је доспела до корена GSEM-а је тражена вредност за потребе учења у датој сесији.

Током друге фазе генерисања сесије (бирање њеног садржаја) подсистем за адаптацију је већ одредио сесију која треба да се додели ученику. Текући задатак и циљ је одређевање њеног садржаја. Овај проблем је редукован на специфичан подкуп тип-блокова који би требали да се укључе у текућу варијанту сесије. Опет, GSEM се користи у ову сврху. Важност сваког тип-блока се прорачунава помоћу евалуатора на GSEM грамама. Ове вредности долазе до рута стабла, пролазећи кроз функције релација. У овом

моменту, функције релација извршавају своју праву сврху. Постоје два типа релација: OR – тип и XOR – тип. Пролазећи кроз релацијски чвор типа OR, сви тип-блокови, који имају генерисану израчунату вредност већу или једнаку захтеваној вредности, се комбинују и пролазе даље. Ова доња вредност се чува у релацијском чвору. Приликом преласка кроз релациони чвор типа XOR, одређује се тип-блок са највећом генерисаном вредношћу и, ако је његова вредност значајности већа или једнака захтеваној вредности, тип-блок се пропушта кроз релациони чвор. Опет се гранична вредност чува у релационом чвору. На крају, добија се подскуп свих грана (тип-блокова сесије) које достижу GSEM рут. Овај подскуп представља све тип-блокове који би требали да буду укључени у актуелну варијанту сесије.

У трећој фази (генерисање садржаја сесије) се генератор функције користе за одређивање садржаја сваког блока из подскупа тип-блокова одговарајућих за дату сесију. Сваки генератор се извршава, а резултати се затим стапају (повезују) и представљају образовни материјал за дату сесију. Потом се она прослеђује ученику.

На слици 36 је пример шеме GSEM-а (Забунов & Гайдарова, 2010). Постоји неколико дефинисаних тип-блокова, а сви они су једног од два типа – активни или пасивни (активни су тамнији, а пасивни светлији).



Слика 36: Пример структуре GSEM датог образовног курса – један за све сесије

Слични, међусобно искључиви тип-блокови су комбиновани са XOR релационом функцијом, док су конкурентни тип-блокови здружени кроз OR релационе чворове.

Индивидуализовани адаптивни LMS пројекти дефинишу генерализовани модел адаптивног e-Learning система, који омогућава креирање специјализованог, а интелигентног електронског образовног окружења. IALMS обједињује интелигентни прорачун и модерне e-Learning стратегије да би се постигло уопштено, програмабилно и флексибилно образовно окружење.

4.2. Постојећа платформа – опште карактеристике и недостаци

LMS системи се уобичајено користе за електронско учење, али допуштају и омогућују веома низак ниво прилагодљивости потенцијалном кориснику. Најчешће, познати и највише коришћени системи уопште нису адаптивни. Кроз претходно излагање је довољно написано о предностима прилагодљивих курсева и о томе како адаптивност позитивно утиче на квалитет наставе и учења. Даље ће бити изложен начин омогућавања адаптивности у курсевима, који су креирани кроз неки од LMS система. Овакви курсеви комбинују предности LMSs и адаптивних система, увођењем појма побољшаног LMS, чија се адаптивност заснива на више нивоа – различитом нивоу знања, стилу учења и путем персонализоване повратне информације.

Платформа на којој се заснива постојећи систем за e-Learning је LMS отвореног кода, Moodle. Moodle је, поред Blackboard и WebCT, најчешће коришћена платформа за e-Learning. Његовој широкој употреби је допринело то што располаже бројним карактеристичним функцијама и опцијама, које омогућавају наставницима и другим ауторима курсева, релативно једноставно креирање online курсева. Међутим, тренутно Moodle не нуди опцију прилагођавања курса према учениковим потребама.

Постојећи систем је развијен у Moodle (слике 37 – 39), и намењен је студентима Педагошког факултета у Ужицу за савлађивање материје предвиђене планом и програмом наставног предмета Информатика. Предмет се слуша у оквиру основних академских студија и то током првог и другог семестра на смеру Учитељ и на смеру Васпитач. Садржај је за оба смера исти: основни рачунарски појмови (структура и начин функционисања рачунара), рад у Windows окружењу, софтверски алати у настави (MS Office – Word, PowerPoint, Excel, FrontPage), Интернет. Online курсом је предвиђено савлађивање дела градива који се односи на софтверске алате, па у суштини постоје четири независна курса: MS Word, MS PowerPoint, MS Excel, MS FrontPage.

Курсеви су осмишљени првенствено као комбинација два типа понуђених курсева у Moodle, тј. то су курсеви који би истовремено били уводни, прегледни курсеви, као и курсеви за развијање умећа и способности из обрађене области. На основу одабраног типа курса, као и на основу претходно поменутих и разматраних методичких аспеката, аутор је дошао до закључка да је за потребе курса најодговарајуће имплементирати следеће Moodle модуле:

- Resources – извори; објављивањем забележака и саопштења о свакој лекцији ће помоћи учесницима да остану ангажовани, тако што ће им на тај начин бити пружена структура за прављење сопствених бележака.
- Quizzes – квизови; квизови се користе како за проверу знања ученика, тако и за њихову самоевалуацију, а учествују у формирању оцене ученика.
- Forums – форуми; креирање форума је ефикасан и ефектан алат за колаборативно, активно учење, као и добар комуникациони медиј.
- Lessons – лекције; овај модул је креиран да би се путем њега ученицима омогућило ваљано увежбавање умећа и могућност вежбе, кроз разне типове лекција
- Exercise – вежбе; кроз низ задатих вежби омогућава се саморефлексија ученика, као и формирање коначне оцене сваког од ученика, а на основу успешности израде сваке од задатих вежби.

Посебан акценат је стављен на креирање самих наставно-дидактичких материјала који су коришћени у курсевима. Сви материјали, како теоријски (којима се излаже градиво које је предвиђено за обраду), тако и они предвиђени за утврђивање и обнављање градива (питања у квизовима, вежбе и задаци), су осмишљени и креирани тако да поштују основне методичке принципе (Арсовић & Стефановић, 2010; Арсовић, 2011).

Приликом креирања образовних материјала поштовао се принцип испуњавања аспеката развоја наставних материјала за електронско учење. Вишекратност направљених материјала је подржана у Moodle систему, који омогућава да се нпр. објављени текстови, лекције и др. могу користити у више наврата и то не само у актуелном курсу, него и у неком другом курсу истог (а и другог) образовног Moodle система.

Вишекратност образовног материјала је најочљивија код питања за постојеће квизове/тестове курсева. Наиме, формирана је база питања, из које се могу бирати, случајним или намерним избором, питања за друге тестове. Приликом развоја материјала предвиђених за ове курсеве, аутор се водио идејом да сви материјали буду додатно описани и објашњени, тако да би их неки други, будући корисници могли лако употребити за своје, нове курсеве. На тај начин се сем вишекратности материјала, постиже и задовољење аспекта семантичке интероперативности.

Колаборативна подршка приликом процеса развијања наставних материјала се огледа у начину њихове израде. Наиме сам аутор има вишегодишње методичко искуство (рад са студентима, више пута обрађивана поменута наставна област), на основу кога је по сопственој процени, укључивши и искуства и закључке других експерата, одабрао најпрактичније форме за наставне материјале, као и упечатљиве, одговарајуће примере, најдискриминантније задатке и др. Колаборативна подршка се управо огледа у прожимању тих искустава из класичне наставе, са неким новим могућностима репрезентовања материјала. Материјали су креирани тако што су у тај процес укључена дидактичко-методичка подршка (као централно питање и можда најбитнији момент целог процеса стварања материјала). Такође, водило се рачуна и о естетском моменту, па је коришћена дизајнерска препорука, али се пажња обраћала и на структуру самих материјала и начине њиховог уклапања у цео образовни софтвер, што представља програмерски моменат у њиховом креирању (Арсовић, 2011).

Употребљивост наставних материјала, као особина блиско повезана са *квалитетом*, се огледа у томе што су креирани материјали заиста лаки за употребу (постоје различити начини размене информација и материјала са студентима, као циљним аудиторijумом). Материјали имају доследан, повезан и разумљив дизајн, који омогућује корисницима да лако разумеју као треба радити са материјалом, па се на тај начин постиже лако учење из таквих материјала (Арсовић, 2011). Образовни материјали су креирани тако да пружају ефективну подршку корисничким циљевима и задацима.

Из изложеног се види, да су током процеса развијања, креирања и дизајнирања наставних (дидактичких) материјала за потребе курса, материјали разматрани као коњункција садржаја и процеса учења/подучавања, а на основама спецификација образовне технологије, зависне од колаборативног развоја и планирања. Само такав приступ наставним материјалима омогућава каснији ваљан и ефектан процес обуке и учења помоћу њих, а то је у принципу крајњи циљ и сврха свих образовних окружења.

Кроз добро планиране и креиране наставне материјале, различитих формата, студентима је дата слобода избора према личним склоностима. Тако за већину лекција постоје наставни материјали у облику текста, мултимедијалне презентације или додатног

ресурса за даље истраживање. Ипак, избор одговарајућих материјала је остављен студентима на савест, тако да не може бити речи о правој, суштинској адаптивности самог система, већ само о могућности већег избора.

Унапређење постојећег модела учења, развијеног у Moodle, мора ићи у правцу обезбеђивања адаптивности система за учење. Адаптивност ће се обављати аутоматизовано, независно од свесног избора студената, већ на основу њихових склоности препознатих током рада и/или на основу резултата упитника помоћу којих би се формирао профил корисника.

4.3. Унапређења и видови персонализације постојећег LMS

Адаптивност LMS се препознаје као веома битна карактеристика једног система за учење, али се и закључује да релативно мали број LMS система (доступних на тржишту) поседује могућност прилагођавања према кориснику. Е-Learning платформе, попут поменутог Moodle, омогућавају бројне, једноставне алате за креирање и касније управљање и администрацију образовног курса, што их чини широко употребљаваним платформама за креирање е-Learning курсева.

Имајући на уму сва ограничења постојеће е-Learning платформе, идеја је да се дизајнира мета-модел адаптивног курса, који се може једноставно интегрисати у дату е-Learning платформу, а са циљом да се повећа и постигне одређени ниво адаптивности.

Технике адаптације се, у суштини, могу заснивати на подршци адаптивне презентације садржаја и/или адаптивној навигацији кроз курс. Адаптивна презентација подразумева и заснива се на адаптивној мултимедијској презентацији и прилагодљивој презентацији текста, док се адаптивна навигација темељи на линковима и неким другим могућностима, као што су директно навођење или прилагодљиво сортирање приказаних линкова, као и истицање и скривање одређених линкова ка садржајима. Осим на поменуте начине, адаптивност образовног софтвера се може обезбедити на основу различитих карактеристика корисника (ученика/студената) – нпр. на основу претходно стеченог знања (предзнања), образовних циљева, когнитивних могућности и стила учења. Предложени модел се фокусира на адаптивност засновану на стилу учења и предзнању студента. Моделом се комбинују предности LMS и адаптивног система, увођењем концепта унапређеног LMS система. Суштина је да се користи LMS Moodle као прототип, а да се развијају додаци (adds-on) који Moodle систему омогућују обезбеђивање адаптивног курса, прилагођеног како стилу учења, тако и предзнању студента. Посебно ће се размотрити поменути додаци.

Основни концепт овог мета-модела јесте креирање обиља индивидуалних LO (образовних објеката), који се потом комбинују да би формирали посебан курс прилагођен особеностима сваког студента (Arsovic & Stefanovic, 2020).

Додатак за адаптацију према стилу учења

Развијени Moodle додатак, којим се обезбеђује адаптивност на основу стила учења и начин његове имплементације у архитектуру LMS система је приказан на слици 37.

Као први додатак укључени су мета-подаци ради распознавања захтеваних и потребних елемената курса. У Moodle систему, модул квиза се може користити за презентовање вежби и тестова провере, а модул ресурса за презентовање садржаја, закључака и

примера. Као проширење, додато је поље у интерфејс ауторизације за креирање квизова и ресурса, а због разликовања елемената курса. Ови мета-подаци се затим предају експертном моделу. Други додатак се бави одређивањем и похрањивањем стила учења студента. За одређивање стила учења користи се ILS (Index of Learning Styles), упитник за одређивање стила учења, који су развили Felder & Silverman. Поменути упитник се додаје Moodle форми за регистрацију корисника. На тај начин се, на основу одговора студената, омогућава одређивање преференси стила учења, које се затим складиште у модел студента. Према коришћеном моделу стила учења, разликујемо 3 групе (кластера) студената, чије карактеристике у стилу учења представљају одређене комбинације стилова предвиђених Felder – Silverman моделом. Трећа екстензија омогућава аутоматски одговор система, у виду прослеђивања образовног курса, који одговара студентовом стилу учења. Стога је развијен адаптациони модул, који је одговоран за приступ информацијама о студентовом стилу учења кроз модел студента и који израчунава вредности сваке адаптационе одлике засноване на преференцама студентовог стила учења. Вредности адаптационих одлика указују на то како ће индивидуални курс бити сачињен. Затим се, путем експертног модела, приступа одговарајућим елементима курса, који се презентују студенту путем LMS интерфејса.

Да би се платформи омогућило да се прилагоди потребама студената, презентација курса мора бити врло флексибилна. Отуда се представљени мета-модел мора састојати од различитих компоненти, које се могу индивидуално комбиновати и укључивати у курс. У даљем тексту ће бити описане компоненте курса.

Сваки курс у систему треба да укључује кратак преглед на почетку, где су представљена сва поглавља (све теме, образовне јединице), као и закључак који сумира најбитније закључке из курса. Слично таквој организацији, свако поглавље (тема) треба да има кратак преглед и закључак. Да би се за студенте са препознатим глобалним стилем учења обезбедила боља оријентација, кратки прегледи могу бити дати допунски, после сваке теме или образовне јединице, док се за секвенцијалне типове могу у потпуности сакрити.

Објекти са образовним садржајем, уствари представљају садржај курса подељен у ситне делове. Они могу укључивати текст, као и разне врсте слика, чиме се задовољавају потребе вербалних, али и визуелних ученика. Додатно, објекти могу садржати и линкове ка другим садржајима, нпр. ка додатним информацијама о обрађиваном појму или везано за текућу тему. Обезбеђивањем ових линкова, глобални ученици имају прилику да обрађиване материјале повежу са другим темама и тако добију додатне информације. За секвенцијалне ученике, линкови могу бити сакривени, чиме курс постаје више линеаран. Али и тада, скуп линкова може бити приказан на крају теме (поглавља), на пример. Осим тога, у садржај курса се могу укључити и мултимедијални објекти (нпр. аудио клип са предавањем експерта, професора, о датој теми). Дакле, мултимедијски објекти су добра замена текстуалном садржају и подржавају визуелне, активне и сензорне ученике. Исто тако, мултимедијални објекти се могу сакрити, а у циљу избегавања проптерећења опажања или ради обезбеђивања линеарности курса. Скуп мултимедијалних објеката је могуће направити и од слајдова који се користе у традиционалној настави (уз дораду, могу се користити као такви објекти).

Пример курса, такође, садржи примере, који се користе ради боље илустрације. Сваки пример се односи на један или више карактеристичних садржаја. Примери су посебно важни за сензорске ученике. Осим тога, курсеви адаптирани према потребама сензорских ученика могу садржати више примера него курсеви за интуитивне ученике.

Курс садржи и објекте вежбе, да би се студентима пружила прилика да практично увежбају своје знање. Како активни ученици преферирају да ствари уче пробањем, то курс намењен њима може садржати више објеката вежбе од курса намењеног рефлексивним ученицима.

У сврху провере стеченог знања, курс садржи тестове. Резултати тестова су накнадно доступни ученицима. Питања садржана у тесту се могу односити на чињенице и појмове, могу захтевати познавање опште структуре или појединих детаља, заснована на тексту или слици, или се бавити интерпретирањем и/или развијањем конкретног решења задатог проблема. Свако питање је повезано са образовним објектом, па тако ученик може лако да буде упућен на додатно објашњење уколико му је потребно. Тестови, као и вежбе, могу бити прилагођени, на пример по броју питања и по месту у курсу. Како је напредовање секвенцијалних ученика линеарно, онда они више воле тестирања у краћим интервалима, него глобални ученици, којима је потребно више времена да увиде ширу слику и суштину ствари. За њих је најпрактичнији и најподобнији тест на крају теме.

Важна ставка јесте и комуникација, поготово за активне и вербалне ученике, када им се, добро осмишљеним системом комуникације, пружа могућност заједничког рада, дискутовања и тражења помоћи и додатних објашњења. Да би се обезбедила међусобна комуникација, као и комуникација студената са предавачима, у курс су интегрисани и форуми и chat. На пример, курс може имати одређени форум и/или причаоницу, уско везан за одређену тему из образовног садржаја курса. Путем једног таквог форума студенти могу дискутовати о специфичним темама курса, а кроз уопштене форуме о уобичајеним проблемима учења и сл. Додатне, виртуалне консултације, пружају могућност студентима да питају предавача све што им је нејасно, а путем причаоница (у унапред дефинисаном термину).

Додатак за адаптацију према предзнању

Додаци развијени за прилагођавање курса према претходно стеченом знању студента су приказани на слици 37.

Принцип имплементације у постојећи систем по много чему одговара претходно изложеној техници уграђивања *adds-on* за адаптацију према стилу учења. Како је то већ описано у делу *Адаптивни e-Learning LMS систем за студенте различитих нивоа знања*, битно је установити којој категорији припада корисник, а према предзнању из обрађиване проблематике. Овако адаптивна структура курса разликује различите категорије студента: почетнике, просечне и надарене. Током пријављивања и регистрације на курс, студенту попуњава упитник (пред-тест). Модел ученика прати ученикове перформансе. На основу способности и знања испољених у овом пред-тесту, студенти се категоризују као почетници, просечни или напредни. Мета-подаци који служе за распознавање нивоа студента се чувају у моделу студента. Адаптациони модул приступа овим подацима, на основу којих се одлучује којим ће образовним објектима студент имати приступ кроз похађани курс. У ту сврху се приликом креирања образовних објеката, њихов садржај означава различитим нивоима (1 ниво – почетни, 2 ниво – просечни, 3 ниво – напредни). Према одређеном нивоу предзнања, доступни су одређени нивои образовних материјала. Категоризација и нивоа знања и нивоа образовних материјала је објашњена у делу 3.7.

Да би се обезбедила адаптивност курса, потребно је креирати одговарајуће образовне материјале, који ће одговарати различитим нивоима знања студената. Образовни материјал је организован као скуп поглавља. Свако поглавље је класификовано у соп-

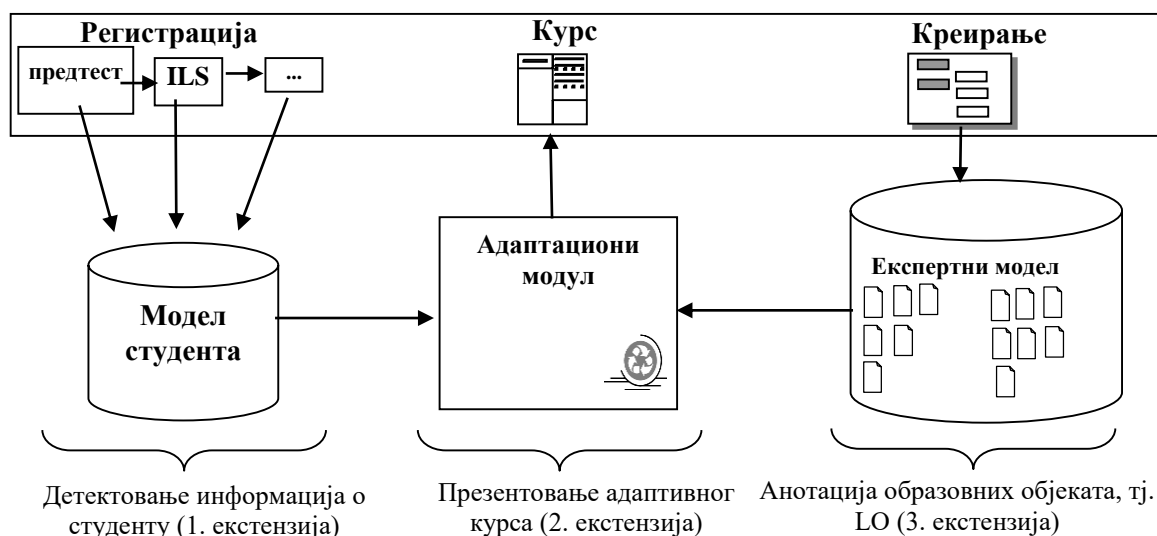
ствени скуп подпоглавља, а опет свако подпоглавље је даље подељено у скуп подпоглавља. Међу поглављима и подпоглављима постоје релације које их међусобно повезују, а сваком нивоу образовног садржаја је додељена одређена тежина (варира од 0 до 1). Тежина материјала који се додељује студенту одговара његовом фактору (фактор такође варира од 0 до 1, у зависности од нивоа предзнања). На тај начин се студенту презентује само одговарајући садржај, дизајниран за тај ниво знања.

4.4. Решење персонализације постојеће LMS платформе

Коначно решење за унапређивање постојеће LMS платформе обједињује претходно описана решења за постизање адаптивности е-Learning система. Другим речима, курс се прилагођава и по нивоу предзнања студента, али и у зависности од његовог стила учења.

Фундаментални концепт предложеног мета-модела лежи у креирању обиља индивидуалних образовних објеката (LO). Приликом креирања образовних материјала, потребно им је доделити метаподатке који ће упућивати на њихов ниво сложености. Образовни објекти у којима се наводе само уводни подаци о обрађиваној теми, а који не улазе у објашњавање исте, се додељују првом нивоу, тј. намењени су за презентовање студентима почетницима. Образовни материјали у којима се обрађивана тема потпуније обрађује и разматра, припадају другом нивоу предзнања и презентују се просечним студентима. Материјали највишег, трећег нивоа, садрже елементе којима се напреднији студент упућује на самостално истраживање и даље учење, кроз повезивање изложене материје са другим, познатим и/или потпуно новим појмовима. Осим додељених параметара који указују коме нивоу припада одређени образовни објекат, уводе се додатни метаподаци који упућују на одговарајући стил учења.

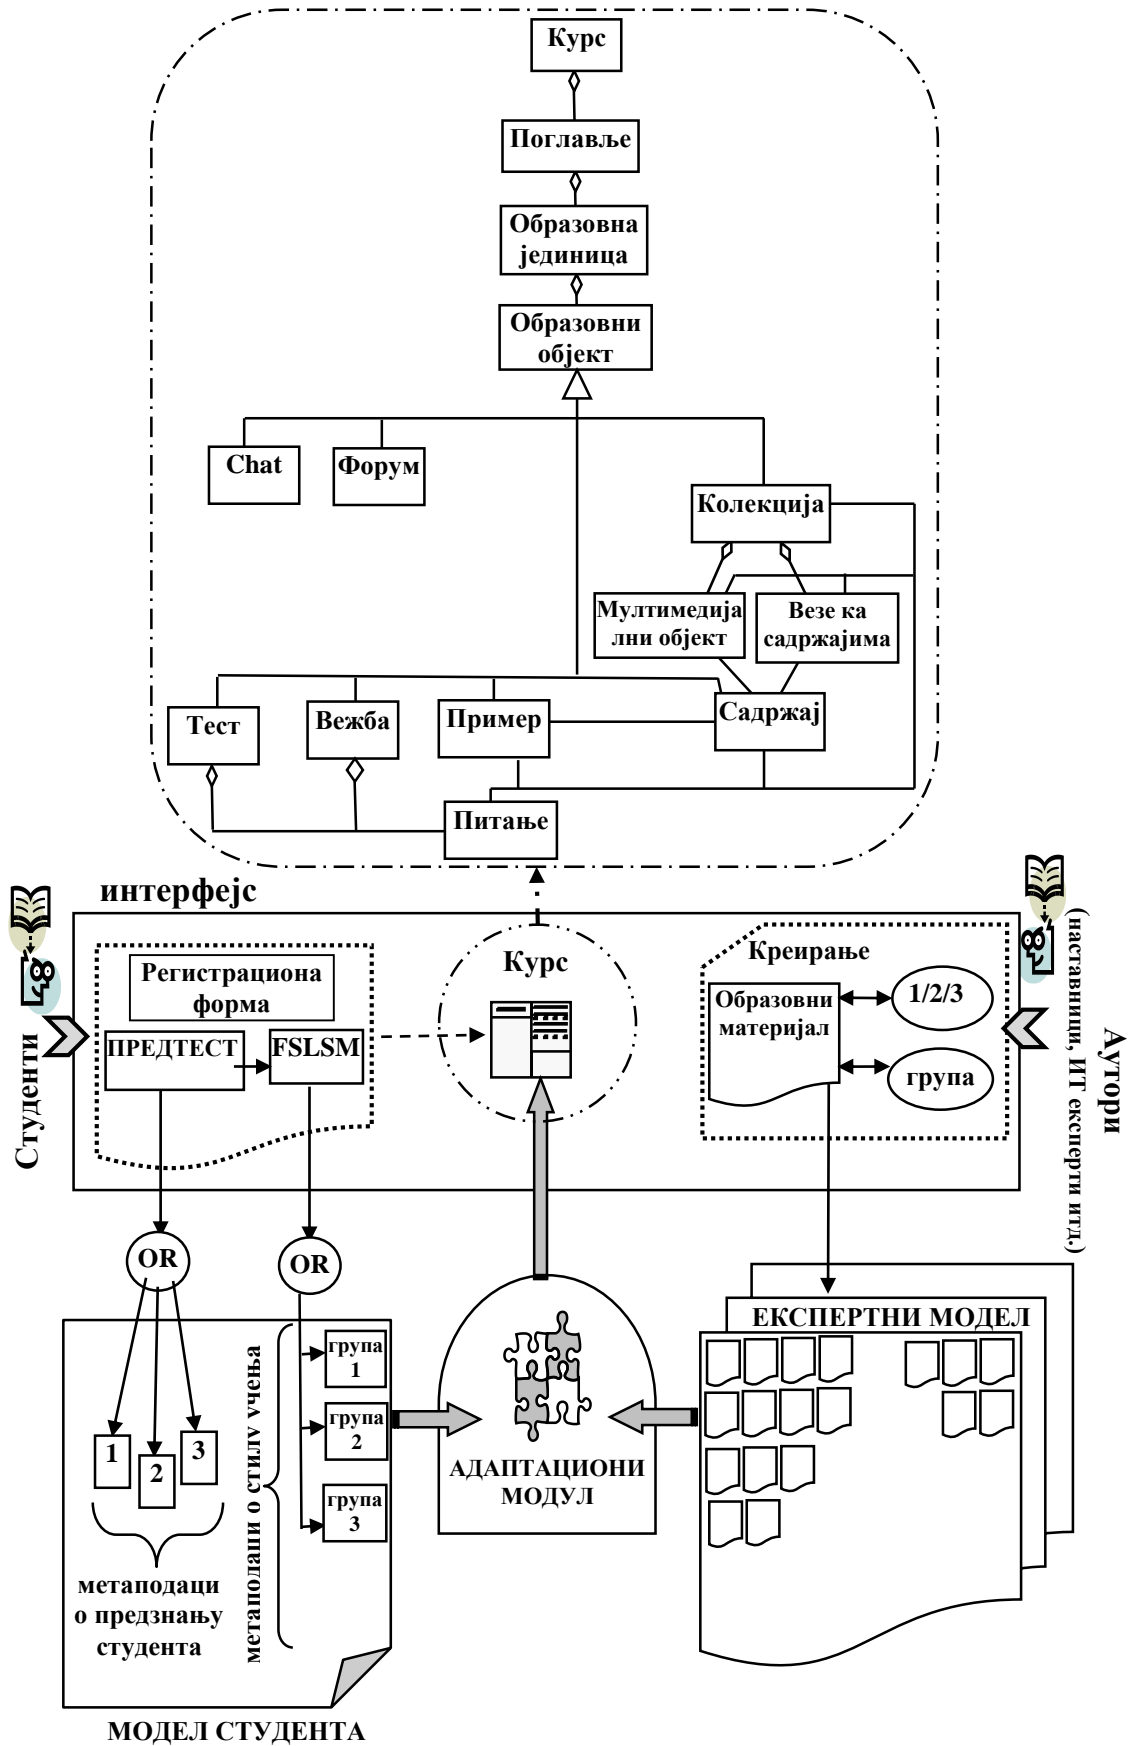
Другим речима сваки образовни објекат садржи и податке о томе коме стилу учења тај објекат највише одговара. Тако креиран образовни објекат, дакле, садржи параметре о свом нивоу сложености и одговарајућем стилу учења који подржава. Све ово упућује на то да је потребно креирати довољно индивидуалних, образовних објеката, чиме се обезбеђује могућност одабира одговарајућих објеката, што у зависности од нивоа предзнања, што у зависности од преферираног стила учења студента.



Слика 37: Проширења архитектуре постојећег LMS (Арсовић & Стефановић, 2010)

Сама имплементација је аналогна претходно описаним случајевима предложених решења (слика 37). Наиме, студент приликом регистравања на курс попуњава прво пред-тест, којим се одређује ниво његовог предзнања. На основу способности и знања испољених у овом пред-тесту, студенти се категоризују као почетници, просечни или напредни. Мета-подаци који служе за распознавање нивоа предзнања студента се складиште у модел студента. Потом студент попуњава упитник, којим се одређује преферирани стил учења. На тај начин се, на основу одговора студента, омогућава одређивање особина стила учења, које се затим складиште у модел студента. Дакле, већ кроз регистрациону форму курса се добијају метаподаци о категорији студента и његовом стилу учења.

Аутоматски одговор система, у виду прослеђивања образовног курса, који одговара категорији предзнања и студентовом стилу учења омогућава адаптациони модул, који је одговоран за приступ информацијама о студентовом стилу учења и категорији, кроз модел студента. Адаптациони модул израчунава вредности сваке адаптационе одлике засноване на преференцама студентовог стила учења. Вредности адаптационих одлика указују на то како ће индивидуални курс бити сачињен. Осим преференци стила учења, адаптациони модул чита метаподатке о категорији студента. Затим се, путем експертног модела, приступа одговарајућим елементима курса, који се презентују студенту путем LMS интерфејса. Образовни елементи, који се бирају у персонализовани курс, морају бити одговарајући како по стилу учења, тако и по нивоу предзнања којем студент припада. Предложени модел адаптивног курса је дат на слици 38 (Арсовић & Стефановић, 2010; Arsovic & Stefanovic, 2020).



Слика 38: Предложени модел адаптивног курса

4.5. Имплементација и тестирање персонализованог адаптивног LMS

На основу претходно разматраног, може се закључити да примена концепата адаптивног е-Learning може значајно допринети побољшању квалитета образовно/наставног процеса на различите начине.

Основни циљ овог рада и истраживања је испитивање могућности адаптације Web оријентисаних образовних курсева, као и њихово презентовање кроз интегрисани LMS Moodle. Један, овако развијен адаптивни LMS курс, треба да задовољи потребе различитих група студената. Тако се, на основу различитих захтева и потреба студената, издваја још један циљ истраживања, а то је разврставање студената у различите групе (кластере) према њиховим карактеристикама (стилу учења и нивоу предзнања). Затим се образовни процес прилагођава свакој од препознатих група (кластера).

Анализа података о студентима и њиховим карактеристикама

Постављена су нека питања, која могу помоћи даљој анализи:

- Који број група је највише одговарајући?
- Које су основне карактеристике сваке од група?
- Које су разлике између дефинисаних група?
- Какви образовни садржаји треба да буду представљени у платформи?
- Који су начини комуникације одговарајући?


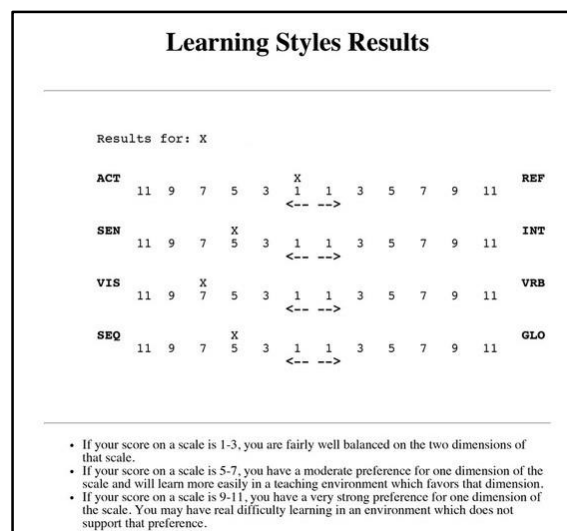
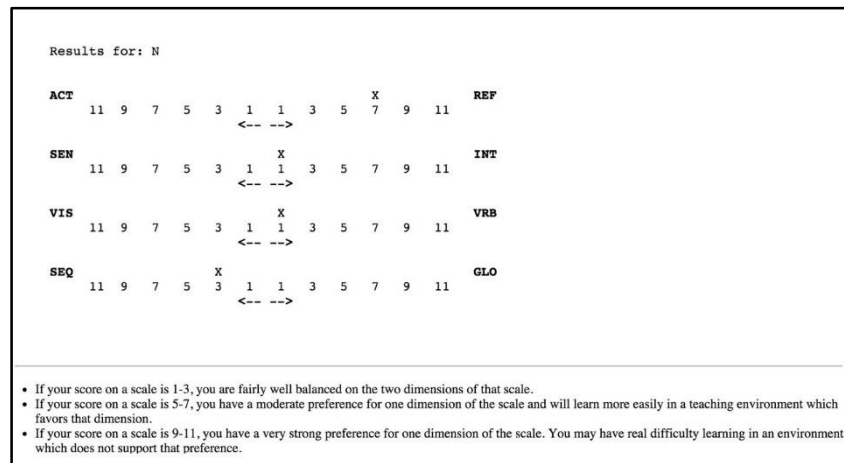
Подаци су прикупљени на узорку студената прве године групе Учитељ и прве године групе Васпитач, основних академских студија на Педафгошком факултету у Ужицу, Универзитета у Крагујевцу. Део података је прикупљен анкетирањем студената пре почетка курса, а део обрађених података је добијен по завршетку е-Learning курса. Цео поступак истраживања подељен је у следеће сегменте:

- прикупљање података (анкета, анкетни упитник)
- класификација студената у одговарајуће групе/кластере
- креирање адаптивног курса
- евалуација курса и анализа података.

У почетној фази истраживања, кључни део се односио на прикупљање података анкетирањем студената. У циљу креирања персонализованог курса за е-Learning, потребно је испитати и на различите начине анализирати податке о студентима, и предвидети будућа понашања студената. Први корак у анализи карактеристика студената је анкетирање којим се утврђује ниво предзнања студената, као и њихових преференци током учења.

Као што је у претходним деловима рада објашњено, постоји више модела стилова учења, али коришћен је Felder-Sliverman Learning Style Model (FSLSM), као најпогоднији за анализу стилова учења у е-Learning окружењу. Овај модел описује сваког студента у складу са четири димензије: активни/рефлексивни стил учења; сензорно/интуитивни стил учења; визуелно/вербални стил учења; секвенцијално/глобални стил учења. О овим димензијама стилова учења је било више речи у делу *Felder-Sliverman Learning Style Model*.

Анкета којом се одређује стил учења покрива области мотивације за учење, начине презентације образовних садржаја, организовање времена предвиђеног за учење и могућности тимског рада. Пошто је планирано персонализовање постојеће LMS Moodle платформе, размотрене су погодности појединих Moodle активности за персонализацију и прилагођавање, према одређеном стилу учења дефинисаном FLSM моделом. Погодност коришћења појединих активности Moodle система у случају одређених стилова учења је дата у табели 10 (Mudrák, 2017; Mudrák, Turcani & Burianová, 2018; Jingga & Sunindy, 2020).



Слика 39: Вектори стила учења – FLSM модел

Табела 10: Однос стилова учења и Moodle активности (Karagiannis & Satratzemi, 2020)

стил учења / активно сти	Активни	Рефлексивни	Визуелни	Вербални	Сквенцијални	Глобални	Сензитивни	Интуитивни
Форум	Конкретни проблеми	Теме за размишљање	Не	Да	Да	Уопштене, глобалне теме	Чињенице, примери	Апстрактне теме
Chat	Да	Не	Не	Да	Често	Не	Да	Не
Речник	Више термина	Концепти	Не	Да	Да	Не	Да	Не
Радионица	Експеримент	Неситражене теме	Да	Да	Да	Да	Практични примери	Неистражене теме
Истраживање	Не	Да	Да	Да	Не	Да	Да	Да
Избор	Да	Да	Да	Да	Да	Ретко	Да	Не
Лекција	Проблеми, примери	Задате теме за размишљање	Илустрације	Писани и мултимедијални материјали	Да	Ретко	Чињенице, алгоритми	Ретко
Комуникација	Лицем-у-лице	E-mail	Комбиновано	Комбиновано	Комбин.	Комбин.	Лицем-у-лице	Комбин.
Студија случаја	Да	Да	Илустрације	Писани и аудио материјали	Да	Не	Да	Иновативне теме

Међу студентима је извршено испитивање о постојећем предзнању. Већ је напоменуто да је узорак над којим је вршено истраживање састављен од студената друге и прве године, а они слушају предмет *Информатика*. У оквиру овог студијског курса предвиђено је да студенти стекну основна теоријска знања о информационим технологијама (основна архитектура рачунара, рачунарске мреже, софтверски пакет MS Office). Постојећа LMS Moodle платформа има четири специјализована курса за учење рада у софтверским алатима: MS Word, MS PowerPoint, MS Excel и MS Front Page. Већина поменутих алата се обрађује током претходног школовања (основно и средње образовање), али због лоших материјалних услова у којима се доста школа у Србији налази (непостојање добро опремљених кабинета за информатику), као и због честе незаинтересованости ученика, ниво предзнања са којима студенти приступају овом курсу *Информатике* се драстично разликују. Управо је то још један параметар који се мора узети у разматрање (осим поменутог стила учења) приликом персонализације система за учење.

У ту сврху је спроведена је анкета, за одређивање нивоа предзнања студената, а питања су се односила на познавање рада у поменутих софтверским алатима. Анкета је, осим питања везана за рад у софтверским алатима, садржала и питања о претходном општем успеху студената током студирања. На основу анкете је утврђено да се студенти могу груписати у једну од три групе по показаном предзнању: студент почетник, студент просечног нивоа знања и напредног нивоа знања. Такође се дошло до резултата о просечној оцени досадашњег студирања. Уочава се да највећи број студената остварује просечне резултате – укупно 80% студената има просечну оцену између 7 и 9, док мањи број студената постиже лошије резултате (15%, просечна оцена испод 7), а такође је мали и број студената који постижу надпросечне резултате (5%, просечна оцена преко 9). У суштини, без обзира на које се предзнање и успех усредсредили, разликују се три поменута нивоа и, самим тим, три поменуте групе студената.

Према резултатима анкете се испоставило да већина студената припада групи почетника, чак њих 56%. Просечни ниво знања у раду са софтверским алатима MS Office показало је 40% анкетираних популације. И коначно у групу напреднијих полазника спада само 4% студената (структура анкетираних студенатске популације на основу показаног предзнања је дата доњим графиком).



Слика 40: Структура анкетираних популације према нивоу предзнања

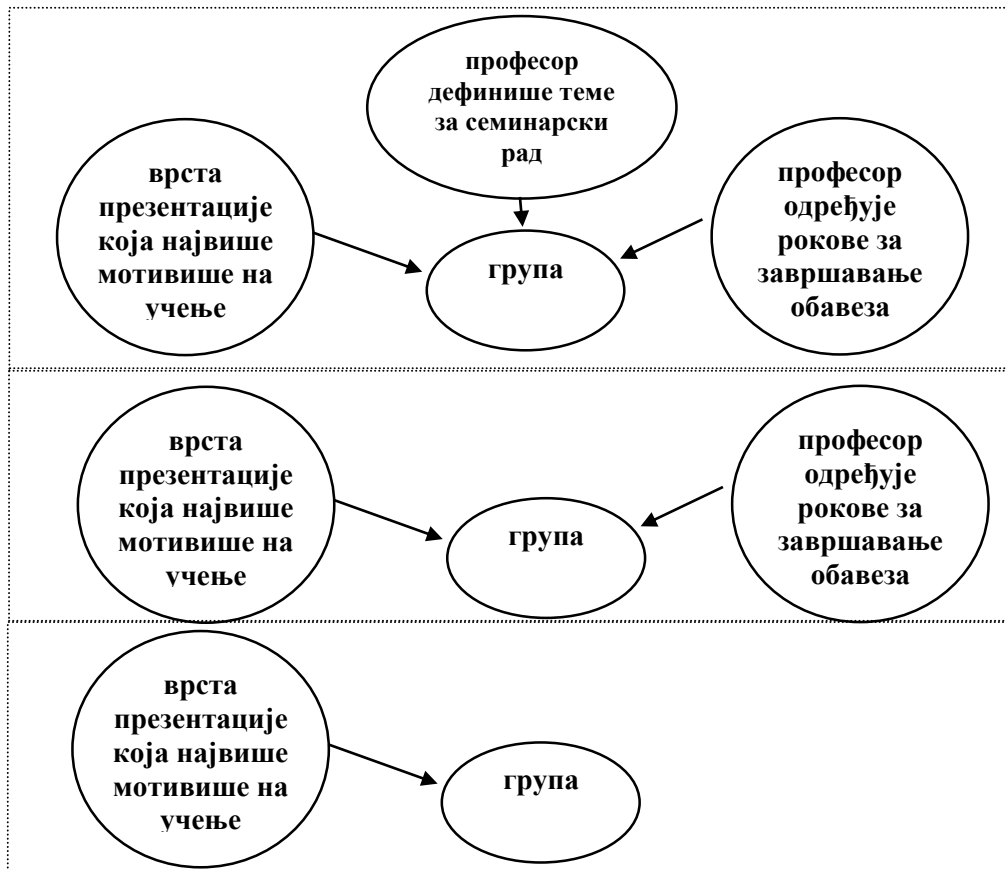
Осим одређивања ниво претходног знања, потребно је одредити навике и склоности студената у процесу учења. Студентима је у анкети дат прилагођени FSLSM упитник, у циљу одређивања преферираног стила учења сваког од њих. За изградњу модела је коришћен clustering алгоритам, који се користи за природно груписање података на основу њихових атрибута, тако да вредност атрибута унутар једног кластера буду сличне, а између кластера значајно различите. Овде не постоје предефинисане групе у које се подаци сврставају, већ се подаци уређују на основу не тако јасно уочљивих правила. Слични резултати се добијају у случају поделе студената у две или у три групе. Међутим, резултати су логичнији, бољег квалитета и конзистентнији у случају три кластера, а и степен имплементираних адаптивности ће бити већи ако се дефинишу три категорије студената. Дакле, обрадом података анкете дошло се до сврставања студената у три групе на основу преферираног стила учења студената.

Свака од група обухвата више стилова учења дефинисаних FSLSM моделом, али су им односи према начину представљања образовних садржаја исти у оквиру једне групе (што је можда најзначајније за класификацију студената). Такође је битан и однос студента према временском ограничењу у учењу, као и према томе ко дефинише теме радова. Карактеристике сваке од дефинисане групе су дате доњом табелом (табела 11).

Табела 11: Карактеристике група према стилу учења

Група 1	Група 2	Група 3
Кроз обавезе се пролази секвенцијално и линеарно	Студенти бирају теме за своје радове (семинарске и сл.)	Кроз обавезе се пролази секвенцијално и линеарно
Много специјализованих тема за дискусију	Кроз обавезе се пролази секвенцијално и линеарно	Писани материјали
Мултимедијски образовни материјали	Практични рад	Тачно одређени временски рокови за завршавање обавеза
Групни/тимски рад	Без стриктних временских ограничења за завршавање обавеза	Групни/тимски рад

За групе и дефинисање стилова учења битни су следећи фактори: тип презентације образовних материјала, дефинисани (или не) рокови за завршавање обавеза, ко дефинише теме за семинарске радове (домаће задатаке, есеје и сл.). Мрежа зависности и односа ових фактора и дефинисаних група је дата на слици 41.



Слика 41: Мрежа односа

За сваку групу је идентификован стил учења на основу уочене карактеристике групе (Bursać & Milošević, 2018). Тако свака од група подразумева одређену комбинацију димензија стилова учења према FLSM моделу. Идентификовани стилови учења за појединачне групе су дати табелом 12.

Табела 12: Идентификовани стилови учења за групе студената

Група	Карактеристике	Стилови учења
1	Мултимедијални материјали	<i>Визуелни</i>
	Кроз обавезе се пролази секвенцијално. Парцијално извршавање обавеза	<i>Секвенцијални</i>
	Групни рад	<i>Активни</i>
2	Студенти бирају теме	<i>Интуитивни</i>
	Практични рад	<i>Активни</i>
	Нема тачно дефинисаних временских рокова	<i>Глобални</i>
3	Писани материјали	<i>Вербални</i>
	Кроз обавезе се пролази секвенцијално. Парцијално извршавање обавеза	<i>Секвенцијални</i>
	Групни рад	<i>Активни</i>

Анализом одговора спроведене анкете, дошло се до три могуће групе студената на основу њихових карактеристика и склоности по питању стила учења. У суштини разликујемо следеће групе студената, који показују следеће особине:

- група 1 – најзначајније навике које одређују стил учења студената у овој категорији су: полагање испита из делова (с тим да студенти сами одлучују када ће полагати поједине делове); професор у оквиру предмета упознаје студенте са већим бројем тема, а не само са једном глобалном темом; врста наставних садржаја који најбоље подстичу учење су мултимедијални материјали; семинарске радове је боље радити у групама него појединачно, а најбољи начин комуникације са професором је “лицем у лице”.
- група 2 – студенти ове групе више воле да им професор зада тему за семинарски рад, него да је сами изабере; полагање испита се обавља из делова уместо одједном; студент више воли практичан рад уместо теоријског; образовни материјали су комбиновани (и мултимедијални и писани); нема задатих рокова за завршетак испитних обавеза, већ студент сам одређује динамику полагања као и предавања одређених радова; уместо теоријског семинарског рада студенти могу радити практичне пројекте.
- група 3 – студент ове групе преферира полагање испита из делова; врста наставних материјала који најбоље подстичу учење су писани материјали (уз аудио записе као додатне изворе); професор одређује рокове за завршетак обавеза; семинарске радове је боље радити у групама него појединачно; студент више воли практичан рад уместо теоријског (уместо теоријског семинарског рада студенти могу радити практичне пројекте); комуникација са професором се одвија путем e-maila, као и “лицем у лице”.



Слика 42: Структура анкетиране популације према стилу учења (припадној групи/кластеру)

Имплементација и детаљи предложеног решења

По предложеном решењу адаптација постојеће LMS платформе се врши према стилу учења, тако што се на основу припадних карактеристика студент сврстава у једну од три дефинисане групе. Систем и предлог решења могуће адаптације према стилу учења је изложен у делу *Додатак за адаптацију према стилу учења*. Већ је изложено да је битна ставка у персонализовању учења и ниво предзнања студената из обрађиване области. Дакле, адаптација LMS платформе се мора извршити и према показаном нивоу предзнања. Систем могуће адаптације је већ изнет у поглављу *Додатак за адаптацију према предзнању*. За сваку од поменутих група различитог нивоа предзнања (1 – почетник, 2 – просечног знања, 3 – напредног знања) се креирају различити образовни материјали, који предвиђено градиво и задатке презентују на посебном нивоу сложености градива. У суштини, у оквиру сваке од три групе (по стилу учења) извршена је нова класификација студената према нивоу предзнања.

Заједничке преференце већине студената (рад у тиму, парцијално полагање испита и сл.) су имплементирани глобално, на нивоу курса, док су карактеристике сваког кластера имплементирани појединачно, на нивоу припадне групе, а у сваком кластеру је дат припадни образовни материјал на три нивоа сложености, према одређеном припадном нивоу знања студента. Фундаментални концепт представљеног мета-модела је креирање обиља индивидуалних образовних објеката, прилагођених потребама одређеног нивоа знања и стила учења. Овакви образовни објекти се затим удружују и формирају прилагођени курс према карактеристикама студента. Однос између врсте образовних материјала и групе студената, дефинисане према стилу учења, дат је у следећој табели. Јасно се види који ће тип презентовања и уопште врста образовног материјала, бити заступљена у одређеној групи. Треба напоменути да се, при том, сваки образовни материјал развија у три нивоа сложености (почетни, просечни и напредни).

Табела 13: Однос активности на курсу и начина комуникацији у односу на припадну групу студента по стилу учења

органи зација курса група	Тип презентац ије образовног материјал а	Активности на курсу					
		Начин провере стеченог знања - оцењивање			Крајњи временск и рок	Активно сти	Начин комуник ације са предавач ем
		Избор теме врши...	Тип префери ране активнос ти	Финални испит/пров ера знања			
Група 1 (BCA)	мултимедиј ални материјали	предавач	пројекат/ истражив ање/студи ја случаја	тест са мултимедиј алним питањима	строго дефинисан од стране наставника	видео лекције, радиониц е	лицем-у- лице, видео конферен ција
Група 2 (IAA)	комбинова но	сам студент	сви типови	не постоји	није дефинисан	лекције, речник, wiki	форум, chat, лицем-у- лице
Група 3 (BAC)	текстуални материјали	предавач	есејског типа	усмено	строго дефинисан од стране наставника	текстуалн е лекције	форум, chat, лицем-у- лице

Прилагођавањем курса по два основа, тј. две димензије процеса учења, постиже се већи ниво адаптивности образовног курса, а самим тим је процес учења прилагођенији потребама студената, што би требало да проузрокује бољом усвојеношћу изложеног градива и вишим нивоом стеченог знања.

Модел студента

Изградња модела студента и праћење когнитивног процеса студента су важни аспекти имплементације персонализације у систему е-учења. Већ је у више наврата наглашено да модел студента представља основу за персонализацију процеса учења.

Модел студента представља скуп информација и података о појединачном студенту, важних за процес адаптације процеса учења. Систем користи податке из овог модела да предвиди понашање студента и на основу тога прилагоди доделу образовних материјала. Комплексност модела студента је пропорционална броју функција коју систем пружа студенту и потребама за адаптацију образовних садржаја. Дакле, модел студента је кључна компонента у адаптивним и интелигентним системима учења. Моделовање студента се дефинише као процес прикупљања и представљања релевантних информација о студенту, у циљу дефинисања и предикције студентовог понашања у персонализованој интеракцији са системом за учење.

Поред резултата тестова, систем прикупља и велику количину података током сесија студента са системом. Ови подаци могу бити врло непрецизни, двосмислени, па чак и контрадикторни. Да би модел апроксимирао реално стање студента у посматраном контексту учења, неопходно је да се обави резонување над тим подацима. Фактички, модел студента се састоји од два дела. Један део се користи искључиво ради провере идентитета студента, пошто чува основне податке студента (име, презиме, студијски смер, корисничко име/шифру), тј. идентификационе податке. Други део модела студента је дизајниран за потребе процесирања учења, са циљем да се укључе сви подаци, а који се односе на конкретног студента (стил учења, показано предзнање).

Информације о студенту се добијају коришћењем технике анкетања студентске популације. Генерисање студентовог профила започиње тако што студенти попуне упитнике/тестове и дају своје основне податке и то:

- своје идентификационе податке (приликом првог логовања на курс),
- тест за одређивање нивоа предзнања из области која се изучава на курсу,
- тест за одређивања студентовог стила учења.

Генерисање корисничког профила врши се обрадом сакупљених података и извођењем студентових психолшких карактеристика методама закључивања, на основу дефинисаних правила или на основу препорука наставника. Према датим упитницима и праћењем студентових активности, могу се закључити и извући подаци о индивидуалном студенту (нпр. стил учења, когнитивни стил, последња савладана лекција, тренутни ресурс итд.) који најбоље описују одређеног студента.

Профил студента посматра се као скуп следећих података:

- информациони подаци – генералне карактеристике студената, тј. лични подаци унети при првом приступању систему (PersonalInfo)

- подаци о профилу – подаци о стилу учења, когнитивном стилу, стратегији учења и циљу учења (LearningStyle)
- историја података – подаци о процесу учења и постигнутом успеху, пријављени и одрађени тестови, статистика о похађању наставе, одрађеним вежбама и задацима и сл. (Performance).

Табела 14: Атрибути модела студента

<i>Student</i>	
id [type:int]	идентификациони број студента
<i>PersonalInfo</i>	
student[type:int]	идентификациони број студента
name[type:string]	име студента
lastname[type:string]	презиме студента
email[type:string]	email адреса студента
department[type:string]	студијски смер
<i>Performance</i>	
student[type:int]	идентификациони број студента
course[type:int]	тренутни курс
previousknowledge[type:string]	претходно знање / предзнање
lesson[type:int]	последња савладана лекција
curlesson[type:int]	тренутна лекција
resurs[type:int]	тренутни ресурс
<i>LearningStyle</i>	
student[type:int]	идентификациони број студента

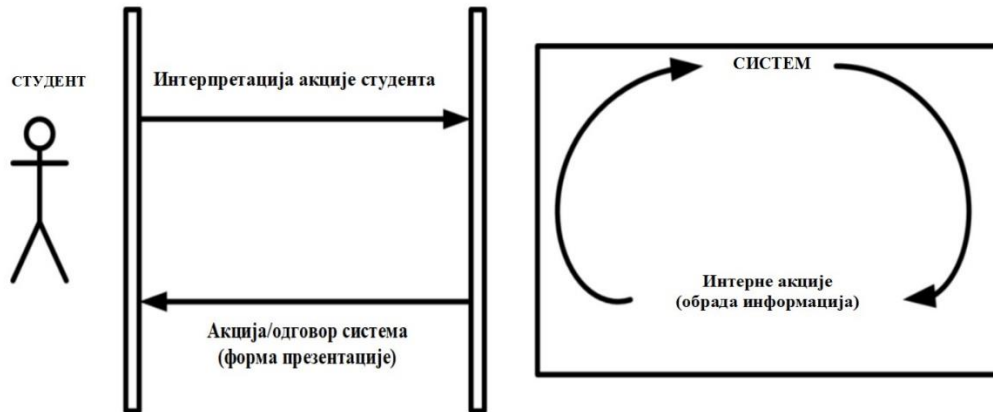
Модел студента врши генерисање и модификовање студентовог профила у неколико корака:

- прикупља податке о студенту и формира базу података студентовог информационог профила,
- обрађује сакупљене податке, изводи студентове психолошке карактеристике методама закључивања на основу дефинисаних правила и генерише базу података студентовог психолошког профила,
- прати студентов процес учења и постигнуте резултате и формира базу података студентових претходних активности.



Слика 43: Моделовање корисника / студента – UML дијаграм

Модел студента има значајну улогу у оквиру адаптивног система. Према (Biswas & Springett, 2018), постоје три главна начина на која кориснички модел доприноси прилагодљивости и персонализацији система за е-учење. Они су приказани на доњој слици и означени су стрелицама, које представљају ограничену интеракцију између корисника и система.



Слика 44: Улога модела студента у персонализацији и адаптацији учења

Стрелица *интерпретација (тумачења) акција студента* представља радње студента, као корисника на интерфејсу. Она покрива могуће акције које су доступне преко корисничког интерфејса, попут уноса података са тастатуре, аудио/видео улаза, команди задатих мишем итд. Модел студента подржава систем у разрешавању (тумачењу) ових информација, као што помаже систему да протумачи нетачне и нејасне радње корисника.

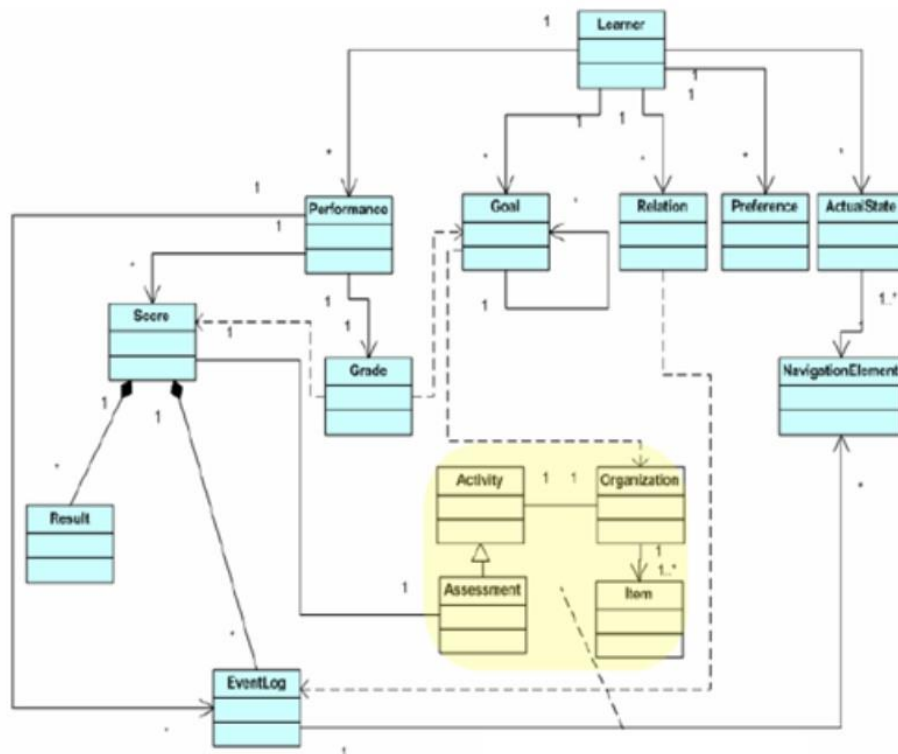
Одговор система представља акције инициране од стране система. Модел студента се користи за контролу и модификовање ових радњи према жељама корисника. Овај метод укључује прилагођавање понашања и изгледа система према кориснику, као и прилагођавање садржаја, тј. начин његове презентације. На пример, систем е-учења прилагођава своје акције нивоу знању из домена студента, тако што додељује једноставније информације за студенте са нижим предзнањем, а сложеније материјале студентима вишег нивоа знања. Адаптивни систем за е-учење је, на тај начин, усредсређен на прилагођавање садржаја сходно преференцијама и домену знања ускладиштеним у моделу студента.

Трећа употреба модела студента у сврху адаптације процеса учења, одвија се у самом систему. Модел студента подржава систем током интерних акција, које су често процеси обраде, током којих се примљене информације филтрирају.

Комбинација ових радњи се користи за адаптивне системе. На пример, систем за е-учење надгледа покушаје студента да реши задати задатак, користећи модел студента за тумачење студентових акција. Тада систем извршава интерне акције за одабир најпогоднијег упутства и образовног материјала који се упућује студенту. На ове интерне радње утиче модел студента, посебно у њему сачувани подаци о постојећем нивоу знања студента и склоности при учењу. Након овог интерног процеса, систем генерише одговарајућу акцију на интерфејсу. Јасно је да на облик презентације ове акције утиче и модел студента (Biswas & Springett, 2018).

При упису, студент постаје члан одговарајуће наставне групе. На основу припадности групи, систем одређује образовне објекте који се достављају студенту (објекти и њихов садржај су, наравно, дефинисани планом и програмом наставе). За сваки курс се дефинишу циљеви - постоје циљеви захтевани од система (у форми обавезних, захтеваних минимума који се морају испунити да би се одређени наставни садржај савладао).

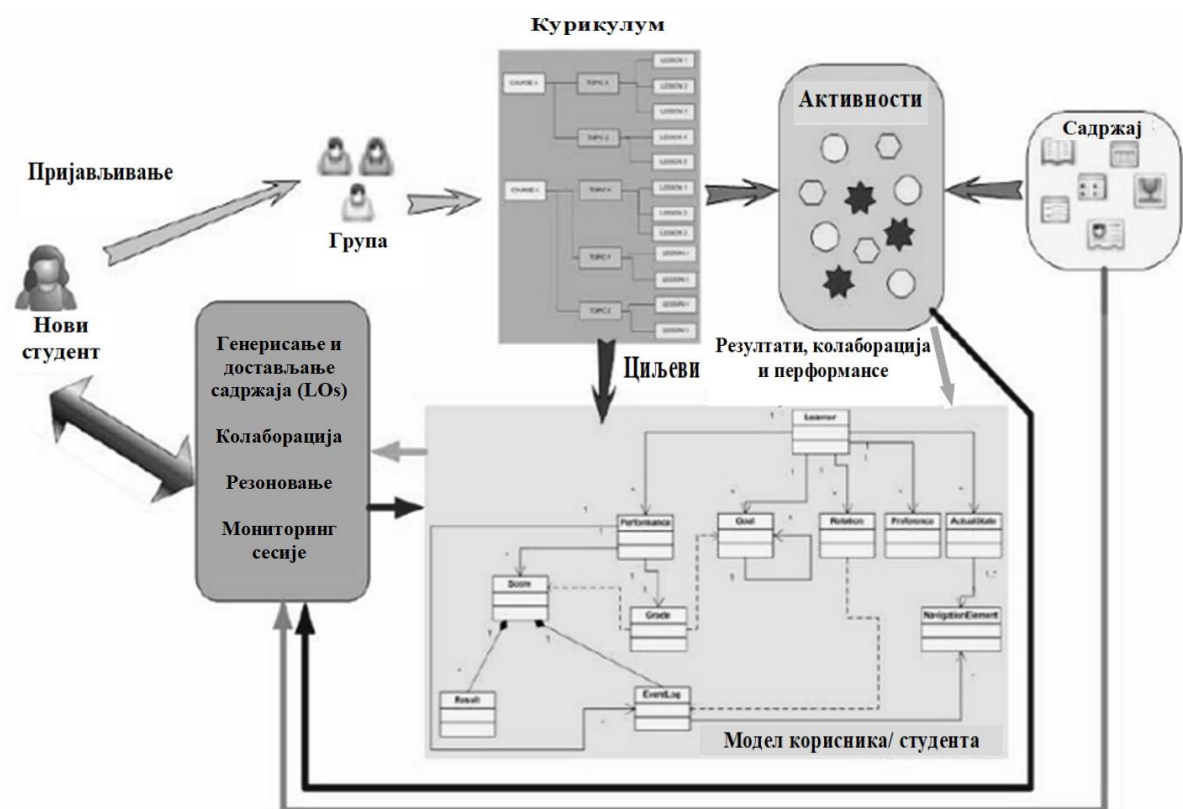
Напредовање студента се посматра и разматра у контексту циљева, и добија се из резултата студента (на тестовима, вежбама, успех остваривања задатка изражен процентуално и сл.).



Слика 45: UML дијаграм - Модел студента

Модел студента (слика 45) представља основну компоненту која омогућава да систем адаптира садржај и персонализује помоћ коју пружа студенту. Пошто студент припада наставној групи, која ради по предефинисаном наставном плану и програму, циљеви који се додају у модел су дефинисани планом и програмом. Наставник анализира садржај курикулума кроз активности које студент треба да реализује у току учења. Кроз активности, студент користи образовне садржаје, а систем мери његово напредовање.

Делови система који су намењени за композицију, презентацију садржаја, сарадњу између корисника система и за праћење сесије, користе податке из модела студента, да би адаптирали понашање система и образовне садржаје према појединачном кориснику – студенту.

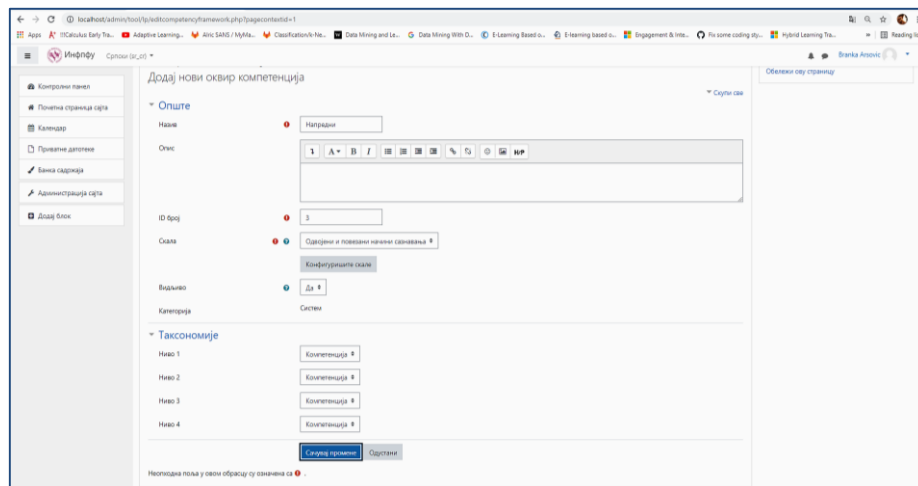
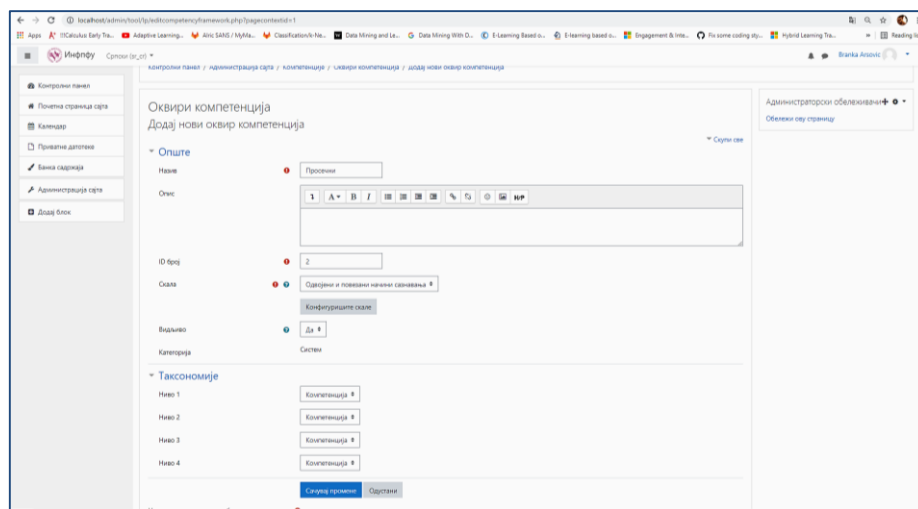
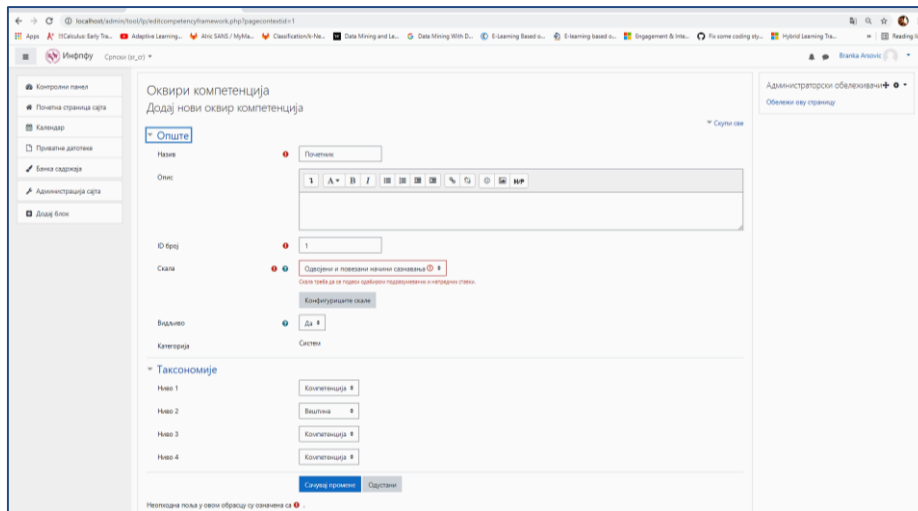


Слика 46: Интеракција модела студента са осталим деловима система

Студенти, који су учествовали у експерименту, по нивоу знања су подељени у три групе, а сваки од њих је даље подељен у три подгрупе по стилу учења (на крају имамо групе/кластере 1-1, 1-2, 1-3...3-3).

Студенти попуњавају тест за одређивање нивоа предзнања, на основу ког се сврставају у три групе:

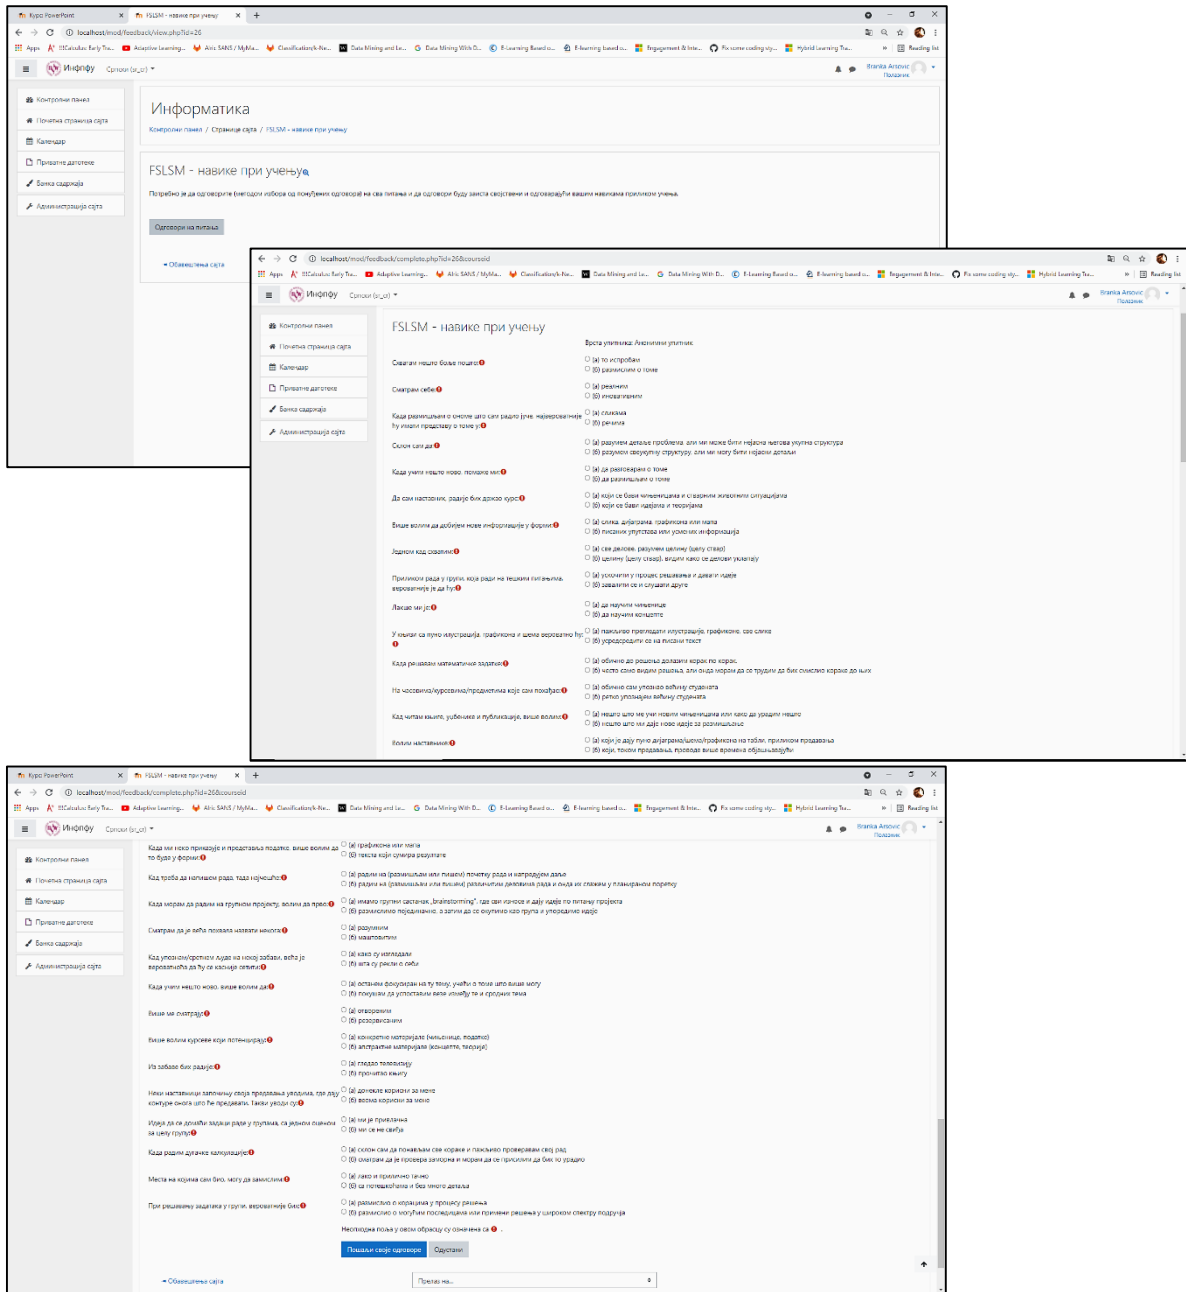
- група 1 – студенти почетници (56% популације)
- група 2 – студенти просечног нивоа знања (40% популације)
- група 3 – студенти напредног нивоа знања (4% популације).



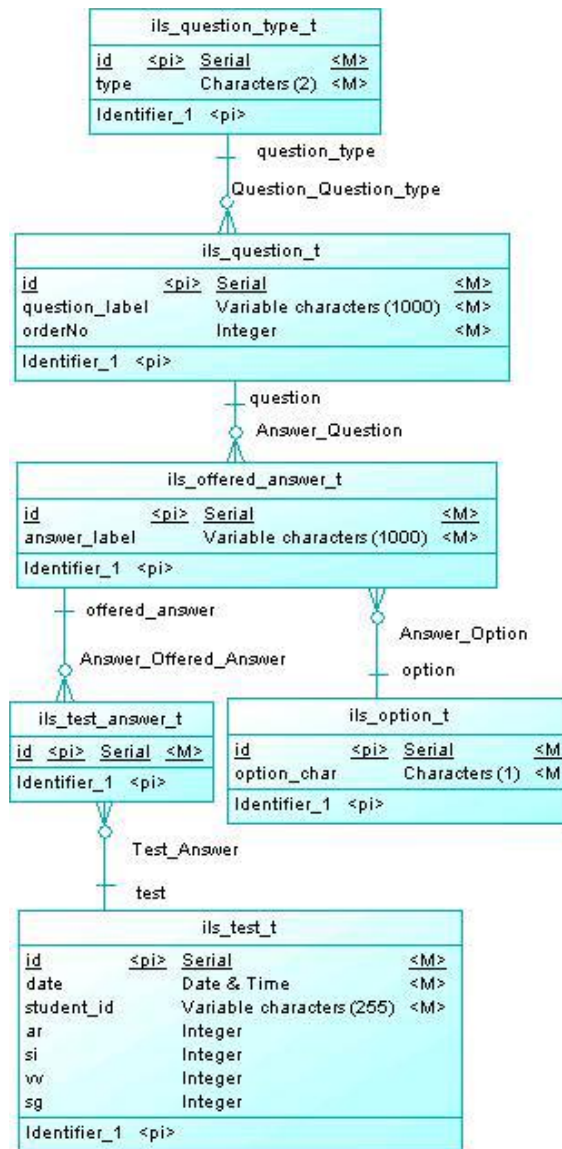
Слика 47: Креирања оквира компетенција студената (почетни, просечни, напредни ниво предзнања)

Даље, попуњавањем упитника за одређивање склоности и навика приликом учења (по FSLSM моделу), код студената добијамо поделу у три групе према стилу учења (слика 48):

- група 1 – визуелни/секвенцијални/активни стил учења (ВСА) (34% популације)
- група 2 – интуитивни/активни/глобални стил учења (ИАГ) (12% популације)
- група 3 – вербални/активни/секвенцијални стил учења (ВАС) (54% популације).



Слика 48: FLSM упитник за одређивање стила учења интегрисан у Moodle систему




Слика 49: Модел податка у FSLSM

Групе различитог стила учења се формирају у оквиру све три групе судената, одређених према нивоу предзнања. На тај начин се формирају коначне групе студената:

- група 1-1 – почетник/ВСА (17% популације)
- група 1-2 – почетник/ИАГ (7% популације)
- група 1-3 – почетник/ВАС (33% популације)
- група 2-1 – просечни/ВСА (14% популације)
- група 2-2 – просечни/ИАГ (4% популације)
- група 2-3 – просечни/ВАС (21% популације)
- група 3-1 – напредни/ВСА (2% популације)
- група 3-2 – напредни/ИАГ (1% популације)

- група 3-3 - напредни/ВАС (1% популације).

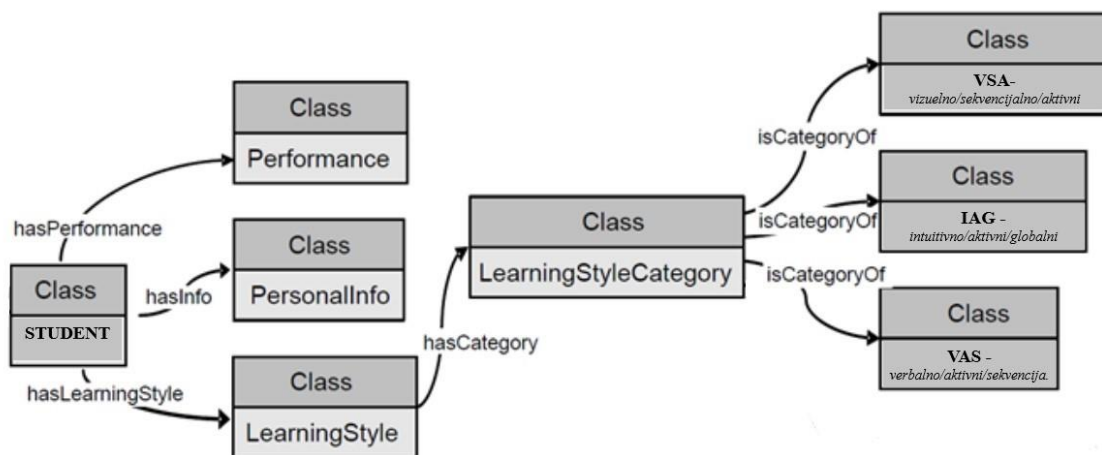
Распоређеност студената по припадним групама, дефинисаним на основу предзнања и стила учења је дата доњим графиком (слика 50).



Слика 50: Број студената у припадним кластерима (кластер, број студената, проценат популације)

Уочљиво је да највећи број студената има вербално/активни/секвенцијални стил учења (ВАС), чак њих 54%, а да је најзаступљенији просечни ниво предзнања (40% популације). Најзаступљенији кластер студената је кластер 1-3 (почетник/ВАС), 33% популације.

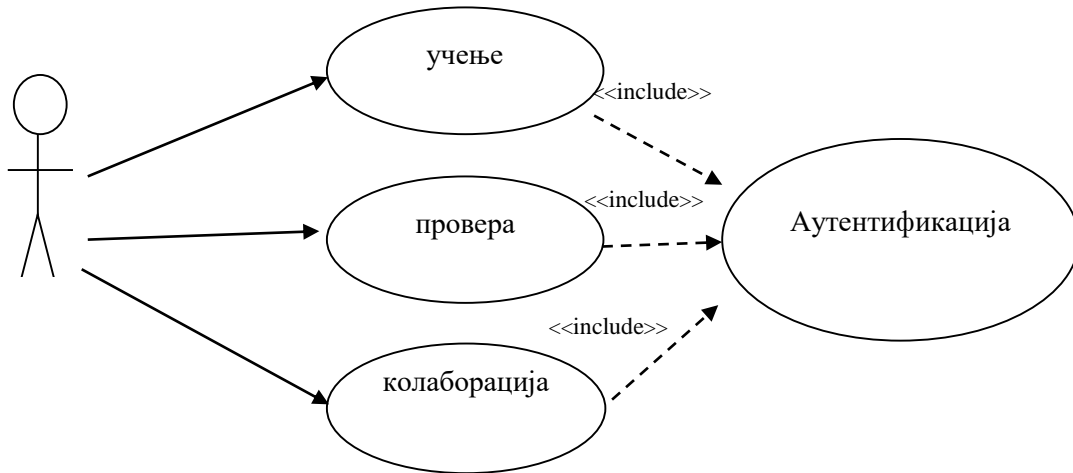
Класа студента (*Student*) се састоји од три компоненте са подацима о напретку ученика (*Performance*), личним подацима (*PersonalInfo*) и индивидуалном стилу учења (*LearningStyle*). Ове три компоненте су повезане са класом студента релацијама: *hasPerformance*, *hasInfo* и *hasLearningStyle* (слика 51).



Слика 51: Моделовање студената према стилу учења

Случајеви коришћења система од стране студента

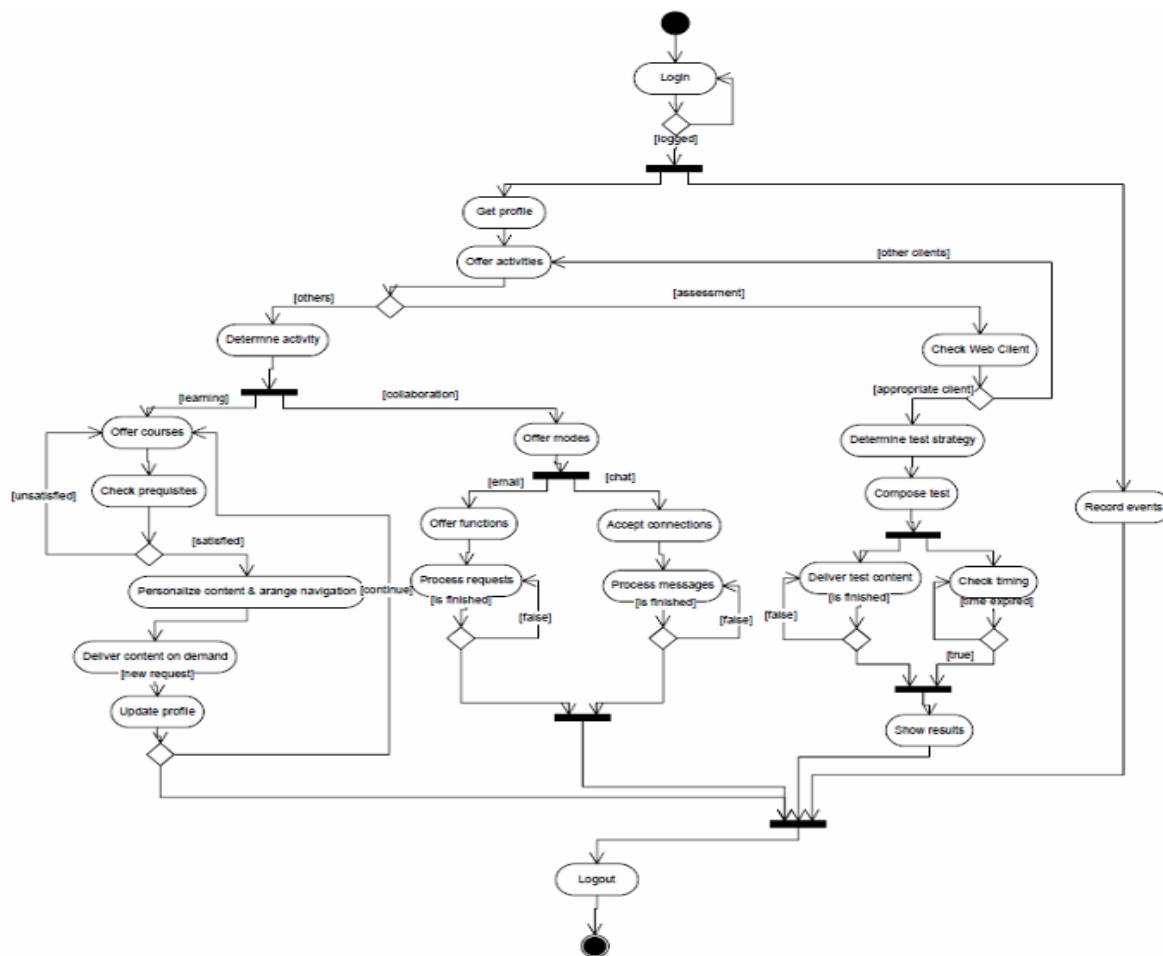
На основу случајева коришћења студентске апликације, постоје три основне групе активности, кроз које студент користи систем: учење, колаборација и провера. Ове три глобалне активности се могу описати јединственим дијаграмом активности (слика 52), а опис активности, коришћењем дијаграма случајева коришћења, следи у наставку.



Слика 52: Случајеви коришћења 0-тог нивоа студентске апликације

Учење је најважнији случај коришћења (СК), пошто се тиче главне функционалности система. На нултом нивоу, под учењем се подразумева не само сазнајни процес, већ и сви остали концепти у најширем смислу те речи (конструктивистички, друштвени, емотивни, мотивациони и когнитивни концепт).

Провера је у директној спречи са учењем. Постоје два вида провере: самооцењивање и испити (класификације). Самооцењивање студенти самостално обављају током учења, како би стекли увид у научено (проценили своје напредовање и „видели где су“). Резултате самооцењивања могу да користе и наставници како би пратили напредовање студената и благовремено пружили потребну помоћ или подстицај. Резултати испита се евидентирају у званични студентски запис и сачињавају његов досије.



Слика 53: UML дијаграм активности у коришћењу система (са аспекта студента)

Колаборација подразумева специфичне активности комуникације корисника кроз систем и са самим системом. Аутентификација се, такође, може издвојити као случај коришћења (и у студентској и у наставничкој апликацији) који је неопходан ради ауторизованог приступа систему. У студентској апликацији, код аутентификације постоји један аспект више – идентификација студента је неопходна као предуслов адаптације система према потребама појединца.

Од свих наведених СК, најкомплекснији је учење, а најспецифичнији је проверавање. Учење и колаборација се могу одвијати у комбинованом моду, али за време провере, остале функционалности система су недоступне (до завршетка провере).

После пријављивања студента (логовања), систем симултано обавља две активности: формира студентов модел (активност Get profile) и региструје догађај да се корисник улоговао (активност Record Events). Током сесије између студента и система, бележе се акције студента (снимају се догађаји, врши се праћење понашања, тј. мониторинг студента). То значи да активност именована као Record Events траје све док траје студентска сесија.

Следећа активност студентске апликације је да понуди студенту функционалности – активности (Offer Activitiest). На основу студентског избора, постоје два могућа тока дешавања. У случају да студент одабере проверу, потребна је додатна провера клијентске апликације (да ли студент има све предуслове да приступи провери). У случају да додатна провера није прошла, систем не дозвољава проверу знања и студент се враћа на поновни избор функционалности.

Други ток дешавања је за све остале активности осим провере знања. У овом случају постоје две гране, за две функционалности: учење и колаборација. Активности обухваћене овим двема гранама могу да се изводе симултано. То значи да, ако студент, нпр. учи, користи образовни садржај, он истовремено може да се консултује са другим корисницима система у вези материјала.

Активности учења

Активности учења започињу избором курса, затим неке теме (Item) предмета за учење, што је приказано као једна активност Offer Courses. Систем испитује да ли студент задовољава све предуслове за приступ одабраним ресурсима (да ли је аутентификован корисник, да ли је прошао претходне кораке учења и сл.). У случају да критеријуми нису испуњени, студент добија информације о томе шта му је још потребно за тај ниво учења и бива упућен на поновно бирање теме (Unsatisfied).

Ако су сви предуслови задовољени, систем користи податке из модела студента и врши персонализацију образовног курса (Personalize Content и Arrange Navigation). После компоновања, апликација испоручује захтеване садржаје студенту (Deliver Content on Demand). Ажурирање података у студентовом моделу (после самотестирања и после мониторинга у интеракцији са системом) врши се са активношћу Update Profile. Тиме се завршава један циклус учења.

Колаборативне активности

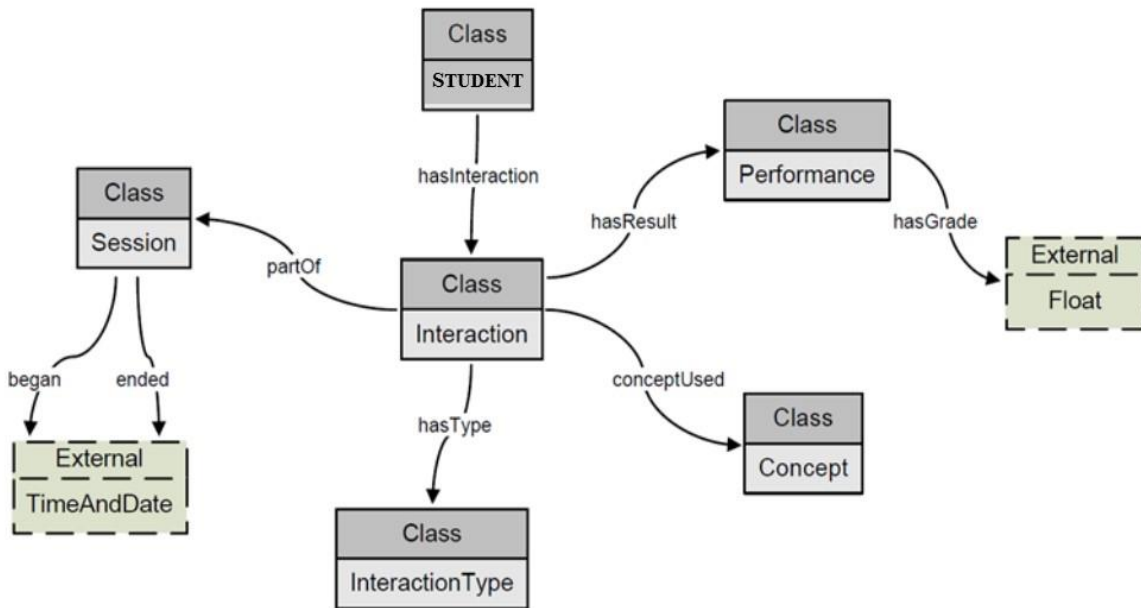
Различити колаборативни алати су у понуди система (Offer Modes), а на шеми су представљени e-mail и систем причаоница. Уопште, комуникација је у систему коришћена као средство за остваривање сарадње међу свим учесницима у процесу учења. Алати за овај случај коришћени од стране корисника су подразумевани у већ постојећем систему за e-Learning, који је изграђен на Moodle платформи, тако да се одатле преузимају.

Активности проверавања

У случају проверавања, пре него што се тест испоручи студенту апликација треба да компоује тест на основу дефинисане стратегије (Compose Test). Систем генерише тест одговарајуће тежине, сходно припаданом нивоу знања студента. Тестови су такође већ постојећи модул у платформи Moodle, тако да се активности испоруке теста, провере и евидентирања времена рада преузимају из платформе.

После тестирања систем приказује резултате у форми коју је дефинисао наставник. Студенту се могу приказати само збирни резултати, детаљни са образложењем за свако питање, комбиновани или само статистика проверавања (време, процентуална тачност и/или нетачност).

Сесија се завршава када се студент одјави из апликације (Logout). Потребно је да се студент експлицитно одјави помоћу форме или затвори прозор клијентске апликације. Тиме се у систему генерише догађај краја сесије. У случају да се ништа од овога не деси (студент заборави да се одјави или да затвори прозор апликације), систем је заштићен од заборављених сесија механизмом максималног времена неактивне сесије. Апликација мери време између акција корисника и у случају пасивности студента, већој од максималног задатог ремесног периода, сесија се насилно прекида.



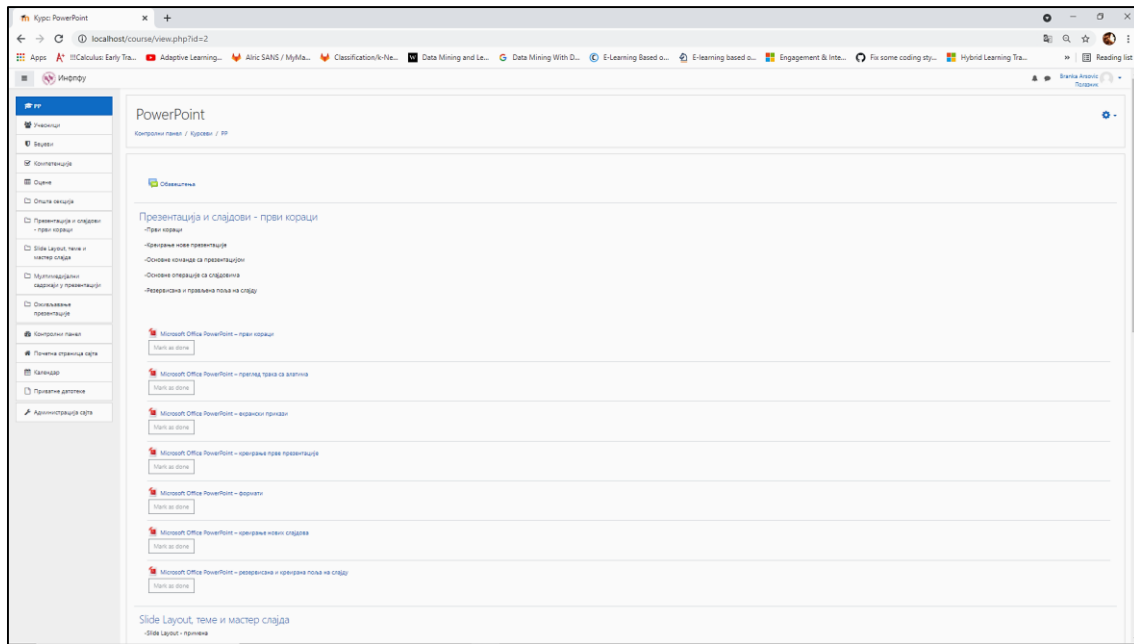
Слика 54: Праћење активности студента кроз његове интеракције са системом

Развијање садржаја

Суштина успешности предложеног адаптивног модела за учење лежи управо у креирању великог броја образовних објеката који су по својој структури, начину презентовања садржаја, али и обиму прилагођени одређеним, дефинисаним групама студената. Тенденција је да образовни материјали буду модуларни и да се креирају по опште прихваћеним стандардима, како би били употребљиви у различитим образовним системима и различитим курсевима.

У циљу омогућавања што боље прилагођености образовног садржаја потребама студента, образовни објекти треба да имају врло разгранату структуру, а ресурси (датотеке различитог типа – pdf, doc, илустрације, аудио-видео записи и сл.) да буду фрагментисани, описани и семантички повезани. Са тако уређеним образовним садржајем, у форми фрагмената манипулација је много лакша, у смислу додавања, измене, сортирања у динамички креираним наставним садржајима који се достављају студентима.

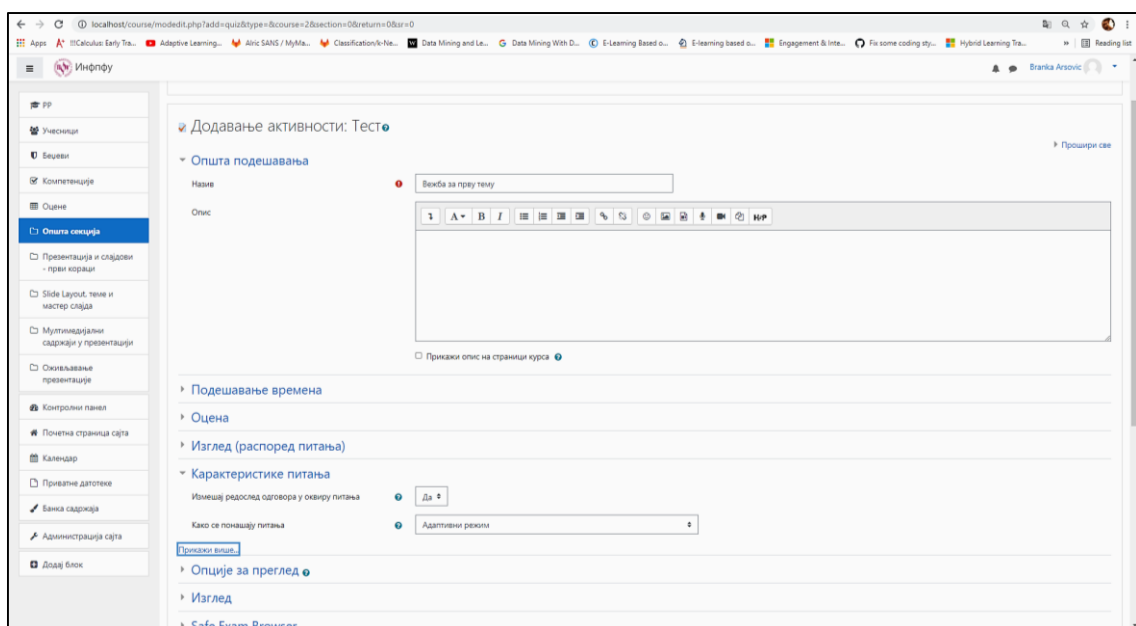
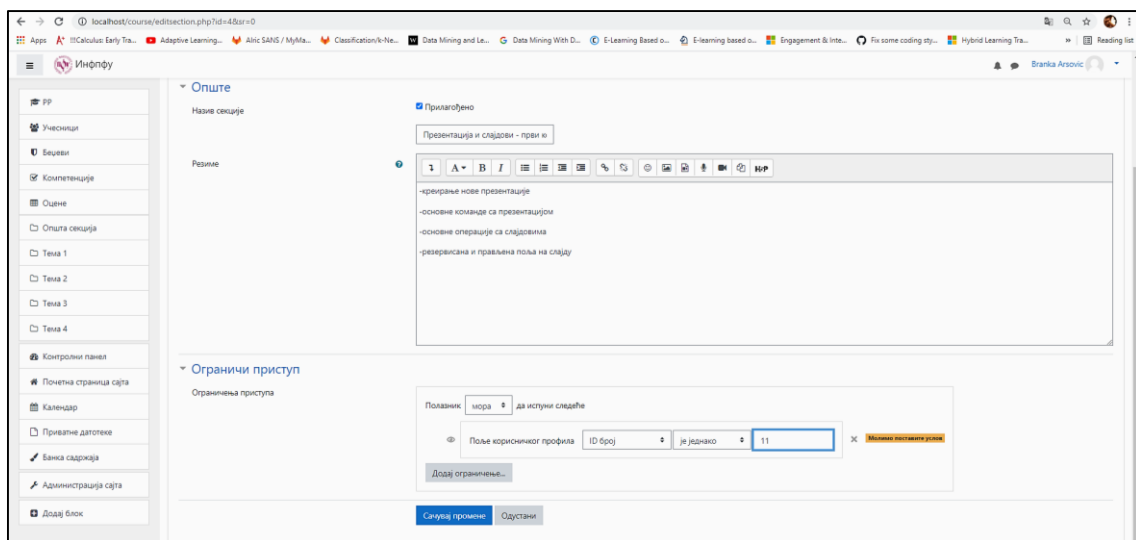
Приликом креирања образовних садржаја, исти се нотирају додатним мета подацима који указују на њихов ниво сложености (који одговара нивоима предзнања студената, више о томе је било речи у 3.5), али и на то за који стил учења су намењени (поглавље 3.6). На основу броја препознатих стилова учења и нивоа предзнања студената, лако се закључује да је потребно креирање великог броја прилагођених образовних објеката, према основним методичко-дидактичким захтевима. Тако је формирање базе образовних материјала изискивало доста времена, али је то потребан труд који се мора уложити у циљу постизања адаптивности у једном систему за управљање процесом учења.



Слика 55: Креирање материјала за одређену групу студената

Свака образовна тема може да има поред подтема и ресурсе (садржаје учења). Динамичко компоновање садржаја није могуће ако се ресурси не класификују према намени у конкретној теми. Актуелни стандарди за компоновање садржаја не покривају где и како се имплементира механизам адаптације садржаја (јер у адаптивним системима постоје специфичности имплементације, тако да за њих стандарди нису развијани). Управо из тог разлога се у модел образовног садржаја (експертни, домен модел) додају још два концепта – контекст ресурса (мета податак о томе да ли се образовни садржај користи за почетнички, средњи или напредни ниво предзнања) и идентификатор стила учења (метаподатак о томе за који стил учења је предвиђен образовни материјал).

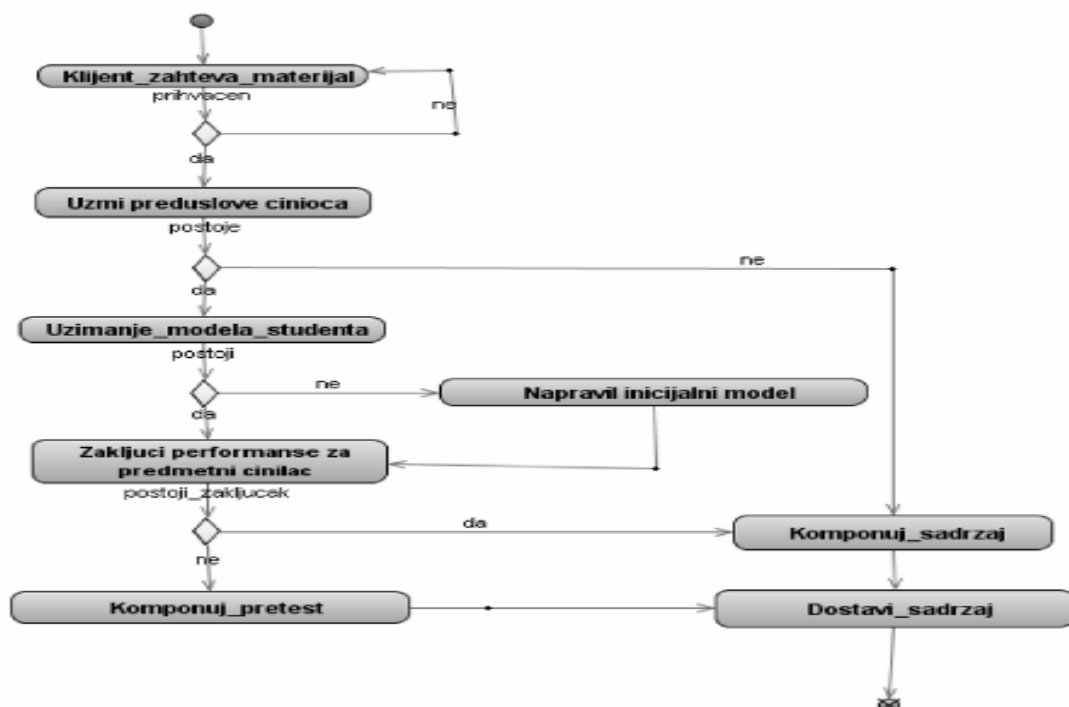
То значи да је оваквим решавањем селекције образовних објеката, учење класификовано у две димензије: по стилу учења и по сложености, тј. према постојећем предзнању, о чему је већ било речи. Адаптација се одвија у студентској апликацији кроз посебне активности система, сваки пут када студент захтева наставни садржај посредством клијентске апликације.



Слика 56: Прилагођавање образовних материјала према компетенцијама и адаптивном моделу рада

Дијаграми активности

Систем динамички компоује садржаје у неколико фаза, тј. кроз неколико активности. Материјал се компоује по захтеву корисника (студента). Апликација омогућава студенту, посредством механизма структуре курса, да приступи ресурсима учења (образовним материјалима) који су повезани за образовну тему. После прихватања захтева за материјал од стране студента, апликација прикупља податке о предусловима приступања чиниоцу. Ако предуслови нису дефинисани, апликација компоује садржај на подразумевани начин (распоређивање одговарајућих материјала по унапред утврђеном шаблону у зависности од припадне групе студената). Ако предуслови постоје, следећи корак у апликацији је да се из модела студента, који је поставио захтев, преузму подаци потребни за одлучивање о компоновању.




Слика 57: Дијаграм активности – адаптивно компоновање садржаја

У сваком случају, систем одлучује о захтеваном садржају. Ако закључак не постоји (не постоји довољан ниво прихватљивости закључка), уместо садржаја компоњује се претест, који омогућава профилисање студента.

Адаптациони модул

Основа за адаптацију су одлуке које доноси машина за резоновање на основу правила кроз која се обрађују улазни подаци. Платформа за резоновање је дизајнирана као адаптациони модул (АС), који користи Jess shell као палтформу за одлучивање и резоновање. Продукциона правила, заједно са шаблонима (templates) чине базу знања. Модуларан дизајн базе правила омогућава бржи одзив система на захтеве корисника. Правила адаптације су груписана у следеће модуле:

- стартна правила – прихватају захтеве за резоновање и активирају одговарајућу групу правила
- навигациона правила – намењена доношењу закључака везаних за решавање адаптивне навигације и
- презентациона правила – намењена доношењу одлука везаних за адаптивно компоновање садржаја (презентацију) (слика 58).



Слика 58: Дефинисани типови правила

Модули правила имају унификовану структуру. Састоје се од потребних шаблона (templates), уланчаних радних и циљних правила. Врста уланчавања у ланцу закључивања може да се експлицитно подеси (у напред – forward chaining, или у назад – backward chaining). Радна правила омогућавају да се улазни подаци прихвате, обраде, дајући међурезултате резоновања. Циљна правила за улазне вредности имају међурезултате резоновања, а као последицу дају коначне закључке. Извршењем било ког циљног правила из модула резоновање се завршава.

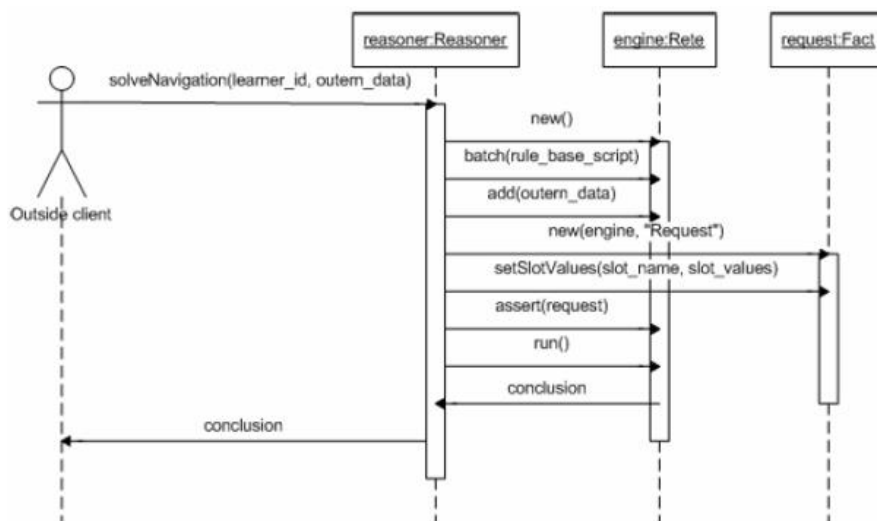
На слици 59 је део основног модула, тј. модула са стартним правилима. Резоновање (одлучивање) започиње активацијом и извршењем једног од стартних правила. Ова правила имају највиши приоритет (salience), а прихватају спољне захтеве, од корисника и, на основу захтева, активира се један од модула базе знања.

```

(defrule start_nav (declare(salience 1000))
  (Request(command == "check_learner_nav")) => (focus NAVIGATION))
(defrule start_prsnt (declare(salience 1000))
  (Request(command == "check_learner_prsnt")) => (focus PRESENTATION))
  
```

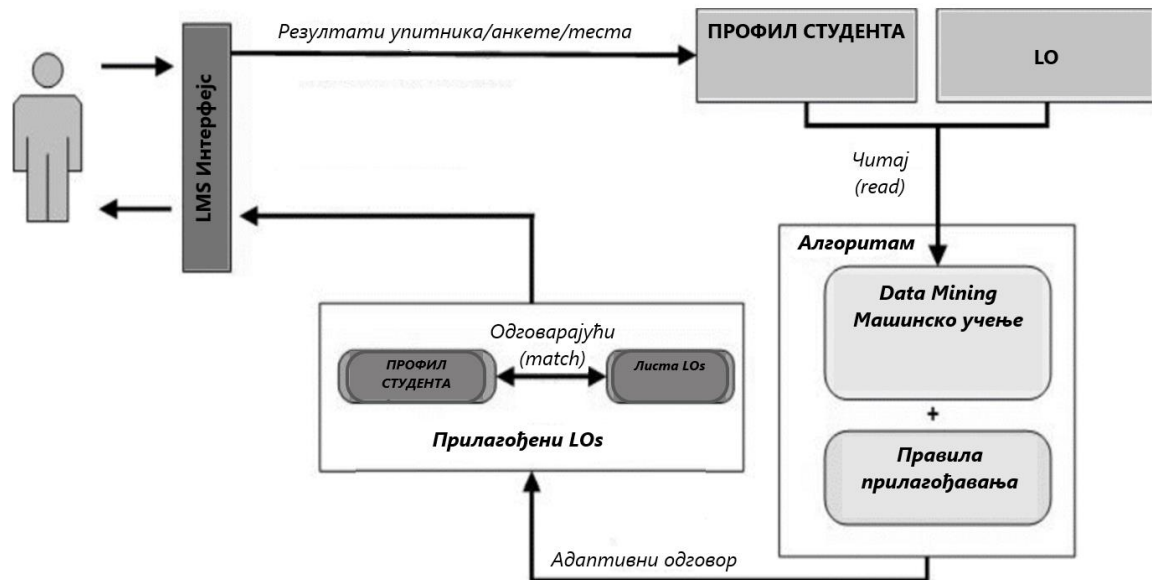
Слика 59: Дефинисање стартних правила

За успешан рад адаптационог модула, поред добро дизајниране базе правила, неопходно је и остваривање синхронизованости са апликацијом. Синхронизација се контролише из клијентске апликације, поштовањем одговарајућег редоследа функционалних позива (слика 60).



Слика 60: Дијаграм секвенци процеса закључивања у адаптационом модулу

Слика 61 приказује општи поступак препоруке образовних материјала и објеката (LOs) за е-учење, прилагођених захтевима и потребама студената. Прво је креиран модел студента на основу података добијених од студената путем упитника и тестова, затим адаптациони модул гради адаптивни концепт правила избора или правила избора садржаја, анализирајући односе између ученика и модела LO (образовних материјала и објеката, похрањених у експертном моделу). Адаптациони модул извршава правила избора и даје препоручени материјал.



Слика 61: Процес доделе адаптивног образовног садржаја

Представљен је ефикасан алгоритам прилагођавања, који препоручује персонализоване образовне објекте (LO), засноване на стилевима учења ученика (приступ се заснива на моделу стила FSLMS, који се користи за представљање како стилова учења студената, тако и профила образовних објеката), такође, у обзир се узима и ниво претходног знања студената. Алгоритам кластеризације методом К-средњих вредности, мера косинусне сличности и Пирсонов коефицијент корелације су ефикасне технике за примену адаптивног система одабира одговарајућих образовних материјала. Прецизност препорука и прилагођавања мери се помоћу традиционалних метрика процене, тј. помоћу средње апсолутне грешке (Mean Absolute Error – MAE) и основне средње квадратне грешке (Root Mean Squared Error – RMSE).

Да би се идентификовале одговарајуће мере сличности које се користе у адаптационом моделу предложеном и развијеном у овој дисертацији, било је важно прегледати уобичајене метрике сличности које се користе у системима за е-учење, и испоставило се да, горе поменути Пирсонов коефицијент корелације, косинусна сличност и кластеризација методом К-средњих вредности, највише одговарају потребама истраживања.

Пирсонова корелација

Пирсонов коефицијент корелације је мера линеарне зависности између две променљиве (вектори са стварном вредношћу). Пирсонов коефицијент корелације две променљиве x и y формално је дефинисан као коваријанса две променљиве подељена

производом њихових стандардних одступања (која делује као фактор нормализације) и еквивалентно се може дефинисати једначином:

$$P(x, y) = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

где су \bar{x} и \bar{y} средње вредности x and y , респективно.

Коефицијент $P(x, y)$ се креће од -1 до 1 и непроменљив је према линеарним трансформацијама било које променљиве. Вредност -1 представља савршену негативну линеарну зависност, 0 да нема линеарне зависности и 1 представља савршену позитивну линеарну зависност. Употребљене као мера сличности, негативне вредности указују на различитост, док позитивне вредности означавају меру сличности између две променљиве, а 1 је савршена сличност.

Косинусна сличност

Косинусна сличност је једна од најпопуларнијих мера сличности, која мери угао између два вектора и израчунава се као однос скаларног производа и производа величина (по следећој једначини):

$$c(x, y) = \frac{x \cdot y}{\|x\| \cdot \|y\|}$$

Вредности $c(x, y)$ се крећу од -1 до 1 уопштено, и од 0 до 1, ако координате x и y нису негативне вредности. Занима нас ово друго, где вредност 0 не представља никакву сличност, а 1 савршену сличност.

Алгоритам кластеризације методом K-средњих вредности

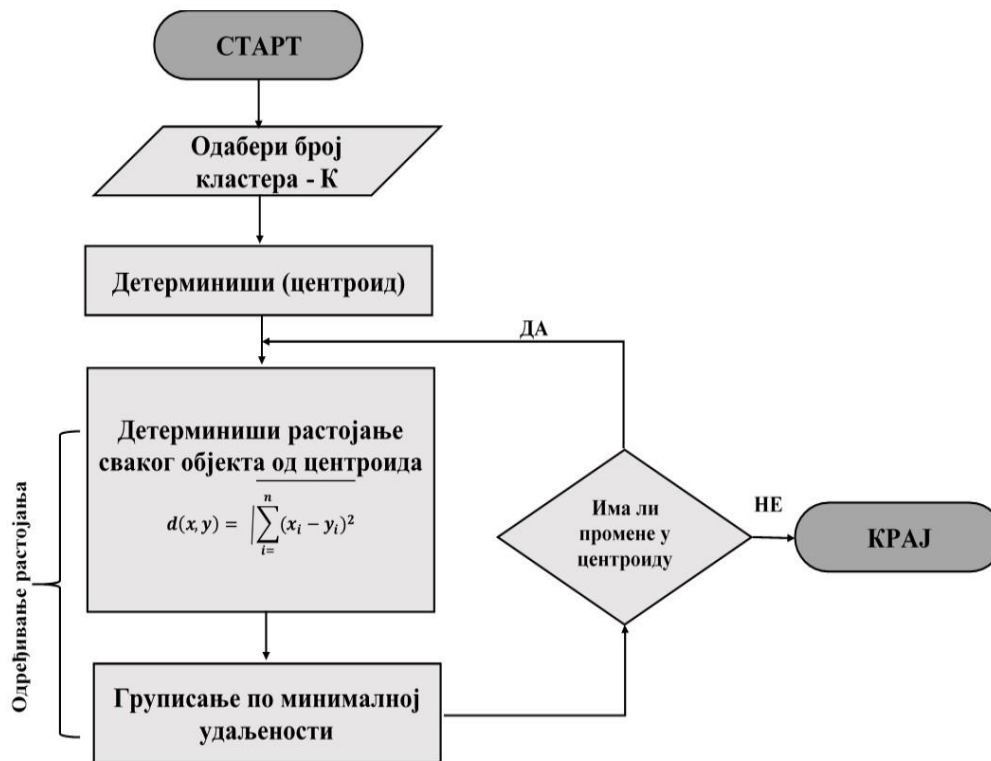
Кластеровање се може дефинисати као процес организовања објеката у бази података у кластере (групе), тако да објекти унутар истог кластера имају висок степен сличности, док објекти који припадају различитим кластерима имају висок степен различитости. Због своје једноставности и интуитивних интерпретација, алгоритам K-средњих вредности један је од најпопуларнијих алгоритама кластеризације. Алгоритам је приказан дијаграмом тока на доњој слици и може се описати следећим корацима:

- Корак 1 – бирање K случајних тачака из скупа података као почетних кластер центроида.
- Корак 2 – стварање K кластера повезивањем сваке тачке података са њиховим најближим центроидом кластера према еуклидској раздаљини дефинисаном једначином:

$$D(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

где су x и y два вектора.

- Корак 3 – прерачунавање центроида (тежишта) сваког кластера, као средине свих тачака-података у том кластеру.
- Корак 4 – понављање корака 2 и 3, док год центроиди не престану више да се мењају.



Слика 62: Алгоритам кластеризације методом К-средњих вредности

Кластеризација побољшава ефикасност система адаптације, јер се може користити ван мреже за поделу скупа података тако да се слични подаци групишу у исти кластер, а различити подаци стављају у различите кластере.

Алгоритам прилагођавања

Раније је напоменуто да се вектори стила учења рачунају коришћењем одговора студената на упитнику за детерминисање навика при учењу (FSLSM). Стил учења студента је представљен вектором стварних вредности, а у моделу студента је означен префиксом 1, 2, 3 респективно за ВСА, ИАГ и ВАС. Такође, предзнање студената, одређено тестом, се представља вектором у распону {1, 2, 3} (респективно за почетно, просечно и напредно предзнање), где се префикси вектора нивоа предзнања користе такође као резервисана поља, по већ претходно описаној методи нотације (део *Модел студента*). Тако да, у моделу студента, имамо метаподатке, који су показатељи припадности одређеној групи, сходно претходном знању и стилу учења: $MS=\{11, 12, 13...32, 33\}$.

Материјали за учење су структурирани у образовне објекте - LOs, за сваку тему. Образовни ресурси су креирани и нуде се у различитим форматима и медијима како би се задовољиле преференце одређених стилови учења студената. Материјали постоје у форми текстуалних докумената (првенствено у pdf формату, ређе као word документи),

мултимедијалних презентација (PowerPoint, Prezi), слика, аудио, видео снимака, интернет ресурса (линкови ка спољним изворима, најчешће туторијалима на Youtube) итд. Како студенти са различитим стилем учења преферирају различите формате материјала, то је профил LO такође представљен вектором стила учења, који указује на категорију студената којима је овај материјал погодан.

За разлику од стилова учења студената који се одређују путем FSLSM упитника, профил LO (тј. његово означавање) поставља наставник. Такође, наставник креира материјале у три нивоа сложености, сходно нивоима претходног знања студената, и врши нотацију сваког од LO и према нивоу сложености, па је коначна нотација образовних материјала: $LO = \{11, 12, 13 \dots 32, 33\}$. За сваку лекцију образовни објекти су груписани ван мреже да би се поделили у групе сличних профила користећи алгоритам кластерисања K-средстава. Овај поступак се понавља сваки пут када дође до промене базе података LO. Ових 9 кластера користи се као улаз у, даље представљени, адаптациони алгоритам.

Нека је MS вектор мета податка о предзнању и стилу учења активног студента. Алгоритам прилагођавања је описан у следећа 4 корака где Sim_1 и Sim_2 означавају било коју претходно описану метрику сличности:

- Корак 1 – израчунај C, кластер LOs најближи карактеристикама MS активног студента, користећи метрику сличности Sim_1 (то се ради израчунавањем степена сличности између MS и центроида (тежишта) сваког кластера) и одабери кластер који даје највећи степен сличности.
- Корак 2 – израчунај степен сличности између MS и сваког LO у C користећи метрику сличности Sim_2 : За све $LO \in C$ израчунај $Sim_2(MS; LO)$.
- Корак 3 – изабери првих n LO који су најсличнији LS: број LOs који ће бити изабрани може бити изабрана константа или одређен помоћу прага сличности.
- Корак 4 – рангирање образовних објеката у опадајућем поретку, према добијеним оценама сличности: ово чини листу LOs који се препоручују активном студенту.

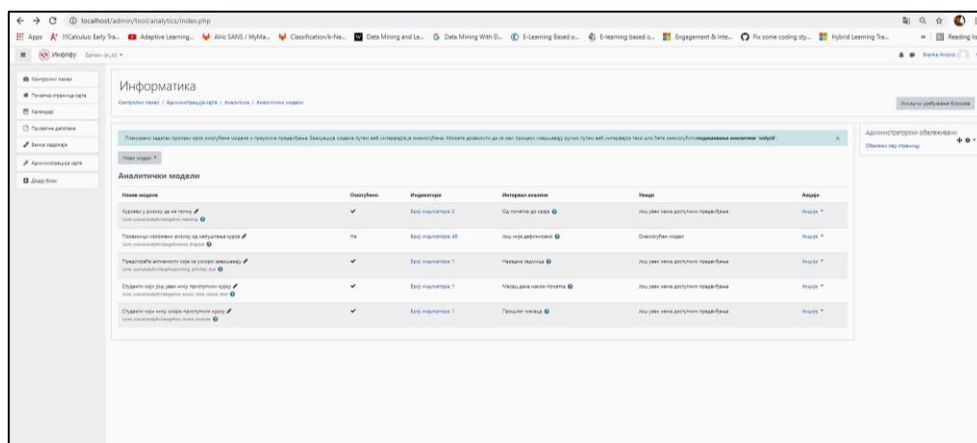
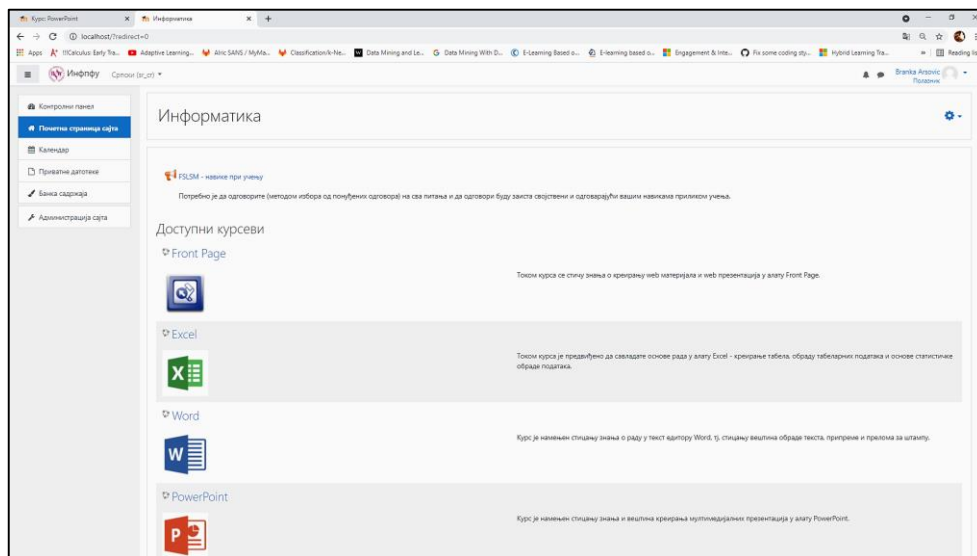
Тестирањем различитих метрика сличности (Пирсонове корелације и косинусне сличности), на узорку студената, утврђено је да метрика сличности Sim_1 коришћена за одређивање кластера LOs најближих карактеристикама MS активног студента, нема значајног утицаја на тачност алгоритма. Показало се да нема значајне разлике између ових расподела. То значи да се било која од ове две мере сличности може користити за Sim_1 у алгоритму. Кад је одређено која се метрика (тј. Sim_1) користити за израчунавање кластера LOs најближих карактеристикама студента, следећи корак је проналажење најефикасније метрике (тј. Sim_2) за одабир топ n LOs најближих карактеристикама MS студента унутар већ формираног кластера образовних објеката. Експериментални резултати су показали да адаптациони алгоритам има најбољу тачност када је Пирсонов коефицијент корелације узет за Sim_2 .

input : K: broj klastera, $K \geq 1$
C: skup K klastera C_1, \dots, C_k
CC: skup centroida (težišta) K klastera
MS: karakteristike aktivnog studenta
T: prag sličnosti
output: TopN: lista preporučenih LO

```

1 j = 1
2 x = c(MS;CC1)
  /* c je kosinusna sličnost */
3 for i = 2 to K do
4     if c(MS;CCi) > x then
5         x = c(MS;CCi)
6         j = i
7     end
8 end
  /* Cj je klaster najbliži MS */
9 TopN = [] /* empty list */
10 foreach LO ∈ Cj do
11 S = P(MS;LO)
  /* P is the Pearson similarity */
12 if S ≥ T then
13     TopN:append(< LO)
14 end
15 end
16 quickSort(TopN; 2)
17 return TopN

```



Слика 63: Screenshot адаптивног курса за е-учење

5. АНАЛИЗА И ДИСКУСИЈА РЕЗУЛТАТА

Евалуација и тестирање креираног модела је обављена кроз спроведени експеримент. Овако изведена евалуација сагледава модел из следећих аспеката: техничко-технолошког, функционалног и друштвеног аспекта. Фокус процене је на новим концептима е-Learninga, имплементираним у предложеном моделу решења – адаптација према стилу учења и предзнању. Компаративна анализа је извршена поређењем са већ постојећом платформом за учење (која је и служила као основа за проширење до предложеног решења).

Студенти, који су учествовали у експерименту, по нивоу знања су подељени у три групе, а свака од њих је даље подељена у три подгрупе по стилу учења (на крају имамо кластере 1-1, 1-2, 1-3...3-3, као што је претходно објашњено у делу 4.5). Анкетирањем је одређена припадност одређеном кластеру, али у експерименту нису сви студенти упућени на адаптивни модул курса. Наиме, случајним избором студената приликом пријављивања на курс, пола их је упућено на курс одговарајући њиховим показаним карактеристикама (адаптивни курс е-учења), а остали су упућени на већ постојећи, традиционални, е-Learning курс, који не подржава персонализацију и није адаптиван. Тако је један број студената имало прилику да прође обуку у адаптивном, прилагођеном курсу, док су остали студенти приступали већ постојећој платформи за учење. Током рада на курсу, вршен је мониторинг студената, тако да су добијени резултати подразумевали број пријављивања на курс, време проведено на курсу и остварене резултате (кроз завршну оцену и процену знања, изведену на основу испуњења обавеза – вежби, задужење и тестова на курсу).

Анализа добијених резултата извршена је применом статистичке анализе и техникама науке о подацима, као и методама Data Mining. У овом раду су коришћени класификација, утицајни параметри и кластер анализа.

5.1. Анализа резултата статистичким методама

За потребе анализе података статистичким методама, праћене су следеће вредности:

- тип похађаног курса (1- постојећи, традиционални е-Learning курс и 2 – адаптивни е-Learning курс)
- време проведено на курсу (систем предвиђа категорије: 0 – недовољно времена проведено на курсу, тј. до 30 сати; 1 – оптимално време проведено на курсу, 30-50 сати и 2 – превише времена на курсу, тј. преко 50 сати)
- број пријављивања на курс (системом су предвиђене категорије: 0 – премало, тј. до 15 пријављивања; 1 – оптимално, 15-40 пријављивања и 2 – пуно, преко 40 пријављивања на курс)
- ниво предзнања (већ је речено да су студенти разврстани у три категорије: 1 – почетни, 2 – просечни и 3 – напредни)
- стил учења (диференцирале су се три групе: 1 – ВСА, 2 – ИАГ и 3 – ВАС)
- припадност одређеној групи (припадна група је дефинисана предзнањем и стилем учења, па је тако и означен комбинацијом ова два податка, при чеми је први од њих одговарајући предзнању, а други стилу учења: 11, 12, 13.... 33)

- оцена (оцена студената је изведена на основу тестирања током курса и одговара стандардном начину нотирања оцена од 5 до 10).

Статистичком анализом података показује се међусобна зависност праћених вредности и, том приликом, су добијени следећи резултати.

Дескриптивна статистика

Дескриптивна (описна) статистика је обично први корак у анализи података, а служи за описивање прикупљених података. Обично претходи статистичком закључивању и предвиђању, а користи бројчане (табеле) и графичке методе како би прикупљене податке приказала на разумљив и јасан начин.

Следеће табеле представљају податке, добијене експериментом, а који се тичу претходно поменутих праћених вредности (време проведено на курсу, број пријављивања, нивои предзнања, стил учења, припадна група) и расподелу популације у оквиру њих, по дефинисаним категоријама.

Табела 15: Време проведено на курсу

Време (0, 1, 2)		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	0 време 0 - 30 сати	30	18,8	18,8	18,8
	1 време >= 30 сати	63	39,4	39,4	58,1
	2 време > 30 сати	67	41,9	41,9	100,0
	Total	160	100,0	100,0	

Табела 16: Број пријављивања (логовања) на курс

Број логовања (0, 1, 2)		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	0 0 - 15	30	18,8	18,8	18,8
	1 15 - 40	71	44,4	44,4	63,1
	2 преко 40	59	36,9	36,9	100,0
	Total	160	100,0	100,0	

Табела 17: Ниво предзнања студената

Предзнање		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	1 почетник	90	56,3	56,3	56,3
	2 просечни	64	40,0	40,0	96,3
	3 напредни	6	3,8	3,8	100,0
	Total	160	100,0	100,0	

Табела 18: Стил учења

Стил учења		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	1 ВСА	54	33,8	33,8	33,8
	2 ИАГ	19	11,9	11,9	45,6
	3 ВАС	87	54,4	54,4	100,0
	Total	160	100,0	100,0	

Табела 19: Припадна група (кластер) студента, по предзнању и стилу учења

Припадни кластер		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	1-1	27	16,9	16,9	16,9
	1-2	11	6,9	6,9	23,8
	1-3	52	32,5	32,5	56,3
	2-1	23	14,4	14,4	70,6
	2-2	7	4,4	4,4	75,0
	2-3	34	21,3	21,3	96,3
	3-1	3	1,9	1,9	98,1
	3-2	2	1,3	1,3	99,4
	3-3	1	0,6	0,6	100,0
	Total	160	100,0	100,0	

Табела 20: Дескриптивна статистика

Descriptive Statistics

	N	Mean	Std. Deviation	Minimum	Maximum	Percentiles		
						25th	50th (Median)	75th
време на курсу	160	39,3438	19,10384	0,00	69,00	33,0000	42,0000	54,0000
број логовања	160	30,1250	17,83458	0,00	67,00	19,2500	31,0000	43,7500
оцена	160	6,8313	1,49305	5,00	10,00	6,0000	7,0000	8,0000

Табела 21: Провера нормалности

Tests of Normality^b

	Позитивна оцена	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
време на курсу	0 негативна оцена	0,326	38	0,000	0,720	38	0,000
	1 позитивна оцена	0,138	122	0,000	0,919	122	0,000
број логовања	0 негативна оцена	0,323	38	0,000	0,710	38	0,000
	1 позитивна оцена	0,108	122	0,001	0,967	122	0,004
оцена	1 позитивна оцена	0,209	122	0,000	0,875	122	0,000

a. Lilliefors Significance Correction

b. Ocena is constant when позитивна оцена = 0 негативна оцена. It has been omitted

Врста курса (традиционални – адаптивни)

Желимо да проверимо релацију вредности *Оцена* и врсте похађаног *Курса*.

Табела 22: Статистика теста

Test Statistics ^a	
	Оцена
Mann-Whitney U	2218,500
Wilcoxon W	5378,500
Z	-3,418
Asymp. Sig. (2-tailed)	0,001

a. Grouping Variable: курс

Табела 23: Групна статистика фактора *оцена* у односу на *курс*

Group Statistics				
курс	N	Mean	Std. Deviation	Std. Error Mean
Оцена 2 традиционални	79	6,3924	1,21336	0,13651
1 адаптивни	81	7,2593	1,61847	0,17983

Табела 24: Независни тест узорака

		Levene's Test for Equality of Variances		t-test for Equality of Means						
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	95% Confidence Interval of the Difference	
									Lower	Upper
Оцена	Equal variances assumed	10,344	0,002	-3,826	158	0,000	-,86685	0,22657	-1,31436	0,41935
	Equal variances not assumed			-3,839	148,270	0,000	-,86685	0,22578	-1,31301	0,42070

Коментар: Разлика средњих вредности оцена између студената који су похађали традиционални и студената који су похађали адаптивни eLearning курс је статистички значајна ($p < 0,0005$). Средња вредност оцена студената који су радили на традиционалан начин је $6,39 \pm 1,21$ а студената који су радили на прилагођен начин је $7,26 \pm 1,62$.

Проверавамо релацију вредности *Времена проведеног на курсу* и врсте похађаног *Курса*.

Табела 25: Статистика теста

	време на курсу
Mann-Whitney U	1764,000
Wilcoxon W	5085,000
Z	-4,903
Asymp. Sig. (2-tailed)	0,000

a. Grouping Variable: курс

Табела 26: Групна статистика фактора *време на курсу* и *курса*

курс		N	Mean	Std. Deviation	Std. Error Mean
време на курсу	2 традиционални	79	44,0127	20,92998	2,35481
	1 адаптивни	81	34,7901	15,99118	1,77680

Табела 27: Независни тест узорака

		Levene's Test for Equality of Variances		t-test for Equality of Means						
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	95% Confidence Interval of the Difference	
									Lower	Upper
време на курсу	Equal variances assumed	7,526	0,007	3,137	158	0,002	9,22253	2,94020	3,41537	15,02970
	Equal variances not assumed			3,126	145,968	0,002	9,22253	2,94994	3,39243	15,05264

Коментар: Разлика средњих вредности времена проведеног на курсу између студената који су похађали традиционални и студената који су похађали адаптивни eLearning курс је статистички значајна ($p = 0,002$). Средња вредност времена проведеног на курсу студената који су радили на традиционалан начин је $44,01 \pm 20,93$ а студената који су радили на прилагођен начин је $34,79 \pm 15,99$.

Желимо да утврдимо релацију вредности *Број логовања* и врсте похађаног *Курса*.

Табела 28: Статистика теста

Test Statistics ^a	
	Број логовања
Mann-Whitney U	1776,000
Wilcoxon W	5097,000
Z	-4,863
Asymp. Sig. (2-tailed)	0,000

a. Grouping Variable: курс

Табела 29: Групна статистика фактора *број логовања* и *курса*

Group Statistics					
курс		N	Mean	Std. Deviation	Std. Error Mean
Број логовања	2 традиционални	79	36,4937	19,84031	2,23221
	1 адаптивни	81	23,9136	13,00980	1,44553

Табела 30: Независни тест узорака

		Levene's Test for Equality of Variances		t-test for Equality of Means						
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	95% Confidence Interval of the Difference	
									Lower	Upper
Број логовања	Equal variances assumed	17,658	0,000	4,754	158	0,000	12,58009	2,64608	7,35384	17,80635
	Equal variances not assumed			4,730	134,137	0,000	12,58009	2,65938	7,32034	17,83984

Коментар: Разлика средњих вредности броја логовања између студената који су похађали традиционални и студената који су похађали адаптивни eLearning курс је статистички значајна ($p < 0,0005$). Средња вредност броја логовања студената који су радили на традиционалан начин је $36,49 \pm 19,84$ а студената који су радили на прилагођен начин је $23,91 \pm 13,01$.

Студенти који су радили на традиционалан начин више су времена провели на курсу, више пута су се логовали, а добили су мање оцене од студената који су похађали адаптивни курс.

Предзнање

Желимо да утврдимо релацију вредности *Време на курсу* и нивоа *Предзнања*.

Табела 31: Статистика теста

	време на курсу
Chi-Square	12,735
df	2
Asymp. Sig.	0,002

a. Kruskal Wallis Test

b. Grouping Variable: предзнање

Табела 32: Дескриптивна анализа *времена на курсу по нивоима предзнања*

	N	Mean	Std. Deviation	Std. Error	95% Confidence Interval for Mean		Minimum	Maximum
					Lower Bound	Upper Bound		
1 почетник	90	41,1444	20,47501	2,15826	36,8560	45,4329	0,00	69,00
2 просечни	64	38,8906	15,78136	1,97267	34,9486	42,8327	0,00	57,00
3 напредни	6	17,1667	18,81932	7,68295	-2,5830	36,9163	0,00	35,00
Total	160	39,3438	19,10384	1,51029	36,3609	42,3266	0,00	69,00

Табела 33: ANOVA тест за *време на курсу у односу на ниво предзнања*

	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	3255,904	2	1627,952	4,666	0,011
Within Groups	54772,190	157	348,867		
Total	58028,094	159			

Коментар: Разлике средњих вредности времена проведеног на курсу између почетника, просечних и напредних су статистички значајне ($p = 0,011$).

Средња вредност времена проведеног на курсу почетника је $41,14 \pm 20,47$.

Средња вредност времена проведеног на курсу просечних је $38,89 \pm 15,78$.

Средња вредност времена проведеног на курсу напредних је $17,17 \pm 18,82$.

Проверавамо релацију вредности *Број логовања* и нивоа *Предзнања*.

Табела 34: Статистика теста

Test Statistics ^{a,b}	
	број логовања
Chi-Square	8,326
df	2
Asymp. Sig.	0,016

a. Kruskal Wallis Test

b. Grouping Variable: предзнање

Табела 35: Дескриптивна анализа броја логовања по нивоима предзнања

Descriptives								
	N	Mean	Std. Deviation	Std. Error	95% Confidence Interval for Mean		Minimum	Maximum
					Lower Bound	Upper Bound		
1 почетник	90	32,6111	20,12863	2,12174	28,3953	36,8270	0,00	67,00
2 просечни	64	28,0938	13,19297	1,64912	24,7982	31,3893	0,00	53,00
3 напредни	6	14,5000	15,89654	6,48974	-2,1824	31,1824	0,00	30,00
Total	160	30,1250	17,83458	1,40995	27,3404	32,9096	0,00	67,00

Табела 36: ANOVA тест за број логовања у односу на ниво предзнања

ANOVA					
	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	2285,174	2	1142,587	3,715	,027
Within Groups	48288,326	157	307,569		
Total	50573,500	159			

Коментар: Разлике средњих вредности броја логовања између почетника, просечних и напредних су статистички значајне ($p = 0,027$).

Средња вредност броја логовања почетника је $32,61 \pm 20,13$.

Средња вредност броја логовања просечних је $28,09 \pm 13,19$.

Средња вредност броја логовања напредних је $14,50 \pm 15,90$.

Проверавамо релацију вредности *Оцена* и нивоа *Предзнања*.

Табела 37: Статистика теста

Test Statistics ^{a,b}	
	Оцена
Chi-Square	45,709
df	2
Asymp. Sig.	0,000

a. Kruskal Wallis Test

b. Grouping Variable: предзнање

Табела 38: Дескриптивна анализа *оцене* по нивоима *предзнања*

Descriptives								
	N	Mean	Std. Deviation	Std. Error	95% Confidence Interval for Mean		Minimum	Maximum
					Lower Bound	Upper Bound		
1 почетник	90	6,1111	0,98807	0,10415	5,9042	6,3181	5,00	8,00
2 просечни	64	7,7813	1,39692	0,17462	7,4323	8,1302	5,00	10,00
3 напредни	6	7,5000	2,73861	1,11803	4,6260	10,3740	5,00	10,00
Total	160	6,8313	1,49305	0,11804	6,5981	7,0644	5,00	10,00

Табела 39: ANOVA тест за *оцену* у односу на ниво *предзнања*

ANOVA					
	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	107,117	2	53,559	33,998	0,000
Within Groups	247,326	157	1,575		
Total	354,444	159			

Коментар: Разлике средњих вредности оцена студената између почетника, просечних и напредних су статистички значајне ($p < 0,0005$).

Средња вредност оцена почетника је $6,11 \pm 0,99$.

Средња вредност оцена просечних је $7,78 \pm 1,40$.

Средња вредност оцена напредних је $7,50 \pm 2,74$.

Стил учења

Желимо да утврдимо релацију вредности *Време на курсу* и *Стила учења*.

Табела 40: Статистика теста

Test Statistics ^{a,b}	
	време на курсу
Chi-Square	0,420
df	2
Asymp. Sig.	0,811

a. Kruskal Wallis Test

b. Grouping Variable: стил учења

Табела 41: Дескриптивна анализа времена на курсу по стиловима учења

Descriptives								
	N	Mean	Std. Deviation	Std. Error	95% Confidence Interval for Mean		Minimum	Maximum
					Lower Bound	Upper Bound		
1 ВСА	54	40,4444	19,52518	2,65704	35,1151	45,7738	0,00	69,00
2 ИАГ	19	38,2105	17,02475	3,90575	30,0049	46,4162	4,00	58,00
3 ВАС	87	38,9080	19,43961	2,08414	34,7649	43,0512	0,00	63,00
Total	160	39,3438	19,10384	1,51029	36,3609	42,3266	0,00	69,00

Табела 42: ANOVA тест за време на курсу у односу на стил учења

ANOVA					
	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	106,338	2	53,169	0,144	0,866
Within Groups	57921,756	157	368,928		
Total	58028,094	159			

Коментар: Разлике средњих вредности времена проведеног на курсу између стилова учења нису статистички значајне ($p = 0,866$).

Утврђујемо релацију вредности *Број логовања* и *Стила учења*.

Табела 43: Статистика теста

Test Statistics ^{a,b}	
	број логовања
Chi-Square	0,174
df	2
Asymp. Sig.	0,917

a. Kruskal Wallis Test

b. Grouping Variable: стил учења

Табела 44: Дескриптивна анализа броја логовања по стиловима учења

Descriptives								
	N	Mean	Std. Deviation	Std. Error	95% Confidence Interval for Mean		Minimum	Maximum
					Lower Bound	Upper Bound		
1 ВСА	54	30,9630	18,17832	2,47376	26,0012	35,9247	0,00	67,00
2 ИАГ	19	29,4737	16,34139	3,74897	21,5974	37,3500	2,00	51,00
3 ВАС	87	29,7471	18,10642	1,94121	25,8881	33,6061	0,00	66,00
Total	160	30,1250	17,83458	1,40995	27,3404	32,9096	0,00	67,00

Табела 45: ANOVA тест за број логовања у односу на стил учења

ANOVA					
	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	58,400	2	29,200	0,091	0,913
Within Groups	50515,100	157	321,752		
Total	50573,500	159			

Коментар: Разлике средњих вредности број логовања између типова учења нису статистички значајне ($p = 0,913$).

Проверавамо релацију вредности *Оцена* и *Стила учења*.

Табела 46: Статистика теста

Test Statistics ^{a,b}	
	Оцена
Chi-Square	7,561
df	2
Asymp. Sig.	0,023

a. Kruskal Wallis Test

b. Grouping Variable: стил учења

Табела 47: Дескриптивна анализа оцене по стилевима учења

	N	Mean	Std. Deviation	Std. Error	95% Confidence Interval for Mean		Minimum	Maximum
					Lower Bound	Upper Bound		
					1 ВСА	54		
2 ИАГ	19	7,6316	1,49854	0,34379	6,9093	8,3539	5,00	10,00
3 ВАС	87	6,6092	1,46554	0,15712	6,2968	6,9215	5,00	10,00
Total	160	6,8313	1,49305	0,11804	6,5981	7,0644	5,00	10,00

Табела 48: ANOVA тест за оцену у односу на стил учења

ANOVA					
	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	16,773	2	8,387	3,899	0,022
Within Groups	337,671	157	2,151		
Total	354,444	159			

Табела 49: Мултипла компарација

Multiple Comparisons

Bonferroni

(I) Стил учења	(J) Стил учења	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval	
					Lower Bound	Upper Bound
1 ВСА	2 ИАГ	-0,72417	0,39119	0,198	-1,6708	0,2225
	3 ВАС	0,29821	0,25407	0,727	-0,3166	0,9130
2 ИАГ	1 ВСА	0,72417	0,39119	0,198	-0,2225	1,6708
	3 ВАС	1,02238*	0,37138	0,020	0,1237	1,9211
3 ВАС	1 ВСА	-0,29821	0,25407	0,727	-0,9130	0,3166
	2 ИАГ	-1,02238*	0,37138	0,020	-1,9211	-0,1237

*. The mean difference is significant at the 0.05 level.

Коментар: Разлике средњих вредности оцена студената између ВСА, ИАГ и ВАС стила учења, су статистички значајне ($p = 0,022$).

Средња вредност ВСА је $6,91 \pm 1,46$

Средња вредност ИАГ је $7,63 \pm 1,50$

Средња вредност оцена ВАС је $6,61 \pm 1,47$.

Најбоље резултате су постигли студенти са ИАГ стилем учења.

Припадни кластер/група

Проверавамо релацију вредности *Припадни кластер* и *Оцена*.

Табела 50: Статистика теста

Test Statistics ^{a,b}	
	Оцена
Chi-Square	65,877
df	8
Asymp. Sig.	0,000

a. Kruskal Wallis Test

b. Grouping Variable: припадни кластер

Табела 51: Дескриптивна анализа оцено по припадном кластеру

Descriptives								
	N	Mean	Std. Deviation	Std. Error	95% Confidence Interval for Mean		Minimum	Maximum
					Lower Bound	Upper Bound		
1-1	27	6,2593	1,02254	0,19679	5,8548	6,6638	5,00	8,00
1-2	11	7,2727	0,78625	0,23706	6,7445	7,8009	6,00	8,00
1-3	52	5,7885	0,80041	0,11100	5,5656	6,0113	5,00	8,00
2-1	23	7,6087	1,37309	0,28631	7,0149	8,2025	5,00	10,00
2-2	7	7,7143	1,97605	0,74688	5,8867	9,5418	5,00	10,00
2-3	34	7,9118	1,31120	0,22487	7,4543	8,3693	5,00	10,00
3-1	3	6,6667	2,88675	1,66667	-0,5044	13,8378	5,00	10,00
3-2	2	10,0000	0,00000	0,00000	10,0000	10,0000	10,00	10,00
3-3	1	5,0000	5,00	5,00
Total	160	6,8313	1,49305	0,11804	6,5981	7,0644	5,00	10,00

Табела 52: ANOVA тест за оцено у односу на припадни кластер

ANOVA					
	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	150,095	8	18,762	13,864	,000
Within Groups	204,349	151	1,353		
Total	354,444	159			

Коментар: Разлике средњих вредности оцена студената између припадних група/кластера су статистички значајне ($p = 0,022$). Најбољу средњу оцено имају студенти из кластера 2-3 ($7,91 \pm 1,31$), а најмању из кластера 1-3 ($5,79 \pm 0,80$). Остале вредности средње оцено за припадне кластере (групе студената) су: кластер 1-1 ($6,25 \pm 1,02$); кластер 1-2 ($7,27 \pm 0,79$); кластер 2-1 ($7,61 \pm 1,37$); кластер 2-2 ($7,71 \pm 1,97$); кластер 3-1 ($6,67 \pm 2,89$); кластер 3-2 (10,00); кластер 3-3 (5,00). Кластери 3-1, 3-2 и 3-3 имају сувише мали број студената.

Позитивна оцена

Утврђује се релација вредности *Позитивна оцена* и *Курс*.

Табела 53: Фреквенција *позитивне оцене*

		Позитивна оцена			
		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	0 негативна оцена	38	23,8	23,8	23,8
	1 позитивна оцена	122	76,3	76,3	100,0
	Total	160	100,0	100,0	

Табела 54: Унакрсна анализа/табела непредвиђених случајева података о *врсти курса* и *добивању позитивне/негативне оцене*

		Crosstab			
		Позитивна оцена		Total	
		0 негативна оцена	1 позитивна оцена		
курс	1 адаптивни	Count	15	66	81
		% within курс	18,5%	81,5%	100,0%
	2 традиционални	Count	23	56	79
		% within курс	29,1%	70,9%	100,0%
Total		Count	38	122	160
		% within курс	23,8%	76,3%	100,0%

Табела 55: Хи-квадрат тестови

Chi-Square Tests					
	Value	df	Asymp. Sig. (2-sided)	Exact Sig. (2-sided)	Exact Sig. (1-sided)
Pearson Chi-Square	2,479 ^a	1	0,115		
Continuity Correction ^b	1,929	1	0,165		
Likelihood Ratio	2,492	1	0,114		
Fisher's Exact Test				0,138	0,082
Linear-by-Linear Association	2,464	1	0,116		
N of Valid Cases	160				

a. 0 cells (,0%) have expected count less than 5. The minimum expected count is 18,76.

b. Computed only for a 2x2 table

Коментар: Врста курса и позитивна оцена нису повезани ($p = 0,165$).

Табела 56: Унакрсна анализа/табела непредвиђених случајева података о времену на курсу и добијању позитивне/негативне оцене

Crosstab

		Позитивна оцена		Total	
		0 негативна оцена	1 позитивна оцена		
време 0_1_2	0 време 0-30 сати	Count	23	7	30
		% within време 0_1_2	76,7%	23,3%	100,0%
	1 време >= 30 сати	Count	3	60	63
		% within време 0_1_2	4,8%	95,2%	100,0%
	2 време > 30 сати	Count	12	55	67
		% within време 0_1_2	17,9%	82,1%	100,0%
Total	Count	38	122	160	
	% within време 0_1_2	23,8%	76,3%	100,0%	

Табела 57: Хи-квадрат тестови

Chi-Square Tests

	Value	df	Asymp. Sig. (2-sided)
Pearson Chi-Square	60,192 ^a	2	0,000
Likelihood Ratio	55,715	2	0,000
Linear-by-Linear Association	24,293	1	0,000
N of Valid Cases	160		

a. 0 cells (,0%) have expected count less than 5. The minimum expected count is 7,13.

Коментар: Категорија времена проведеног на курсу (до 30, 30 - 50, преко 50 минута) и позитивна оцена су повезани ($p < 0,0005$). Видети проценте (најмањи проценат позитивних оцена 23,3% имају они студенти који су провели на курсу мање од 30 сати).

Табела 58: Унакрсна анализа/табела непредвиђених случајева података о броју логовања и добијању позитивне/негативне оцене

Crosstab

		Позитивна оцена		Total	
		0 негативна оцена	1 позитивна оцена		
број логовања 0_1_2	0	Count	23	7	30
		% within број логовања 0_1_2	76,7%	23,3%	100,0%
	1	Count	3	68	71
		% within број логовања 0_1_2	4,2%	95,8%	100,0%
	2	Count	12	47	59
		% within број логовања 0_1_2	20,3%	79,7%	100,0%
Total		Count	38	122	160
		% within број логовања 0_1_2	23,8%	76,3%	100,0%

Табела 59: Хи-квадрат тестови

Chi-Square Tests

	Value	df	Asymp. Sig. (2-sided)
Pearson Chi-Square	61,713 ^a	2	0,000
Likelihood Ratio	58,368	2	0,000
Linear-by-Linear Association	20,966	1	0,000
N of Valid Cases	160		

a. 0 cells (,0%) have expected count less than 5. The minimum expected count is 7,13.

Коментар: Категорија броја логовања (до 15, 15 - 40, преко 40 пута) и позитивна оцена су повезани ($p < 0,0005$). Видети проценте.

Табела 60: Унакрсна анализа/табела непредвиђених случајева података о *стилу учења* и *добијању позитивне/негативне оцене*

Crosstab

		Позитивна оцена		Total	
		0 негативна оцена	1 позитивна оцена		
Стил учења	1 ВСА	Count	12	42	54
		% within Стил учења	22,2%	77,8%	100,0%
	2 ИАГ	Count	1	18	19
		% within Стил учења	5,3%	94,7%	100,0%
	3 ВАС	Count	25	62	87
		% within Стил учења	28,7%	71,3%	100,0%
Total	Count	38	122	160	
	% within Стил учења	23,8%	76,3%	100,0%	

Табела 61: Хи-квадрат тестови

Chi-Square Tests

	Value	df	Asymp. Sig. (2-sided)
Pearson Chi-Square	4,849 ^a	2	0,089
Likelihood Ratio	6,015	2	0,049
Linear-by-Linear Association	1,090	1	0,297
N of Valid Cases	160		

a. 1 cells (16,7%) have expected count less than 5. The minimum expected count is 4,51.

Коментар: Тип учења и позитивна оцена нису повезани ($p = 0,089$), али је ова веза индикативна (близу статистичке значајности). Видети проценте.

Табела 62: Унакрсна анализа/табела непредвиђених случајева података о нивоу предзнања и добијању позитивне/негативне оцене

Crosstab

		Позитивна оцена		Total	
		0 негативна оцена	1 позитивна оцена		
Предзнање	1 почетник	Count	61	29	90
		% within Предзнање	67,8%	32,2%	100,0%
	2 просечни	Count	58	6	64
		% within Предзнање	90,6%	9,4%	100,0%
	3 напредни	Count	3	3	6
		% within Предзнање	50,0%	50,0%	100,0%
Total		Count	122	38	160
		% within Предзнање	76,3%	23,8%	100,0%

Табела 63: Хи-квадрат тестови

Chi-Square Tests

	Value	df	Asymp. Sig. (2-sided)
Pearson Chi-Square	5,563 ^a	4	0,234
Likelihood Ratio	5,347	4	0,253
Linear-by-Linear Association	2,137	1	0,144
N of Valid Cases	160		

a. 3 cells (33,3%) have expected count less than 5. The minimum expected count is ,71.

Коментар: Предзнање и позитивна оцена нису повезани ($p = 0,234$).

Табела 64: Унакрсна анализа/табела непредвиђених случајева података о нивоу предзнања и стилу учења

Crosstab

		Стил учења			Total	
		1 ВСА	2 ИАГ	3 ВАС		
Предзнање	1 почетник	Count	27	11	52	90
		% within Предзнање	30,0%	12,2%	57,8%	100,0%
	2 просечни	Count	24	6	34	64
		% within Предзнање	37,5%	9,4%	53,1%	100,0%
	3 напредни	Count	3	2	1	6
		% within Предзнање	50,0%	33,3%	16,7%	100,0%
	Total	Count	54	19	87	160
		% within Предзнање	33,8%	11,9%	54,4%	100,0%

Уводи се варијабла „почетник“

Табела 65: Фреквенција варијабле почетник

		Почетник			
		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	0 није почетник	70	43,8	43,8	43,8
	1 почетник	90	56,3	56,3	100,0
Total		160	100,0	100,0	

Табела 66: Унакрсна анализа/табела непредвиђених случајева података почетник и позитивна оцена

Почетник * позитивна оцена Crosstabulation					
		Позитивна оцена		Total	
		0 негативна оцена	1 позитивна оцена		
Почетник	0 није почетник	Count	9	61	70
		% within Почетник	12,9%	87,1%	100,0%
	1 почетник	Count	29	61	90
		% within Почетник	32,2%	67,8%	100,0%
Total		Count	38	122	160
		% within Почетник	23,8%	76,3%	100,0%

Табела 67: Хи-квадрат тестови

Chi-Square Tests					
	Value	df	Asymp. Sig. (2-sided)	Exact Sig. (2-sided)	Exact Sig. (1-sided)
Pearson Chi-Square	8,154 ^a	1	0,004		
Continuity Correction ^b	7,119	1	0,008		
Likelihood Ratio	8,569	1	0,003		
Fisher's Exact Test				0,005	0,003
Linear-by-Linear Association	8,103	1	0,004		
N of Valid Cases	160				

a. 0 cells (,0%) have expected count less than 5. The minimum expected count is 16,63.

b. Computed only for a 2x2 table

Коментар: Искуство (почетник и није почетник) и позитивна оцена су повезани ($p = 0,008$). Процент позитивних оцена код почетника је 67,8% а код осталих је 87,1%.

Табела 68: Унакрсна анализа/табела непредвиђених случајева података курс и позитивна оцена

Адаптивни курс * позитивна оцена Crosstabulation

		Позитивна оцена		Total	
		0 негативна оцена	1 позитивна оцена		
Адаптивни курс	0 није адаптивни	Count	23	59	82
		% within Адаптивни курс	28,0%	72,0%	100,0%
	1 адаптивни	Count	15	63	78
		% within Адаптивни курс	19,2%	80,8%	100,0%
Total		Count	38	122	160
		% within Адаптивни курс	23,8%	76,3%	100,0%

Табела 69: Хи-квадрат тестови

Chi-Square Tests

	Value	df	Asymp. Sig. (2-sided)	Exact Sig. (2-sided)	Exact Sig. (1-sided)
Pearson Chi-Square	1,716 ^a	1	0,190		
Continuity Correction ^b	1,264	1	0,261		
Likelihood Ratio	1,728	1	0,189		
Fisher's Exact Test				0,200	0,130
Linear-by-Linear Association	1,706	1	0,192		
N of Valid Cases	160				

a. 0 cells (0%) have expected count less than 5. The minimum expected count is 18,53.

b. Computed only for a 2x2 table

Коментар: Прилагођеност курса и позитивна оцена нису повезани ($p = 0,261$).

Табела 70: Корелација времена на курсу, броја логовања и оцене

		Correlations		
		време на курсу	број логовања	оцена
време на курсу	Pearson Correlation	1	0,864**	0,300**
	Sig. (2-tailed)		0,000	0,000
	N	160	160	160
број логовања	Pearson Correlation	0,864**	1	0,194*
	Sig. (2-tailed)	0,000		0,014
	N	160	160	160
оцена	Pearson Correlation	0,300**	0,194*	1
	Sig. (2-tailed)	0,000	0,014	
	N	160	160	160

** . Correlation is significant at the 0.01 level (2-tailed).

* . Correlation is significant at the 0.05 level (2-tailed).

Табела 71: Коefицијент Спирманове ранг корелације времена на курсу, броја логовања и оцене

		Correlations			
		време на курсу	број логовања	оцена	
Spearman's rho	време на курсу	Correlation Coefficient	1,000	0,796**	0,119
		Sig. (2-tailed)	.	0,000	0,135
		N	160	160	160
	број логовања	Correlation Coefficient	0,796**	1,000	0,174*
		Sig. (2-tailed)	0,000	.	0,028
		N	160	160	160
	оцена	Correlation Coefficient	0,119	0,174*	1,000
		Sig. (2-tailed)	0,135	0,028	.
		N	160	160	160

** . Correlation is significant at the 0.01 level (2-tailed).

* . Correlation is significant at the 0.05 level (2-tailed).

Коментар: Број логовања и оцена су у слабој позитивној корелацији ($r = 0,174$, $p = 0,028$).

Табела 72: Статистика теста

	време на курсу
Mann-Whitney U	1472,500
Wilcoxon W	2213,500
Z	-3,393
Asymp. Sig. (2-tailed)	0,001

a. Grouping Variable: Pozitivna_ocena

Табела 73: Групна статистика фактора *време на курсу и позитивна оцена*

	позитивна оцена	N	Mean	Std. Deviation	Std. Error Mean
време на курсу	0 негативна оцена	38	23,1053	27,51392	4,46335
	1 позитивна оцена	122	44,4016	11,81025	1,06925

Табела 74: Независни тест узорака

		Levene's Test for Equality of Variances		t-test for Equality of Means						
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	95% Confidence Interval of the Difference	
									Lower	Upper
време на курсу	Equal variances assumed	130,113	0,000	-6,801	158	0,000	-21,29638	3,13126	-27,48091	-15,11184
	Equal variances not assumed			-4,640	41,327	0,000	-21,29638	4,58964	-30,56311	-12,02965

Коментар: Разлика средњих вредности времена проведеног на курсу између позитивних и негативних оцена је статистички значајна ($p < 0,0005$). Средња вредност времена проведеног на курсу студената који су добили позитивну оцену је $44,40 \pm 27,51$, а студената који су добили негативну оцену је $23,11 \pm 11,81$.

Табела 75: Статистика теста

	број логовања
Mann-Whitney U	1457,500
Wilcoxon W	2198,500
Z	-3,453
Asymp. Sig. (2-tailed)	0,001

a. Grouping Variable: Pozitivna_ocena

Табела 76: Групна статистика фактора број логовања и позитивна оцена

	Позитивна оцена	N	Mean	Std. Deviation	Std. Error Mean
Број логовања	0 негативна оцена	38	19,9737	25,94431	4,20872
	1 позитивна оцена	122	33,2869	13,02666	1,17938

Табела 77: Независни тест узорака

		Levene's Test for Equality of Variances		t-test for Equality of Means						
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	95% Confidence Interval of the Difference	
									Lower	Upper
број логовања	Equal variances assumed	65,658	0,000	-4,226	158	0,000	-13,31320	3,15042	-19,53558	-7,09082
	Equal variances not assumed			-3,046	42,958	0,004	-13,31320	4,37084	-22,12810	-4,49830

Коментар: Разлика средњих вредности броја логовања између позитивних и негативних оцена је статистички значајна ($p < 0,0005$). Средња вредност броја логовања студената који су добили позитивну оцелу је $33,29 \pm 13,03$ а студената који су добили негативну оцелу је $19,97 \pm 25,941$.

Линеарна регресија

Табела 78: Резиме модела

Модел	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	0,750 ^a	0,562	0,551	1,00051
2	0,750 ^b	0,562	0,554	0,99730

a. Predictors: (Constant), почетник, адаптивни курс, време на курсу, број логовања

b. Predictors: (Constant), почетник, адаптивни курс, време на курсу

Табела 79: ANOVA – анализа варијансе

Модел		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	199,284	4	49,821	49,770	0,000 ^a
	Residual	155,159	155	1,001		
	Total	354,444	159			
2	Regression	199,284	3	66,428	66,788	0,000 ^b
	Residual	155,160	156	0,995		
	Total	354,444	159			

Табела 80: Регресија коефицијента (нестандардизована и стандардизована)

Модел		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	5,842	,233		25,048	,000
	време на курсу	,036	,008	,461	4,363	,000
	број логовања	,000	,009	,002	,018	,986
	адаптивни курс	1,122	,166	,377	6,750	,000
	почетник	-1,729	,162	-,576	-10,689	,000
2	(Constant)	5,842	,232		25,135	,000
	време на курсу	,036	,004	,463	8,372	,000
	адаптивни курс	1,122	,164	,376	6,842	,000
	почетник	-1,729	,160	-,576	-10,811	,000

a. Dependent Variable: Ocena

Коментар: Линеарна регресија покажује да оцена зависи од времена проведеног на курсу ($p < 0,0005$), од прилагођености курса ($p < 0,0005$) и од тога да ли је студент почетник ($p < 0,0005$), $R^2 = 0,562$.

Једначина регресионе равни је:

$$\text{Оцена} = 0,036 \cdot (\text{време на курсу}) + 1,122 \cdot (\text{прилагођени курс}) - 1,729 \cdot \text{поčetник} - 1,729.$$

Ово може да послужи за приближно предвиђање оцене будућих студената. Модел је доста добар, јер је $R^2 = 0,562$.

Табела 81: Статистика упарених узорака

Paired Samples Statistics					
		Mean	N	Std. Deviation	Std. Error Mean
Pair 1	оцена	6,8313	160	1,49305	0,11804
	оцена модела	6,8258	160	1,11850	0,08843

Табела 82: Тест упарених узорака

Paired Samples Test									
		Paired Differences					t	df	Sig. (2-tailed)
		Mean	Std. Deviation	Std. Error Mean	95% Confidence Interval of the Difference				
					Lower	Upper			
Pair 1	оцена – оцена модела	0,00548	0,98785	0,07810	-0,14877	0,15972	0,070	159	0,944

Средња вредност оцена студената је 6,8313, а према моделу је 6,8258.

Бинарна логистичка регресија

Табела 83: Класификациона табела – тачност модела

Classification Table^{a,b}

	Observed	Predicted			
		позитивна оцена		Percentage Correct	
		0 негативна оцена	1 позитивна оцена		
Step 0	позитивна оцена	0 негативна оцена	0	38	,0
		1 позитивна оцена	0	122	100,0
	Overall Percentage				76,3

a. Constant is included in the model.

b. The cut value is ,500

Табела 84: Променљиве из једначине

Variables in the Equation

	B	S.E.	Wald	df	Sig.	Exp(B)	95% C.I. for EXP(B)		
							Lower	Upper	
Step 1 ^a	време на курсу	0,127	0,030	18,316	1	0,000	1,135	1,071	1,203
	број логовања	-0,057	0,030	3,711	1	0,054	0,944	0,891	1,001
	стил учења			3,355	2	0,187			
	стил учења(1)	0,198	0,525	0,143	1	0,705	1,220	0,436	3,413
	стил учења(2)	2,341	1,280	3,345	1	0,067	10,394	0,845	127,799
	адаптивни курс	1,229	0,561	4,795	1	0,029	3,416	1,138	10,260
	почетник	-1,816	0,596	9,285	1	0,002	0,163	0,051	,523
	Constant	-1,401	0,736	3,621	1	0,057	0,246		
Step 2 ^a	време на курсу	0,129	0,030	18,313	1	0,000	1,137	1,072	1,206
	број логовања	-0,061	0,030	4,035	1	0,045	0,941	0,886	0,999
	адаптивни курс	1,200	0,545	4,848	1	0,028	3,318	1,141	9,653
	почетник	-1,820	0,587	9,624	1	0,002	0,162	0,051	0,512
	Constant	-1,089	0,661	2,717	1	0,099	0,336		

a. Variable(s) entered on step 1: време на курсу, број логовања, стил учења, адаптивни курс, почетник.

$$\text{Sum} = 0.129^* \text{ време на курсу} - 0.061^* \text{ број логовања} + 1.200^* \text{ адаптивни курс} - 1.820^* \text{ почетник} - 1.089$$

Коментар: Мултиваријантна бинарна логистичка регресија показује да позитивна оцена зависи од временаведеног на курсу ($p < 0,0005$), броја логовања ($p = 0,045$), од прилагођености курса ($p = 0,028$) и од тога да ли је студент почетник ($p = 0,002$).

Количник шансе (odds ratio) за време на курсу је 1,137 (1,072 – 1,206), што значи ако се време проведено на курсу повећа за један сат, шанса да се добије позитивна оцена повећава се за 13,7%.

Количник шансе (odds ratio) за број логовања је 0,941 (0,886 – 0,999), што значи ако се број логовања повећа за један, шанса да се добије позитивна оцена смањује се за 5,9%.

Количник шансе (odds ratio) за прилагођени курс је 3,318 (1,141 – 9,653), што значи ако студент учи по прилагођеном курсу, шанса да се добије позитивна оцена повећава се око три пута.

Количник шансе (odds ratio) за почетника је 0,162 (0,051 – 0,512), што значи ако студент учи по прилагођеном курсу, шанса да се добије позитивна оцена смањује се око 6 пута.

Из предоченог се види да су се студенти са позитивним оценама, у просеку, више логовали. Мултиваријантна бинарна логистичка регресија показује да већи број логовања смањује шансу да се добије позитивна оцена. Можда ово изгледа противуречно. Међутим, код мултиваријантне бинарне логистичке регресије се посматра истовремени утицај варијабли на зависну варијаблу (позитивна оцена), тако да променљива број логовања не делује независно, већ заједно са осталим варијаблама, па је њен утицај различит од онога када делује сама.

Прављење модела

Модел је нова варијабла направљена помоћу мултиваријантне бинарне логистичке регресије. Он је дат помоћу формуле:


$$\text{Model} = 100 \cdot e^{\text{sum}} / (1 + e^{\text{sum}}),$$

где је

$$\text{Sum} = 0.129 * \text{време на курсу} - 0.061 * \text{број логовања} + 1.200 * \text{адаптивни курс} - 1.820 * \text{почетник} - 1.089.$$

Помоћу ROC (receiver operating characteristic) криве може да се види колико је креирани модел добар маркер за раздвајање позитивних и негативних оцена.

Квалитет модела



Diagonal segments are produced by ties.

Слика 64: ROC крива

Табела 85: Резултат теста променљиве: модел

Area Under the Curve
Test Result Variable(s):model

Area	Std. Error ^a	Asymptotic Sig. ^b	Asymptotic 95% Confidence Interval	
			Lower Bound	Upper Bound
0,881	0,035	0,000	0,813	0,948

The test result variable(s): model has at least one tie between the positive actual state group and the negative actual state group. Statistics may be biased.

a. Under the nonparametric assumption

b. Null hypothesis: true area = 0.5

Табела 86: Координате криве

Coordinates of the Curve
Test Result Variable(s):model

Positive if Greater Than or Equal To ^a	Sensitivity	1 - Specificity
4,1710	1,000	1,000
5,3429	1,000	0,895
56,8881	0,951	0,447
76,8791	0,828	0,211
77,3527	0,820	0,211
78,1237	0,820	0,184
78,9147	0,811	0,184
79,5590	0,803	0,184
79,8427	0,795	0,184
99,1124	0,008	0,026
99,5095	0,000	0,026
100,7882	0,000	0,000

Коментар: ROC (receiver operating characteristic) крива показује да је наш модел одличан маркер за раздвајање позитивних и негативних оцена.

Пресечна тачка (cut-off) је 78.

Сензитивност је 0,820, што значи да од студената са позитивном оценом њих 82,0% има вредност нове променљиве (Model) већу од 78.

Специфичност је 0,816, што значи да од студената са негативном оценом њих 81,6% има вредност нове променљиве (Model) мању од 78.

5.2. Развој Data Mining модела за напредну анализу података

Постоји више приступа за истраживање података: Description (дескрипција), Estimation (процена), Clustering (кластеризација), Prediction (предикција), Klassification (класификација), Association (асоцијација), сваки од ових алата користе одређене алгоритме као што су Neural networks (неуронске мреже), Decision trees (стабла одлучивања), Regression (регресија), Bayes algorithms (Бајесови алгоритми), Rule induction (правила индукције), Discriminant analysis (дискриминаторска анализа), Genetic algorithms (генетски алгоритам) и друге (Li & Lin, 2021; Balakrishna & Thirumaran, 2020; Putro & Saepurohman, 2020).

Data Mining се базира на процесу израде модела, који се састоји из следећих корака: дефинисање циља (Define Goal), одабир података (Select Data), припрему података (Prepare Data), одабир и трансформација променљивих (Select and Transform Variables), моделовање процеса (Process Model), валидација модела (Validate Model) и имплементација модела (Implement Model), (Rotondo & Quilligan, 2020).


У циљу надградње адаптивног система за е-учење и генерисање нових информација, знања, скривених шаблона и зависности, развијено је више Data Mining модела. Циљ анализе у овој дисертацији је предвиђање какве оцене студент може да добије (и са којом вероватноћом) у зависности од утицајних променљивих. Зато ће се у раду користити класификација и анализа утицајних параметара. Коришћена је Microsoft-ова платформа за анализу података, а опис алата и алгоритама у овом окружењу су приказали N. Ansari са сарадницима (Ansari, Singh, Trivedi & Nandankar, 2020), Julianto са сарадницима (Julianto, Rohmanto, Sarifudin & Widiyanto, 2021), као и Khan и Ghosh (Khan & Ghosh, 2021) и Shrestha и Pokharel (Shrestha & Pokharel, 2020).

Анализа класификацијом

Класификација открива шаблоне који предвиђају вредности једног атрибута неког објекта базирајући се на вредностима атрибута других објеката (Kadam, 2020). Објекти су представљени колонама у бази података и уобичајено се у истраживању података називају променљивим. Пре него што се приступи истраживању података било којом методом, подаци морају да буду припремљени. У овом окружењу то значи да су подаци у Excel датотеци или Analysis Services упиту. Истраживање података које се заснива на класификацији се састоји у изградњи модела, извршавању класификационог алгоритма и анализе података. Моделирање се састоји у избору атрибута (врсте, променљиве) која се назива *the response, dependent, class* или *target variable* и атрибута (врста, променљивих) које које користимо за предвиђање, а називају се *the predictor* или *independent variables*.

Data Mining приступ ће да предложи независне променљиве које могу да се промене. Избор променљивих је зависан од циља истраживања и познавања особина података који се истражују. Препорука је да се искључе колоне које представљају јединствене идентификаторе и независне шаблоне. Класификациони алгоритми могу да буду Decision Tree, Naïve Bayes и Neural Nets. Microsoft Decision Tree је хибридни и подржава класификацију, регресију и асоцијацију. Излазне информације су стабла одлучивања и мреже зависности (Charbuty & Abdulazeez, 2021).

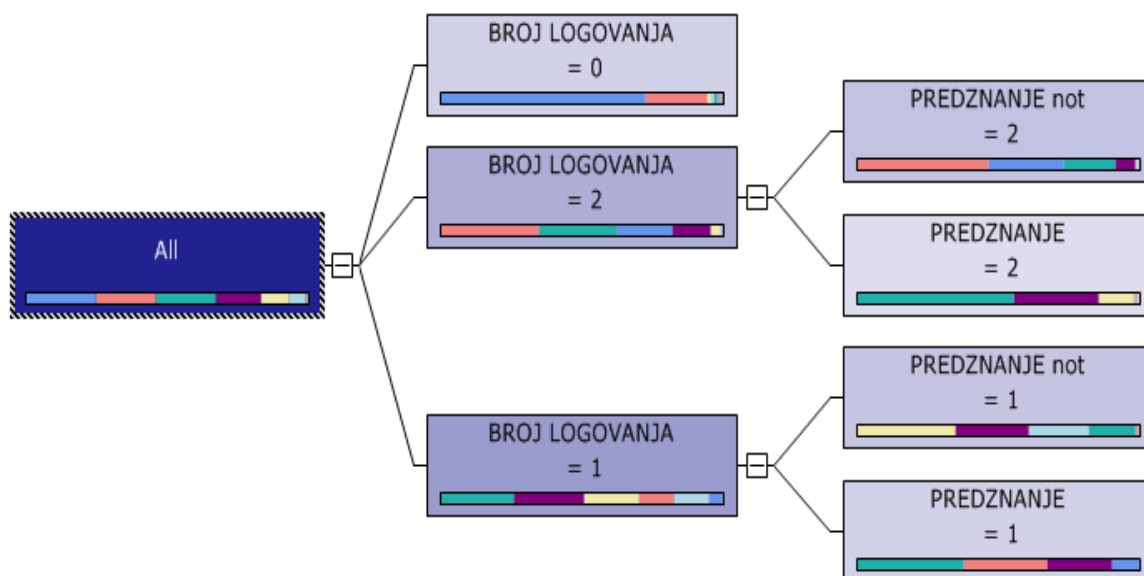
Први модел који је изграђен има за циљ да утврди шаблоне по којима се може извршити предвиђање оцено студента у зависности од: типа курса, броја сати које је студент провео на курсу, броја пријављивања студента на курс, предзнања студента, стила учења који је студент упражњавао и припадног кластера/групе студента. У презентовааном узорку *оцена ученика* је циљна променљива, а остале променљиве су независно променљиве. У истраживање су укључени сви студенти, рачунајући и оне који нису учествовали ни на једном курсу. На слици 65 је приказана мрежа зависности за модел **M1**(курс, број пријављивања - логовања, време проведено на курсу, предзнање, припадни кластер, стил учења, *оцена*).



Слика 65: Мрежа зависности за оцену студента за модел **M1**

Мрежа зависности приказује везе циљне променљиве са независно променљивима за које је откривен шаблон зависности. Стабла одлучивања се састоје од чворова и грана (branches). Чвор на највишем нивоу у хијерархији стабла се назива root node, а на најнижем нивоу leaf node. Између ових чворова су intermediate (internal) node. У сваком чвору је дефинисано правило. Од резултата тестирања променљиве у односу на правило су дефинисана гранања.

На слици 66 је приказано стабло одлучивања за оцену студента. Појединачне оцене на стаблима одлучивања су су представљене на следећи начин: 5 – плава, 6 – црвена, 7 – зелена, 8 – бордо, 9 – жута, 10 – бледо плава. *Број логовања* (bl) је кодиран на следећи начин: 0 – премало (≤ 15), 1 – оптималан (15-40); пуно (>40 сати). *Предзнање* (pr) је кодирано на следећи начин: 1 – почетник; 2 – просечно предзнање; 3 – напредни ниво предзнања.



Слика 66: Стабло одлучивања за оцену студента за модел M1


У кореном чвору (All) су приказане вероватноће оцена свих студената, независно од било ког правила или услова. У свим осталим чворовима су приказане вероватноће у зависности од правила за одговарајући чвор. У табели 87 су приказане вероватноће оцене за све услове зависних променљивих.

Табела 87: Вероватноће оцена у стаблу одлучивања за модел M1

оцена	All	bl = 0	bl = 2	bl = 1	bl=2 and pr not=2	bl=2 and pr = 2	bl not=2 and pr not=1	pr = 1 and pr =1
5	22,89	69,33	19,95	4,76	27,02	0,84	0,97	10,14
6	21,75	22,27	32,65	12,76	44,41	0,84	0,97	29,49
7	21,19	1,68	27,89	24,76	18,32	53,78	16,88	35,94
8	16,07	1,68	13,61	24,76	7,45	30,25	25,97	23,04
9	10,39	1,68	4,08	19,43	0,93	12,61	32,79	0,46
10	6,41	1,68	0,91	12,76	0,93	0,84	21,43	0,46

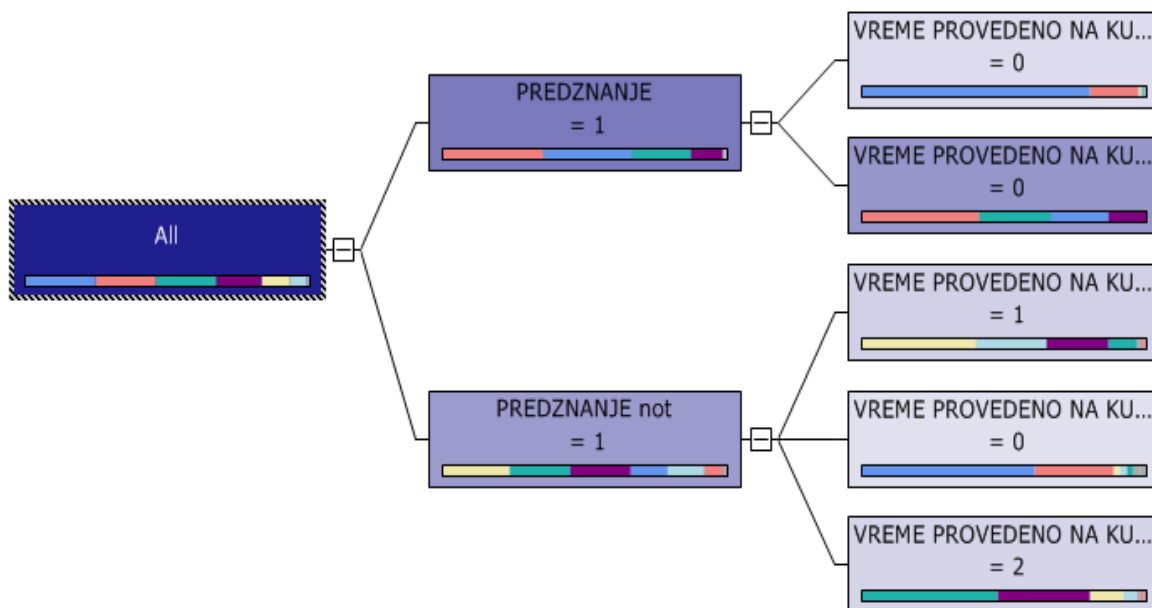
У односу на број пријављивања, највећа вероватноћа да ће студенти постићи добре резултате је за оне са оптималним број пријављивања на курс, затим са пуно пријављивања и на крају са премало пријављивања. У случају премалог броја пријављивања не постоји даље гранање, односно даље функционалне везе. За студенте који, практично, нису ни учествовали на курсу, не може се ни говорити о значајнијем утицају других променљивих. За пуно пријављивања на курс постоји велика вероватноћа да ће студенти са успехом да положи испит (78,43%). За ове студенте успех зависи и од предзнања, при чему се од осталих студената разликују студенти са напредним нивоом предзнања. За студенте са напредним нивоом предзнањем знатно је већа вероватноћа да ће да положи испит и да, при том, постигну више оцене. За просечан број пријављивања, такође, је утицајно предзнање, при чему се разликује почетни ниво предзнања, у односу на остале нивое предзнања. Значајно бољи ниво успеха постићи ће студенти са просечним и напредним нивоом предзнања.

С обзиром да број пријављивања на курс не одговара у потпуности времену проведеном на курсу, следећи модел је развијен без променљиве број логовања. На слици 67 је приказана одговарајућа мрежа зависности за модел **M2** (курс, време проведено на курсу, предзнање, припадни кластер, стил учења, *оцена*).



Слика 67: Мрежа зависности за оцену студента за модел **M2**

Одговарајуће стабло одлучивања за оцену студента за модел **M2** је приказано на слици 68. Види се да је да су утицајне променљиве, такође, *време проведено на курсу* и *предзнање*. Сада је примарна променљива *предзнање*. *Време проведено на курсу* (*vr*) је кодирано према броју часова проведених на курсу на следећи начин: 0 – недовољно (≤ 30); 1 – оптимално (30-50) и 2 – пуно (> 50).



Слика 68: : Стабло одлучивања за оцену студента за модел **M2**

У табели 88 су приказане вероватноће појединачних оцена по чворовима.

Табела 88: Вероватноће оцена у стаблу одлучивања за модел М2

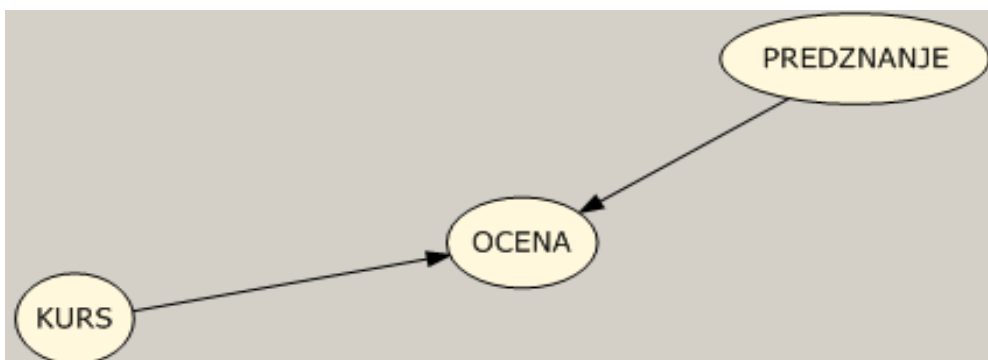
оцена	All	pr=1	pr not=1	pr=1 and vr=0	pr=1 and vr not = 0	pr not=1 and vr=1	pr not=1 and vr=0	pr not=1 and vr=2
5	22,89	31,46	13,07	78,57	20,30	1,26	58,93	1,48
6	21,75	34,65	6,97	17,46	38,72	1,26	27,68	1,48
7	21,19	20,82	21,60	0,79	25,56	10,08	2,68	46,31
8	16,07	11,25	21,60	0,79	13,72	21,85	2,68	32,51
9	10,39	0,61	21,60	0,79	0,56	39,50	2,68	11,82
10	6,41	0,61	13,07	0,79	0,56	24,79	2,68	4,93

Први услов који је класификациони алгоритам препознао јесте *предзнање*, при чему се прави разлика између почетника и студената са одређеним нивоом предзнања. Скоро сваки трећи студент са почетним нивоом предзнања неће положити испит (вероватноћа 31,46%). А, ако такав студент ипак положи испит, то ће највероватније бити оцене 6 или 7 (вероватноћа 55,47%). Студенти са почетним нивоом предзнања и који су према ло времена провели на курсу, углавном неће положити испит (вероватноћа 75,57%). А, ако га и положи, то ће сигурно бити са оценом шест. Ако су студенти из ове групе проводили оптимално или пуно времена на курсу, њихове шансе да положи испит се знатно повећавају (вероватноћа 79,70%), при чему би сваки четврти студент добио оцену седам (25,56%).

Студенти са одређеним нивоом предзнања (pr=2 или 3) ће са великом вероватноћом да положи испит (86,93%) и то са подједнаким вероватноћама да добију оцене 7, 8 или 9. Вероватноћа да ће они добити оцену 10 (13,07%) је иста као вероватноћа да неће положити испит, а већа него вероватноћа да добију оцену 6 (6,97%). Студенти из ове групе, такође са значајном вероватноћом (58,93%) неће положити испит, мада је њихова пролазност боља од студената који немају никакво предзнање. Ови студенти не могу да очекују оцене више од шестике. Студенти из ове групе са оптималним временом проведеним на курсу ће скоро сигурно да положи испит са оценом већом од 6, при чему ће сваки четврти да добије оцену 10, а преко половине ће добити или деветку или десетку. Према томе, студенти из ове групе могу да очекују најбоље резултате.


Студенти који су проводили пуно времена на курсу ће скоро сигурно положити испит и највероватније ће да добију оцену 7 (вероватноћа 46,31%).

У циљу анализе утицаја осталих променљивих креирани су следећи модели. Као први од њих развијен је модел **М3**, у коме је поред *оцене* као циљне (зависне) променљиве још и *курс*, *предзнање*, *стил учења* и *припадајући кластер*. Истраживање је, такође, спроведено на комплетном узорку. Класификациони алгоритам је идентификовао зависност успеха од *предзнања* и *врсте курса* (слика 69).



Слика 69: Мрежа зависности оцене студента за модел М3

За овај модел, одговарајуће стабло одлучивања је приказано на слици 70. Види се да је, поред предзнања, као утицајна променљива идентификована и *врста курса*. Курс је кодиран на следећи начин: 1 – адаптивни e-Learning kurs; 2 - традиционални e-Learning курс.



Слика 70: Стабло одлучивања за оцмену студента за модел М2

Види се, да у случају почетног нивоа предзнања, нема даљих зависности. Може се закључити да ефекти организовања курса имају смисла само код већ припремљених студената, са неким одговарајућим нивоом предзнања.

Вероватноће појављивања појединачних оцена по чворовима су приказани у табели 89.

Табела 89: Вероватноће оцена у стаблу одлучивања за модел М3

оцена	All	pred=1	pred not=1	pred not=1 and kurs not=2	pred not=1 and kurs=2
5	22,89	25,68	8,72	13,96	1,73
6	21,75	36,39	6,12	9,42	1,73
7	21,19	23,30	23,01	4,87	47,19
8	16,07	12,59	23,01	16,23	32,03
9	10,39	0,68	23,01	32,14	10,82
10	1,30	0,68	13,91	20,78	4,76

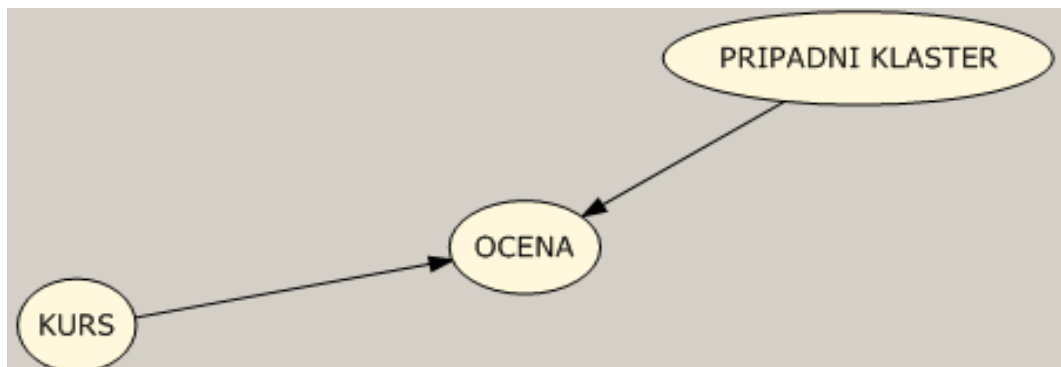
Види се, на пример, да сваки четврти студент почетник (са почетним нивоом предзнања) неће положити испит и да ће, ако положи (са вероватноћом 36,39%) то бити оцена шест.

Студент, који има ниво предзнања изнад почетног, ће са великом вероватноћом положити испит (91,28%) и то ће, са вероватноћом 69,03%, бити оцена од 7 – 9.

Студенти, који су били на традиционалном е-Learning курсу, су постигли задовољавајуће резултате. Студент који учествује на овом курсу, са нивоом предзнања изнад почетног, ће сигурно положити испит (вероватноћа 100%) и врло вероватно да ће добити оцену 7 (47,19%), али и оцене 8 (32,03%) и оцена 9 (10,82%) су такође вероватне.

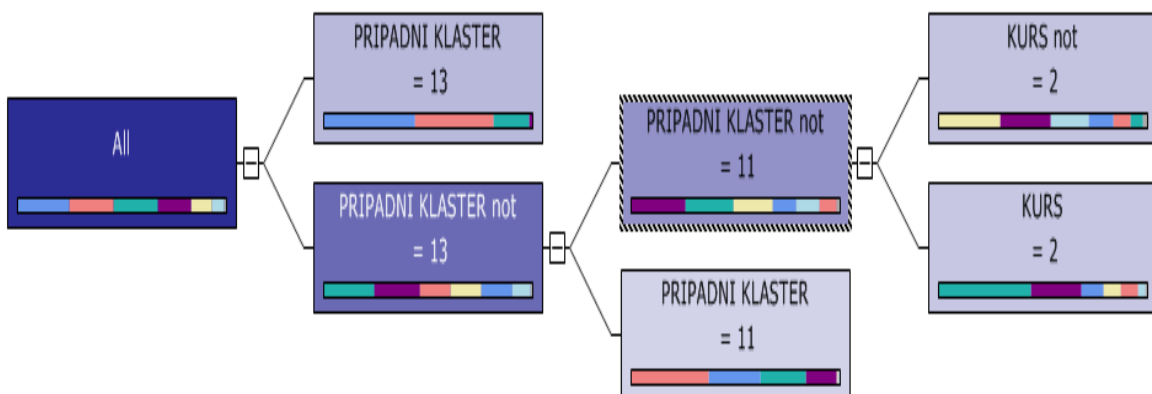
Ипак, њихови резултати су слабији у односу на студенте који су били на прилагођеном (адаптивном/персонализованом) курсу. Студент, који учествује на овом курсу и који није почетник, ће највероватније добити оцену 9 (32,14%), а затим оцену 10 (20,78%). Постоји и вероватноћа (13,96%) да студент са овим карактеристикама не положи испит. Разлог је недовољан број часова присуства ових студената на курсу.

Следећи модел **М4** (курс, припадни кластер, стил учења, **оцена**) представља подваријанту модела М3 и креиран је са циљем да се утврди евентуална утицајност *припадајућег кластера*. На слици 71 је приказана мрежа зависности за овај модел.



Слика 71: Мрежа зависности оцене студента за модел М4

Види се да је зависност слична као у претходном моделу. Сада је предзнање замењено припадном кластеру. Одговарајућа мрежа зависности је приказана на следећој слици.



Слика 72: Стабло одлучивања за оцену студента за модел М4

Стабло одлучивања има четири нивоа и омогућава детаљнију анализу утицаја предзнања, односно припадајућег кластера. Одговарајуће вероватноће у чворовима су приказане у табели 90.

Табела 90: Вероватноће оцена у стаблу одлучивања за модел М4

оцена	All	pk=13	pk not=13	pk not=13 and pk not=11	pk not=13 and pk =11	pk not=13 and pk not=11 and kurs not=2	pk not=13 and pk not=11 and kurs=2
5	22,89	41,47	14,75	11,54	25,27	2,31	10,65
6	21,75	37,74	14,75	8,35	35,76	8,35	8,34
7	21,19	17,22	22,92	23,27	21,78	6,37	43,01
8	16,07	2,29	22,11	24,34	14,79	24,18	24,52
9	10,39	0,43	14,75	19,01	0,80	28,14	8,34
10	6,41	0,43	9,03	11,54	0,80	18,24	3,72

Класификациона анализа је на првом нивоу издвојила припадни кластер 13 (кластер/група студената 1-3; почетни ниво предзнања и стил учења ВАС – вербално/ активно/секвенцијални). Студенти који припадају овом кластеру са великом вероватноћом (41,47%) неће положити испит. А, ако га положи, највероватније ће то бити оцена шест (37,74%).

Студенти свих осталих кластера у просеку ће имати боље резултате, боље од целе популације. Сваки четврти студент са припадним кластером 11 (кластер/група студената 1-1; почетни ниво предзнања и стил учења ВСА – визуелно/секвенцијално/активни) неће положити испит, а ако и положи, то ће бити највероватније оцена 6 (35,76%), затим оцена 7 (21,78%) и, најмање вероватно, оцена 8 (14,79%).

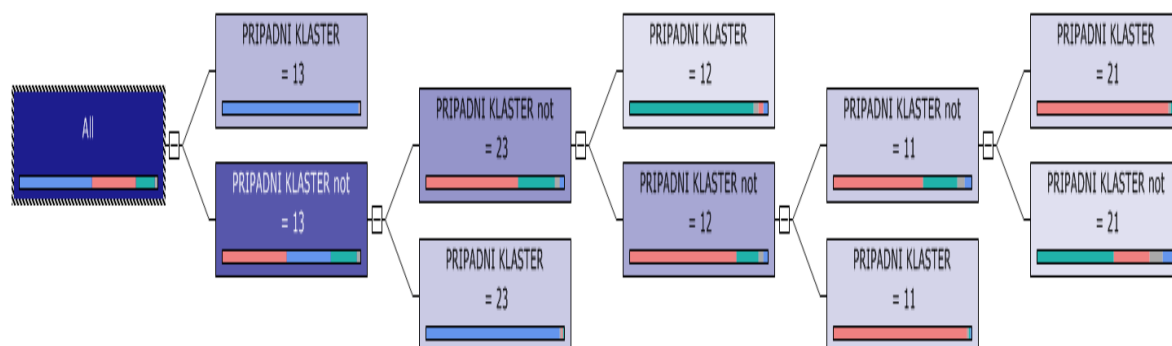
Студенти који не припадају ни кластеру 13, ни кластеру 11, ће имати задовољавајуће резултате. Приближно сваки други ће добити оцену 7 или оцену 8, а приближно сваки пети оцену 9. Студенти из ове групе (81 студент целе популације), а који су похађали прилагођени курс, ће вероватно имати боље резултате него студенти на традиционалном е-Learning курсу. Вероватноћа да студент на прилагођеном курсу неће положити испит је око пет пута мања у односу на студенте на традиционалном курсу. Посебно, вероватноћа да ће добити оцене 9 и 10, такође је приближно пет пута већа код студената на адаптивном курсу. Студенти на традиционалном е-Learning курсу ће углавном добити оцену седам (вероватноћа 43,01%).

Класификацијом није откривена никаква зависност успеха студената од стила учења. Зато је учињен покушај да се открије да ли постоји зависност (и са каквим особинама) стила учења од осталих променљивих. Зато је формиран модел М5 (курс, број логовања, време проведено на курсу, предзнање, припадни кластер, стил учења, оцена). На доњој слици је приказана мрежа зависности овог модела.



Слика 73: Мрежа зависности стила учења за модел М5

Стил учења је кодиран на следећи начин: 1 – визуелно/секвенцијално/активни; 2 – интуитивно/активни/глобални; 3 – вербално/активни/секвенцијални. Утврђена је зависност стила учења само од припадног кластера, односно предзнања. Шифре припадних кластера се састоје од шифара предзнања и стила учења. На слици 74, која приказује стабло одлучивања, виде се и зависности и њихове особине.



Слика 74: Стабло одлучивања за оцену студента за модел М5

Стил учења је искључиво зависан од припадног кластера. Припадни кластери који формирају услове гранања у дијаграму стабла одлучивања су: 13, 23, 12, 11 и 21. У табели 91 су приказане вероватноће стила учења у зависности од припадног кластера.

Табела 91: Вероватноће стила учења у стаблу одлучивања за модел М5

кластер	All	pk=13	pk not=13	pk not=13 and pk not=23	pk not=13 and pk =23	pk not=13 and pk not=23 and pk=12	pk not=13 and pk not=23 and pk not=12	pk not=13 and pk not=23 and pk not=12 and pk not=11	pk not=13 and pk not=23 and pk not=12 and pk =11	pk not=13 and pk not=23 and pk not=12 and pk not=11 and pk not=21	pk not=13 and pk not=23 and pk not=12 and pk =21
1	32,95	0,75	47,06	65,90	1,12	3,17	76,55	64,47	95,80	28,57	95,12
2	13,07	0,75	18,46	25,58	1,12	90,48	14,56	22,81	1,40	47,62	1,63
3	51,70	97,76	31,54	4,84	96,63	3,17	5,12	7,46	1,40	14,29	1,63

Најпримењенији стил учења је вербално/секвенцијално/активни и износи мало више од половине целе популације (51,70%). На основу добијених података може да се закључи да су неки стилови учења чврсто повезани са одговарајућим припадним кластерима. Тако, ће студенти са припадним кластерима 13 и 23 у потпуности примењивати стил учења вербално/активно/секвенцијални, а са припадним кластером 12 примењиваће интуитивно/активни/глобални, а са припадним кластерима 11 и 21 визуелно/секвенцијално/активни. Студенти који примењују остале припадне кластере ће, највероватније, примењивати интуитивно/активни/глобални стил (47,62%,) затим визуелно/секвенцијално/активни стил (28,57%) и вербално/активно/секвенцијални стил (14,29%).

Утицајни параметри

У циљу детаљније анализе успеха анализираће се који параметри утичу на оцену. Анализа утицајних параметара на оцену је спроведена преко Naïve Bayes алгоритма. Овај алгоритам за циљни параметар проналази параметре који на њега утичу, као и степен тог утицаја. У табели 92 су приказани кључни утицаји на параметар *оцену*. У првој колони су називи параметара, у другој су шифре карактеристика параметара, у трећој су вредности циљне променљиве (оцене) и у четвртој је релативни утицај сваког од параметара на оцену.

Табела 92: Утицајни параметри на оцену

Column	Value	Favors	Relative Impact
ПРЕДЗНАЊЕ	1	6	100
ПРИПАДНИ КЛАСТЕР	13	6	45
БРОЈ ЛОГОВАЊА	2	6	30
ВРЕМЕ ПРОВЕДЕНО НА КУРСУ	2	6	17
ПРИПАДНИ КЛАСТЕР	11	6	12
КУРС	2	6	8
БРОЈ ЛОГОВАЊА	1	8	100
ПРЕДЗНАЊЕ	2	8	73
ПРИПАДНИ КЛАСТЕР	21	8	59
ПРИПАДНИ КЛАСТЕР	12	8	58
ВРЕМЕ ПРОВЕДЕНО НА КУРСУ	1	8	52
СТИЛ УЧЕЊА	1	8	18
КУРС	1	8	17
ПРИПАДНИ КЛАСТЕР	23	8	8
СТИЛ УЧЕЊА	2	8	6
ВРЕМЕ ПРОВЕДЕНО НА КУРСУ	2	7	61
КУРС	2	7	33
БРОЈ ЛОГОВАЊА	2	7	32
ПРИПАДНИ КЛАСТЕР	23	7	24
БРОЈ ЛОГОВАЊА	1	7	8

Column	Value	Favors	Relative Impact
ПРИПАДНИ КЛАСТЕР	12	7	5
ВРЕМЕ ПРОВЕДЕНО НА КУРСУ	0	5	100
БРОЈ ЛОГОВАЊА	0	5	100
ПРИПАДНИ КЛАСТЕР	13	5	33
ПРЕДЗНАЊЕ	1	5	26
СТИЛ УЧЕЊА	3	5	10
КУРС	2	5	8
ПРИПАДНИ КЛАСТЕР	31	5	4
ПРИПАДНИ КЛАСТЕР	33	5	4
ПРЕДЗНАЊЕ	2	9	100
БРОЈ ЛОГОВАЊА	1	9	50
ВРЕМЕ ПРОВЕДЕНО НА КУРСУ	1	9	45
КУРС	1	9	26
ПРИПАДНИ КЛАСТЕР	23	9	24
ПРИПАДНИ КЛАСТЕР	22	9	19
ПРИПАДНИ КЛАСТЕР	21	9	10
БРОЈ ЛОГОВАЊА	1	10	100
ПРИПАДНИ КЛАСТЕР	32	10	92
ПРЕДЗНАЊЕ	3	10	86
ВРЕМЕ ПРОВЕДЕНО НА КУРСУ	1	10	73
КУРС	1	10	44
ПРИПАДНИ КЛАСТЕР	31	10	28
СТИЛ УЧЕЊА	2	10	24
ПРИПАДНИ КЛАСТЕР	23	10	16
ПРЕДЗНАЊЕ	2	10	16
ПРИПАДНИ КЛАСТЕР	22	10	9

Види се да су за оцену 10 најутицајнији: оптимални број логовања (100), кластер напредни ниво предзнања/ИАГ (92), напредни ниво предзнања (86), оптимално време проведено на курсу (73) и упућеност на адаптивни курс (44).

За оцену 9 су најутицајнији: напредни ниво предзнања (100), оптимални број логовања (50), оптимално време проведено на курсу (45) и упућеност на адаптивни курс (26).

За оцену 8 најутицајни су: оптимални број логовања (100), напредни ниво предзнања (73), кластер просечни ниво предзнања/ВАС (59) и кластер напредни ниво предзнања/ИАГ (52).

За оцену 7 су најутицајнији: пуно времена проведених на курсу (61), упућеност на адаптивни курс (33), пуно логовања (32) и кластер просечни ниво предзнања/ВАС.

За оцену 6 су најутицајнији: почетни ниво предзнања (100), кластер почетни ниво предзнања/ВАС (45) и пуно логовања (30).

За оцену 5 су најутицајнији: недовољно времена проведених на курсу (100), недовољни број логовања (100), кластер почетни ниво предзнања/ВАС (33) и почетно предзнање (26).

У циљу даље анализе утицајних фактора користе се дијаграми разлика утицајних фактора на појединачне оцене. Може да се посматра разлика утицајних променљивих између било које две оцене. На пример, разлика између оцена 10 и 5 је приказана у табели 93.

Табела 93: Дискриминација између фактора битних за оцену 5 и оцену 10

Column	Value	Favors 5	Favors 10
БРОЈ ЛОГОВАЊА	1		100
ВРЕМЕ ПРОВЕДЕНО НА КУРСУ	1		75,81
ПРЕДЗНАЊЕ	1	58,27	
БРОЈ ЛОГОВАЊА	0	33,33	
ВРЕМЕ ПРОВЕДЕНО НА КУРСУ	0	33,33	
ПРИПАДНИ КЛАСТЕР	13	30,03	
ПРЕДЗНАЊЕ	2		23,76
ПРИПАДНИ КЛАСТЕР	23		22,61
СТИЛ УЧЕЊА	2		18,99
ПРИПАДНИ КЛАСТЕР	32		17,84
КУРС	2	16,95	
КУРС	1		16,95
ПРЕДЗНАЊЕ	3		7,1
БРОЈ ЛОГОВАЊА	2	5,43	
ПРИПАДНИ КЛАСТЕР	22		1,05

Параметри који утичу на оцену 10 према значајности су: оптимално логовање на курс, оптимално време проведено на курсу, просечни ниво предзнања, припадни кластер почетни/ВАС, стил учења интуитивно/активни/глобални, припадни кластер просечни/ВАС, упућен на адаптивни курс, напредни ниво знања и припадни кластер просечни/ИАГ. Параметри који утичу на оцену 5 према значајности су: почетни ниво предзнања, премали број пријављивања и времена проведеног на курсу, припадни кластер почетни/ВАС, упућен на традиционални e-Learning курс и превише пријављивања на курс. Наравно, разлике утицајних параметара за суседне оцене су мање. На пример, разлика између оцена 10 и 9 (табела 94), показује да су за оцену 10 од утицаја напредни ниво предзнања и припадни кластери напредни/ИАГ и напредни/ВАС, а за оцену 9 просечни ниво предзнања.

Табела 94: Разлика утицајних параметара за оцене 10 и 9

Column	Value	Favors 9	Favors 10
ПРЕДЗНАЊЕ	3		100
ПРЕДЗНАЊЕ	2	100	
ПРИПАДНИ КЛАСТЕР	32		45,93
ПРИПАДНИ КЛАСТЕР	31		3,91

Посматрајући утицајне параметре за све оцене види се да су за успех на курсу најутицајнији време проведено на курсу и предзнање. Постигнути резултати су у директној пропорцији за овим параметрима. Време проведено на курсу је потребан и неопходан услов за постизање доброг резултата.

Следећи фактор по важности је учешће на (адаптивном) курсу. Види се да је упућеност на (адаптивни) курс генерално утицала на веће оцене студената. У циљу детаљније анализе утицаја врсте курса, може се упореди успех студената за исте нивое предзнања и исте нивое времена проведеног на курсу. На пример, за оптимално време проведено на курсу и просечни ниво предзнања од 28 студената, 25 је похађало адаптивни курс и то са оценама: 6 десетки, 13 деветки, 5 осмица и једном седмицом. Троје студената које је било на традиционалном курсу, имало је оцене: две седмице и једна осмица. Очигледно је да су у овој групи бољи успех постизали студенти са учешћем на адаптивном курсу.

Следећи пример обухвата студенте који су на курсу проводили пуно (превише) времена и били су просечног нивоа предзнања. Од 25 студената са овим карактеристикама параметара, 13 је било са оценом седам, 9 је било осмица и троје студената је са оценом девет. Скоро сви поменути студенти, укупно њих 24, је похађало и било упућено на традиционални е-Learning курс.

Трећи пример обухвата студенте који су проводили оптимално времена на курсу и имали су почетни ниво знања. Укупно је 32 таквих студената са следећим оценама: 3 петице, 9 шестица, 12 седмица и 8 осмица. Сви студенти су били на адаптивном курсу.

Четврти пример обухвата студенте који су провели пуно времена на курсу и имали су почетни ниво знања. Укупно је 41 таквих студената, од којих је 7 било на адаптивном курсу, а 34 студента је било на традиционалном е-Learning курсу. Студенти на адаптивном курсу су имали следеће оцене: две петице, две шестице, једна седмица и две осмице. Студенти на традиционалном е-Learning курсу су имали следеће оцене: 10 петица, 18 шестица и 6 седмица.

Закључак

Из спроведених анализа података могу да се изведу следећи закључци:

- Услов за постизање добрих резултата у учењу је време проведено на курсу. Дуже време проведено на учењу је делимично поправљало резултат код студената са мањим предзнањем или оних који су били на традиционалном е-Learning курсу.
- Следећи веома значајан фактор је предзнање. Студенти са одређеним нивоима предзнања су постизали боље резултате од почетника.

- Учесће на адаптивном курсу је показало да се са оптималним ангажовањем могу да постигну одлични резултати.
- Најбољи резултати се постижу код студената са напредним нивоом предзнањем и оптималним ангажовањем на адаптивном e-Learning курсу.

Кластер анализа

Анализа података врши се у неколико корака: интеграција података, израда модела Data Mining, процена модела и извештавање (Romero & Ventura, 2020).

Након прикупљања података, први задатак у анализи података је интеграција података. Да бисмо обезбедили модел података погодан за анализу, морали смо да издвојимо, трансформишемо и учитамо (енг. ETL – extract, transform and load) податке у специјализовано складиште података. Створен је SQL (Server Integration Services) сервер, који садржи један контролни ток, неколико токова података и извршава ETL задатке. Развој и процена Data Mining модела, као и анализа података врше се у Microsoft Analysis Services (Guimaraes, 2018). Крајњи циљ Data Mining је достављање извештаја релевантним корисницима за доношење одлука. Microsoft Excel се користи за генерисање извештаја директно из резултата Data Mining на основу DMX (Data Mining Extension) упита.

Као што је претходно у раду већ напоменуто, Data Mining има за циљ откривање образаца, група, претходно непознатих релација у подацима, као и предвиђање. За потребе дисертације, поред претходно изложене класификације, коришћена је и кластер анализа. Кластер анализа, као и друге Data Mining технике, успешно се примењују последњих година у домену учења. Примена техника Data Mining у LMS показала се успешном кроз примену на Moodle подацима. Кластер анализа се такође показала корисном за класификацију типова ученика по групама, према различитим карактеристикама (Chien, Liu & Wu, 2020). Кластер анализа испитује обрасце у којима се објектима додељују вредности, или колоне из табеле. Сваки кластер има специфичне особине, које га разликују од осталих кластера.

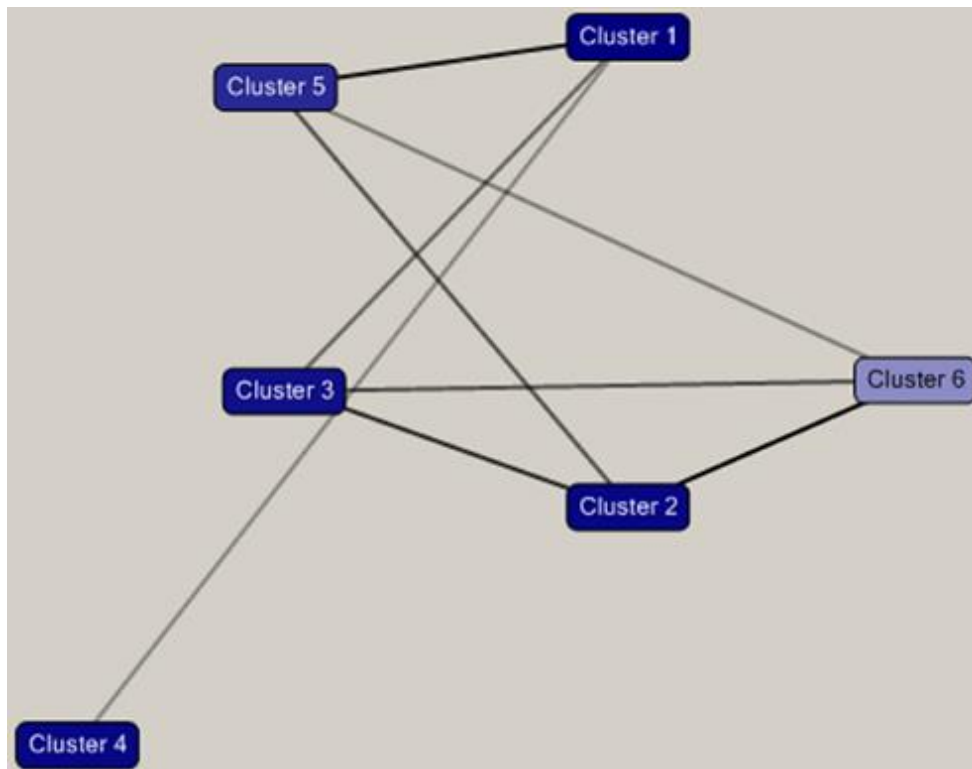
Кластер анализа садржи следеће аспекте:

- дијаграм кластера
- профил кластера
- карактеристике кластера и
- разлике између кластера (Chabih, Sbai, Behja, Louhdi & Trousse, 2021).

Први корак кластер анализе је креирање модела који поставља променљиву. Модел садржи следеће променљиве: курс (тип курса), број сати проведених на курсу (време проведено на курсу), број пријава на курс (број логовања), предзнање, стил учења, припадајућу групу/кластер и ознаку.

Сам алат оптимизује број кластера, али се тај број може и експлицитно дефинисати. Дијаграм кластера (слика 75) приказује све кластере који су идентификовани алгоритмом, као и њихове везе. Кластери са великим бројем објеката (врста) приказани су тамнијим нијансама на дијаграму. Уколико постоје неке уобичајене

карактеристике објеката онда су оне приказане као везе. Што су заједничке карактеристике јаче, уколико су њихове везе истакнутије на дијаграму (тамније линије).



Слика 75: Кластер дијаграм

Профили кластера, приказани на једном месту, показују опште карактеристике сваког кластера (слика 76). Графичка илустрација има јасан визуелни приказ и омогућава брзи приступ карактеристикама кластера. Кликом на сваки правоугаоник (оквир кластера) може се видети вредност сваке карактеристике.

У графичким илустрацијама и табеларним презентацијама користе се следећи кодови:

- Курс:
 - 1 – традиционално е-учење
 - 2 - адаптивно е-учење
- Време проведено на курсу:
 - 0 – недовољно
 - 1 – оптимално
 - 2 – у великој мери
- Број пријављивања:
 - 0 – недовољно
 - 1 – оптимално
 - 2 – у великој мери
- Предзнање:
 - 1 – почетник
 - 2 – просек
 - 3 – напредни

- Стил учења:
 - 1 – визуелно / секвенцијално / активно (ВСА)
 - 2 – интуитивно / активно / глобално (ИАГ)
 - 3 – визуелно / активно / секвенцијално (ВАС)

- Одговарајући кластер (група):
 - 11 – почетник / ВСА
 - 12 – почетник / ИАГ
 - 13 – почетник/ВАС
 - 21 – просек / ВСА
 - 22 – просек / ИАГ
 - 23 – просек / ВАС
 - 31 – напредни / ВСА
 - 32 – напредни / ИАГ
 - 33 – напредни / ВАС.



Слика 76: Профили кластера

Табеларно приказивање профила кластера пружа информације о целокупној популацији и сваком кластеру са вредностима његових карактеристика.

Профили кластера омогућавају различите врсте анализа. На пример, ако треба анализирати успех студената, види се да су оцене 5, 6, 7, 8, 9 и 10 за целокупну популацију приближно подједнако заступљене.

Најбоље оцене су у кластерима 2, 3 и 6. Оцене веће од 7, су заступљене у кластеру 2 са укупно 86%, у кластеру 3 са 48%, а у кластеру 6 са вероватноћом 68%. Када се говори само о оценама 9 и 10, доминира кластер 2 са 56%, затим кластер 6 са 33% и на крају

кластер 3 са 11% вероватноће. То значи да су студенти са одличним резултатима концентрисани у кластере 2 и 6, а у кластеру 3 су студенти са врло dobrим резултатима, јер је у овом кластеру оцена 7 заступљена са 52% вероватноће.

Студенти са најслабијим резултатима груписани су у кластере 4, 1 и 5. Укупне оцене 5 и 6 представљене су на следећи начин: кластер 1 са 100%, кластер 4 са 88% и кластер 5 са вероватноћом 64%. У кластеру 5 налази се значајан број студената са оценом 7 (са вероватноћом од 32%).

Укупно рангирање студената према успеху, по кластерима је: 2, 6, 3, 5, 4 и 1. Уочљиво је да кластери 2 и 6 имају највећу вероватноћу појаве оцене веће од 7, а за оптимално време проведено на курсу, просечни ниво предзнања и оптимално проведеног времена на курсу. На сличан начин се могу анализирати и други параметри. Следи кластер анализа према успеху ученика.

Кластер анализа према успеху ученика

Кластер 2

Као што је поменуто, вероватноћа појаве оцене веће од 8 је највећа у овом кластеру. Од оцена, у кластерима су најзаступљеније деветке (37%), осмице (30%) и десетке (19%). Анализирањем осталих променљивих у кластеру, добијамо следеће информације. Вероватноћа да је учешће на курсу типа 1 (што значи да студенти похађају адаптивни курс) је 100%. То значи да су сви студенти који припадају овом кластеру били учесници адаптивног курса. Што се тиче времена проведеног на курсу, сви учесници су провели оптимално времена на курсу (100%). У значајном проценту (73%) студенти су имали просечан ниво предзнања (2). Доминантни стилови учења су: 1 – визуелни /секвенцијални/активни (ВСА) и 3 – вербални/активни/секвенцијални (ВАС), укупно 97%. Одговарајуће припадне групе 23 (просечни/ВАС) и 21 (просечни/ВСА) чине 69%.

Кластер 6

У овом кластеру осмица је најзаступљенија оцена (35%), а затим седмица са 26% и десетка са 21%. Похађање адаптивног курса је 79% вероватноће и 66% почетничког знања. Већина студената је проводила просечно (оптимално) време на курсу (65%), али треба имати на уму да је преосталих 35% студената провело више од оптималног времена на курсу. Доминантан стил учења је интуитиван/активан/глобални (ИАГ). Одговарајућа група почетник/ИАГ била је заступљена са 51%. У односу на кластер 2 главне разлике су нижи ниво знања, мање похађање адаптивног курса и више сати проведених на курсу. Успех је нижи него у кластеру 2, али и даље на високом нивоу.

Кластер 3

Најчешће оцене у овом кластеру су 7 (52%) и 8 (37%). Готово сви студенти, који припадају овом кластеру, имају просечно знање (98%) и углавном су били у групи просечни/ВАС (67%). Такође, скоро сви студенти су похађали традиционални курс е-учења (96%). Углавном су проводили пуно времена (више него оптимално) на курсу (85%). Доминантан стил учења је вербални/активни/секвенцијални (ВАС) – 67%. Може се закључити да студенти у овом кластеру не заостају значајно у предзнању у односу на претходна два кластера. Разликују се по томе што су похађали традиционални курс за е-учење и више времена су провели на курсу. Њихов успех је нешто слабији од претходна два кластера, али веома задовољавајући.

Кластер 5

Најраспрострањеније оцене су 6 са 39%, затим 7 (32%) и 5 (26%). Сви студенти у овој групи имају почетничко знање (100%), повезано са превладавајућом групом почетник/ВАС (86%). Скоро сви студенти су похађали адаптивни курс (96%). Стил учења вербални/активни/секвенцијални (ВАС) чини 86%. Студенти су проводили просечно времена на курсу (71%). У овом кластеру се појављује и 9% студената са недовољним временом проведеним на курсу (мање од оптималног времена). Као разлоге за нижи постигнути успех, упркос високом учешћу на адаптивном курсу, може се узети најнижи ниво предзнања од свих претходних кластера и мање времена проведеног на курсу.

Кластер 4

Доминантна оцена у овој групи студената је 5 (77%), а затим 6 (23%). У овом кластеру студенти нису ефикасно учествовали у курсу. Већина ученика су почетници (52%) из одређене групе почетник/ВАС (која представља 34%), али није безначајан број и оних са просечним предзнањем (37%). Студенти су прилично уједначени по врсти курса коју су похађали, има их и у традиционалном неадаптибилном курсу учења (52%) и адаптивном курсу е-учења (48%). Најчешћи стилови учења су вербални/активни секвенцијални – ВАС (49%) и визуелни/секвенцијални/активни – ВСА (36%). Незадовољавајуће постигнуће студената у овом кластеру може се правдати неучествовањем на курсевима и нижим нивоом претходног знања.

Кластер 1

Оцене у овом кластеру студената су 6 (55%), 5 (33%) и 7 (12%). Сви студенти су пријављени на традиционални курс за е-учење. Скоро сви су са почетним нивоом предзнања (98%) и припадају дефинисаној групи почетник/ВАС (57%) и почетник/ВСА (38%). Студенти имају пуно времена проведеног на курсу, што значи више од оптимално проведеног времена (98%). Доминирају стилови учења вербални/активни/секвенцијални (59%) и 38% визуелни/секвенцијални/активни. Упркос значајном нивоу ангажовања ових студената, постигнути успех је нижи, што се може тумачити тиме да су скоро сви учесници почетници и да тип традиционалног курса е-учења није дао добре резултате.

Разлике између кластера

Додатне могућности за кластер анализу укључују креирање дијаграма диференцијације са остатком популације и разлике између самих кластера. На пример, карактеристике разлика кластера 1 у односу на друге кластере и остатак целокупне популације, за коју је утврђено да садржи студенте са највише успеха, наведене су у следећој табели.

Табела 95: Разлике Кластера 1 у односу на остатак популације

Параметри	Вредност	Фаворизује Clstr. 1	Фаворизује Complement of Clstr. 1
Број пријављивања	2	100	
Време проведено на курсу	2	81,23	
Група	2	67,89	
Група	1		67,89
Број пријављивања	1		54,68

Предзнање	1	47,27	
Време проведено на курсу	1		42,70
Предзнање	2		40,05
Оцена	6	26,35	
Група	23		11,79
Група	11	11,74	
Група	13	10,10	
Број пријављивања	0		9,50
Време проведено на курсу	0		9,50
Оцена	8		9,48
Група	21		7,75
Оцена	9		3,1

Може се видети да вредности параметара, који негативно утичу на добре оцене, имају велику вероватноћу утицаја на овај кластер, посебно време проведено на курсу. Насупрот томе, вредности параметара који позитивно утичу на добре оцене, са значајном вероватноћом утичу на комплемент кластера (остатак популације).

За разлику од кластера 1, кластер 2 је концентрисан на студенте са најбољим резултатима (табела 96).

Табела 96: Разлике Кластера 2 у односу на остатак популације

Параметри	Вредност	Фаворизује Clstr. 2	Фаворизује Complement of Clstr. 2
Време проведено на курсу	1	100	
Број пријављивања	1	70,2	
Група	2		67,57
Група	1	67,57	
Време проведено на курсу	2		49,84
Оцена	9	33,12	
Број пријављивања	2		29,56
Група	13		28,93
Предзнање	2	20,99	
Оцена	5		19,68
Предзнање	1		18,51
Learning Style	1	15,00	
Време проведено на курсу	0		12,96
Број пријављивања	0		12,96
Оцена	10	12,26	
Група	21	9,92	
Оцена	6		9,22
Стил учења	2		3,15
Оцена	8	2,53	
Група	23	2,31	

Може се видети да су главне карактеристике по којима се овај кластер разликује од остатка популације, оптимално време проведено на курсу и учешће у курсу.

Коришћењем табеле разлика између кластера може се одговорити, на пример, на питање која је предност кластера 2 у односу на кластер 3 (табела 97).

Табела 97: Разлике Кластера 2 у поређењу са Кластером 3

Параметри	Вредност	Фаворизује Clstr. 2	Фаворизује Clstr. 3
Курс	2		100
Курс	1	100	
Време проведено на курсу	2		76,43
Време проведено на курсу	1	76,43	
Број пријављивања	1	27,53	
Број пријављивања	2		27,53
Оцена	7		13,14
Група	11	9,2	
Предзнање	2		8,91
Предзнање	1	7,38	
Оцена	10	5,87	
Оцена	9	4,01	
Група	23		3,74
Стил учења	1	3,43	
Стил учења	3		2,97

Главна разлика између кластера 2 и кластера 3 је врста курса коју су студенти похађали, као и време проведено на курсу. Оба параметра имају исти степен утицаја у оба кластера. Кластер 2 даје предност адаптивном курсу, док кластер 3 даје предност традиционалном курсу е-учења. Исти проценат (76,43%) Кластер 2 фаворизује оптимално време проведено на курсу, а кластер 3 фаворизује више од оптималног времена проведеног на курсу. Кластер 2 фаворизује оцене 9 и 10, док кластер 3 фаворизује 7. У овим разликама би требало тражити узроке бољих постигнућа студената у кластеру 2, у поређењу са постигнућима студената који припадају трећем кластеру.

Студенти са истим нивоом предзнања

Следећи модел је створен како би се анализирао успех студената са истим нивоом знања. Изабран је просечан ниво знања.

У овом делу укупне популације постоји приближно иста заступљеност адаптивног курса (33) и традиционалног курса е-учења (31). У кластерима 1, 2, 3 и 4 су студенти са оценама вишим од 6. У кластерима 2 и 3 је присуство адаптивног курса од скоро стотину процената и износи 97% односно 96%. У кластерима 1 и 4 доминира традиционални курс е-учења и износи 97% односно 100%. У кластеру 5 је веће присуство адаптивног курса и износи 70%. Табела 98 приказује заступљеност оцена за целокупну популацију и по кластерима.

Табела 98: Заступљеност оцена по кластерима

Заступљеност оцене	Сви	C1	C2	C3	C4	C5
Степен	16	56	6	2	52	0
Оцене веће од 7	38	44	100	98	48	0
Оцене веће од 8	22	11	67	88	11	0
Оцена 10	6	0	13	35	0	0

Очигледно је да су много бољи резултати у кластерима 2 и 3 у поређењу са кластерима 1 и 4. То значи да су студенти на адаптивном курсу е-учења имали знатно боље резултате. Преко табеле разлика се могу утврдити било какве разлике или одређене специфичности појединих кластера. На пример, специфичности студената у кластеру 2, у односу на све остале студенте, могу се видети у табели 99.

Табела 99: Специфичности Кластера 2

Параметри	Вредност	Фаворизује Clstr 2	Фаворизује Complement of Clstr 2
Време проведено на курсу	1	100	
Курс	1	63,23	
Курс	2		63,23
Број пријављивања	1	54,589	
Време проведено на курсу	2		50,487
Група	23		24,225
Стил учења	3		24,225
Оцена	9	22,626	
Број пријављивања	2		19,68
Стил учења	1	18,565	
Група	21	10,829	
Време проведено на курсу	0		4,527
Број пријављивања	0		4,527
Оцена	7		4,151

Нарочито важне променљиве које утичу на кластер су оптимално време проведено на курсу, адаптивни курс, оцена 9, визуелни/секвенцијални/активни стил учења, одговарајућа група просечни/ВАС. Разлике студената груписаних у кластере 2 и 3 (који су учествовали у адаптивном курсу е-учења) наведене су у табели 100.

Табела 100: Разлике између Кластера 2 и Кластера 3

Параметри	Вредност	Фаворизује Clstr 2	Фаворизује Clstr 3
Група	23		100
Стил учења	3		100
Стил учења	1	87,015	
Група	21	66,855	

Може се видети да су разлике у одговарајућој групи и/или стилу учења.

За приказивање разлике између студената ове популације, потпуно другачијег типа учешћа на курсу, пореде се кластери 2 и 4 (табела 101).

Може се видети да су студенти у кластеру 2 били оптимално ангажовани на адаптивном курсу е-учења и добили су углавном оцену 9, док су студенти из кластера 4 били далеко више ангажовани на традиционалном курсу е-учења и добили су као највишу оцену 7.

Табела 101: Разлике између Кластера 2 и Кластера 4

Параметри	Вредност	Фаворизује Clstr 2	Фаворизује Clstr 4
Време проведено на курсу	1	100	
Време проведено на курсу	2		99,924
Курс	1	94,66	
Курс	2		94,66
Број пријављивања	1	57,083	
Број пријављивања	2		57,042
Оцена	7		17,414
Оцена	9	10,243	

Спроведена анализа података јасно показује да је успех студената који су учествовали у адаптивном курсу е-учења знатно бољи од ученика који су били на традиционалном курсу е-учења. Такође, студенти са одређеним нивоима знања (не почетници) били су успешнији од ученика почетника. Учешће на адаптивном курсу омогућило је студентима да, до одређеног нивоа знања, постигну још боље резултате. Време проведено на курсу је неопходан услов за постизање задовољавајућег успеха. Значајан број ученика који су учествовали у традиционалном курсу и провели значајну количину времена на курсу, нису постигли довољно добре резултате.

Закључак

Дизајниран је специфични кластер модел који генерише кластере студената са сличним карактеристикама (атрибутима). Параметри модела се могу мењати што омогућава експериментисање са различитим конфигурацијама (моделима). Свака конфигурација се може испитати како би се утврдило значење кластера. Кластер модел омогућава брзи преглед података, као и поређење између стилова учења и профила студената. Такође пружа детаљне информације у вези са својствима кластера заједно са одговарајућим статистичким подацима.

Кластер анализа омогућила је добијање богатог скупа информација у облику графикана и табела, из којих се могу извести многи релевантни закључци. Овај кластер модел може се користити да се више научи о студентима, како би се стилови учења и курсеви усмерили на одређене групе. Добијени резултати у потпуности потврђују валидност концепта адаптивног учења и кластер модела. Показало се да кластери, у које су студенти груписани према постигнутом успеху, омогућавају јасну идентификацију других уочених карактеристика које утичу на постигнуте резултате, и са којом вероватноћом врше тај утицај. Било је евидентно да предзнање и стил учења у великој мери утичу на успех ученика, па се адаптивни систем заснива првенствено на овим карактеристикама. Студенти који су похађали адаптивни курс за е-учење, у просеку, су постигли знатно боље резултате и били су ефикаснији у процесу учења у поређењу са студентима који су похађали традиционални курс за е-учење.

6. ЗАКЉУЧАК

Образовање је један од кључних елемената савременог друштва. Учење, као централни и сложени процес, захтева примену система и алата електронског учења. Системи за управљање учењем су постали незаобилазан део процеса учење.

Потреба да се системи за учење прилагоде индивидуалним способностима студента довела је до развоја адаптивних система за управљање учењем. Развој адаптивног LMS-a је широко истраживачко подручје. Иако је способност прилагођавања значајно питање у LMS-у, комерцијални системи учења који интегришу прилагодљивост у савремено е-образовање су ретки и имају ограничене адаптивне могућности. Стога је посебан изазов развој LMS-a који омогућава персонализацију учења, такозвани адаптивни LMS.

Ова дисертација представља адаптивни модел учења, који пружа висок ниво прилагодљивости и флексибилност за прилагођавање различитим сценаријима учења и реализације наставе. Систем који је у овом раду приказан представља надградњу постојећег e-Learning система развијеног на Moodle. Ова, у пракси проверена платформа, је надграђена са моделом студента, адаптационим модулом и експертним моделом. Ови модули омогућавају да се према карактеристикама, навикама и особеностима сваког студента изврши прилагођавање наставног садржаја. Сама структура модела, као и персонализација учења по два аспекта (стил учења и претходно знање) омогућавају прилагођеније и персонализоване искуство учења. Персонализација учења по два аспекта представља вредан помак у приступу стварању адаптивног LMS.

Развијени адаптивни модул учења и софтверске компоненте тестирани су на стварном узорку студента и показали су се успешним. Успех учења са овим адаптивним LMS-ом се огледа у способности персонализације учења према преференцијама ученика и бољим постигнућима и исходима учења (који се огледају у бољим оценама, побољшаном нивоу знања ученика, квантитету и квалитету временаведеног у учење).

Валидност адаптивног LMS-a је проверена експериментом који је обухватио једну групу студената на класичном, неадаптивном e-Learning курсу и другу групу студената који су похађали адаптивни e-Learning курс. Тако је упоређен адаптивни LMS са традиционалним, неадаптивним LMS-ом. Као што се и очекивало, испоставило се да адаптивно окружење за учење има позитиван утицај на постигнућа у учењу и исходе учења. Анализа добијених података довела је до закључка да на успех учења утичу прилагодљивост курса, број пријављивања, времеведено на курсу и предзнање (да ли је студент почетник или не). Показало се да су најбоље резултате постигли студенти који су похађали адаптивни курс, имали оптимално трајање пријавних сесија, бољу ефикасност реализације активности и они који су имали неко предзнање. Ови резултати и исходи оправдавају побољшање LMS-a у смислу адаптивности, јер се на тај начин побољшавају ефикасност и исходи учења.

Развијени модел адаптивног LMS и развијена софтверска апликација показали су се корисним у унапређивању процеса учења и побољшању исхода учења студената. На основу спроведене анализе података, добијене су драгоцене информације и знања која се могу користити за боље доношење одлука и побољшање стратегије поучавања и учења.

Резултати истраживања су објављени у седам радова у међународним и домаћим часописима, као и зборницима конференција. Неки сегменти истраживања, приступи и идеје, настали током рада на дисертацији, су такође објављени у форми проширених теорија и разматрања у 19 радова, публикованих у домаћим, међународним часописима и зборницима научних конференција. Ови резултати ће се користити као смерница за даља истраживања у побољшању адаптивног развоја и дизајна LMS, као и за побољшање софтверског експертног система за боље и прецизније доношење одлука.

Добијени резултати су систематизовани и меморисани у структурама података погодним за обраду статистичким методама и примену Data Mining техника. На тај начин је адаптивни систем за учење фактички проширен и модул за Data Mining. Развијени су прилагођени Data Mining модели за анализу кључних утицаја и класификацију. Добијен је веома богат скуп информација који је показао оправданост примене адаптивног LMS-а. Идентификовани су кључни утицајни параметри на успех студената, степен њиховог утицаја и предвиђање успеха студената у зависности од утицајних параметара. Бројни аспекти анализе из различитих углова посматрања указују на акције које треба предузети за поједине категорије студената да би они постигли одређене резултате. У даљим истраживањима може да се обухвати знатно шири број променљивих које се односе и на студенте и на систем за учење. То ће омогућити да се уз помоћ статистичких метода и Data Mining приступа дође до нових сазнања о изградњи и примени адаптивних e-Learning система.

РЕФЕРЕНЦЕ

1. Abuhlfaia, K., & Quincey, E. D. (2018). The usability of E-Learning platforms in higher education: a systematic mapping study. In *Proceedings of the 32nd International BCS Human Computer Interaction Conference 32*, 1-13.
2. Ahmadaliev, D. K., Medatov, A. A., Jo'rayev, M. M., & O'rinov, N. T. (2019). Adaptive Educational Hypermedia Systems: An Overview Of Current Trend Of Adaptive Content Representation And Sequencing. *Theoretical & Applied Science*, (3), 58-61.
3. Ahmed, M., Sangi, N. A., & Mahmood, A. (2018). A model of adaptive e-Learning in an ODL environment. *Mehran University Research Journal Of Engineering & Technology*.
4. Ajmera, R. (2014). E-Learning quality criteria and aspects. *arXiv preprint arXiv:1406.7744*.
5. Al-Chalabi, H. K. M., & Hussein, A. M. A. (2020). Pedagogical Approaches in Adaptive E-Learning Systems. In *2020 12th International Conference on Electronics, Computers and Artificial Intelligence (ECAI)*, 1-4. IEEE.
6. Al-Fraihat, D., Joy, M., & Sinclair, J. (2020). Evaluating E-Learning systems success: An empirical study. *Computers in Human Behavior*, 102, 67-86.
7. Alhawiti, M. M., & Abdelhamid, Y. (2017). A Personalized e-Learning Framework. *Journal of education and e-Learning research*, 4(1), pp. 15-21.
8. Alkhatlan, A., & Kalita, J. (2018). Intelligent tutoring systems: A comprehensive historical survey with recent developments. *arXiv preprint arXiv:1812.09628*.
9. Al Muhaideb, S., Hammami, S., & Mathkour, H. (2010). Towards a distributed architecture for adaptive e-Learning system. In *2010 10th IEEE International Conference on Advanced Learning Technologies*, 632-636. IEEE.
10. Andaloussi, K. S., Capus, L., & Berrada, I. (2017). Adaptive educational hypermedia systems: current developments and challenges. In *Proceedings of the 2nd international Conference on Big Data, Cloud and Applications*, 1-8.
11. Ansari, N., Singh, A. B., Trivedi, B. D., & Nandankar, P. B. (2020, May). Analysis of Suitable Approaches for Data Mining Algorithms. In *2020 4th International Conference on Intelligent Computing and Control Systems (ICICCS)*. 916-921. IEEE.
12. Арсовић, Б., и Стефановић, Д. (2010). Значај колаборативних наставних материјала у е-Learning системима (The Importance of Collaborative Teaching Materials in e-Learning Systems), *Инфо М (часопис за информациону технологију и мултимедијалне системе)*, 33/2010, 19-25.
13. Арсовић, Б. (2010). Методе вредновања образовног рачунарског софтвера, *Зборник радова „Иновације у основошколском образовању – вредновање“*. Београд: Учитељски факултет. 545-551.
14. Arsović, B. (2011). Adaptivity in elearning LMS platform – approaches and solutions, *Proceeding of The 2nd International Conference on e-Learning (eLearning-2011)*, 49-54

15. Арсовић, Б. (2012). *Напредне информационе технологије и образовни рачунарски софтвери у математичком образовању*. Магистарски радови књ. 4. Ужице: Учитељски факултет у Ужицу
16. Арсовић, Б. (2017). ИКТ у образовању – могућности и изазови, *Културно – потпорна средства у функцији наставе и учења*, 423-432
17. Arsović, B. (2018). Tendencies in Future Education Development – Personalised and Adaptive e-Learning, *Зборник радова*, број 20, децембар 2018, година 21.
18. Arsovic, B., & Stefanovic, N. (2020). E-Learning based on the adaptive learning model: case study in Serbia. *Sādhanā*, 45(1), 1-13.
19. Baca, M. (2017). Metadata for Digital Projects: An Overview of Practical Issues and Challenges. *Digital Initiatives Symposium*. 26.
20. El Bachari, E., & El Hassan Abelwahed, M. E. A. (2011). E-Learning personalization based on dynamic learners' preference. *International Journal of Computer Science and Information Technology*, 3(3), 200-216.
21. Bakhouyi, A., Dehbi, R., Talea, M., & Hajoui, O. (2017). Evolution of standardization and interoperability on E-Learning systems: An overview. In *2017 16th International Conference on Information Technology Based Higher Education and Training (ITHET)*, 1-8. IEEE.
22. Balakrishna, S., & Thirumaran, M. (2020). Semantics and clustering techniques for iot sensor data analysis: A comprehensive survey. *Principles of Internet of Things (IoT) Ecosystem: Insight Paradigm*, 103-125.
23. Bártek, K., & Nocar, D. (2016). Digital Learning Objects as a support for new teaching methods. In *TED2016 Proceedings*. Valencia: IATED, 2583-2586.
24. Bartolomé, A., Castañeda, L., & Adell, J. (2018). Personalisation in educational technology: the absence of underlying pedagogies. *International Journal of Educational Technology in Higher Education*, 15(1), 1-17.
25. Bendahmane, M., El Falaki, B., & Benattou, M. (2019). Toward a Personalized learning Path through a Services-Oriented Approach. *International Journal of Emerging Technologies in Learning*, 14(15).
26. Binh, H. T., & Trung, N. Q. (2021). Responsive student model in an intelligent tutoring system and its evaluation. *Education and Information Technologies*, 1-23.
27. Bimba, A. T., Idris, N., Al-Hunaiyyan, A., Mahmud, R. B., & Shuib, N. L. B. M. (2017). Adaptive feedback in computer-based learning environments: a review. *Adaptive Behavior*, 25(5), 217-234.
28. Biswas, P., & Springett, M. (2018). User modeling. *The Wiley Handbook of Human Computer Interaction Volume*, 143.
29. Bloom, B. S. (1956). Taxonomy of educational objectives: The classification of educational goals. *Cognitive domain*.

30. Bogomolova E., Gorelova I., Menshikov, P., Zalavina T., & Arpentieva, M. (2018). The ability to learn and ability to teach: learning and teaching styles. In *International Conference on the Theory and Practice of Personality Formation in Modern Society (ICTPPFMS 2018)*, 146-153. Atlantis Press.
31. Borkar, S. (2020). A Perceptual Study of Data Mining and Machine Learning Techniques in Education. *learning*, 8(11).
32. Brusilovsky, P. (2000). Adaptive hypermedia: From intelligent tutoring systems to web-based education. In *International Conference on Intelligent Tutoring Systems*, 1-7. Springer, Berlin, Heidelberg.
33. Brusilovsky, P. (1996). Methods and Techniques of Adaptive Hypermedia, *User Modeling and User-Adapted Interaction*, vol. 6, no. 2-3, 87-129.
34. Brusilovsky, P. (2017). Intelligent interfaces for open social student modeling. In *Proceedings of the 2017 ACM Workshop on Intelligent Interfaces for Ubiquitous and Smart Learning*, 1-1.
35. Brusilovsky, P. (2004). Methods and techniques of adaptive hypermedia. *User Modeling and User-Adapted Interaction*, 6, 87-129.
36. Brusilovsky, P. (2004). KnowledgeTree: A distributed architecture for adaptive e-Learning, In *Proceedings of the Thirteenth International World Wide Web Conference, WWW 2004, New York, NY, 17-22 May, 2004, ACM Press*, 104-113.
37. Bruen, C., Fitzpatrick, N., Gormley, P., Harvey, J., & McAvinia, C. (2011). The Management and Creation of Knowledge. In *Organizational Learning and Knowledge: Concepts, Methodologies, Tools and Applications: Concepts, Methodologies, Tools and Applications*, 58, Management Association, Information Resources, IGI Global
38. Brickley, D., & Miller, L. (2006). FOAF Vocabulary Specification, Available at: <http://xmlns.com/foaf/0.1/>
39. Bursać, M., & Milošević, D. (2018). Adaptive Testing With LMS Moodle. In *X međunarodni naučno-stručni skup IT za elektronsko obrazovanje IteO 2018*, Panevropski univerzitet Aperion
40. Castro-Schez, J. J., Glez-Morcillo, C., Albusac, J., & Vallejo, D. (2021). An intelligent tutoring system for supporting active learning: A case study on predictive parsing learning. *Information Sciences*, 544, 446-468.
41. Celik, D., & Magoulas, G. D. (2016). A review, timeline, and categorization of learning design tools. In: Chiu, D.K.W. and Marenzi, I. and Nanni, U. and Spaniol, M. (eds.) *Advances in Web-Based Learning – ICWL 2016*. Lecture Notes in Computer Science 10013. New York, U.S.: Springer, 3-13.
42. Chabih, O., Sbai, S., Behja, H., Louhdi, M. R. C., & Trousse, B. (2021). New approach to determine the optimal number of clusters K in unsupervised classification. In *2020 6th IEEE Congress on Information Science and Technology (CiSt)* (pp. 348-352). IEEE.
43. Charbuty, B., & Abdulazeez, A. (2021). Classification based on decision tree algorithm for machine learning. *Journal of Applied Science and Technology Trends*, 2(01), 20-28.

44. Chien, Y. C., Liu, M. C., & Wu, T. T. (2020). Discussion-record-based prediction model for creativity education using clustering methods. *Thinking Skills and Creativity*, 36, 100650
45. Clark, K. R. (2018). Learning theories: constructivism. *Radiologic technology*, 90, 180-182
46. Composite Capability/Preference Profiles (CC/PP): Structure and Vocabularies 2.0. W3C Working Group Note 29 June 2010. [Online] Available at: <https://www.w3.org/TR/CCPP-struct-vocab2/>
47. De Bra, P. (2000). Pros and Cons of Adaptive Hypermedia in Web-Based Education. *CyberPsychology & Behavior*, 3. 10.1089/109493100316247.
48. De, S., Zhou, Y., & Moessner, K. (2017). Ontologies and context modeling for the Web of Things. *Managing the Web of Things*, 3-36.
49. Devedžić, V. (2006). *Semantic web and education* (Vol. 12). Springer Science & Business Media.
50. Devedzic, V., Jovanovic, J. & Gasevic, D. (2007). The pragmatics of current e-Learning standards. *IEEE Internet Computing*, 11(3), 19-27.
51. Dhika, H., Destiawati, F., & Jaya, M. (2021). Data Mining Approach for Learning management system. In *IOP Conference Series: Materials Science and Engineering* (Vol. 1088, No. 1, p. 012013). IOP Publishing.
52. Drozdova, A. A.. & Guseva, A. I. (2017). Modern Technologies of E-Learning and its Evaluation of Efficiency. *Procedia-Social and Behavioral Sciences*, 237, 1032-1038.
53. Durak, G., & Çankaya, S. (2019). Learning Management Systems: Popular LMSs and Their Comparison. In Khosrow-Pour, D.B.A., M. (Ed.), *Handbook of Research on Challenges and Opportunities in Launching a Technology-Driven International University* (pp. 299-320). IGI Global.
54. Duval, E., Hodgins, W., Sutton, S., & Weibel, S. L. (2002). Metadata principles and practicalities. *D-lib Magazine*, 8(4), 1-10.
55. Duval, E. (2002). 1484.12. 1 IEEE Standard for learning Object Metadata, IEEE Learning Technology Standards Committee.
56. El-Bishouty, M. M., Aldraiweesh, A., Alturki, U., Tortorella, R., Yang, J., Chang, T. W. & Graf, S. (2019). Use of Felder and Silverman learning style model for online course design. *Educational Technology Research and Development*, 67(1), 161-177.
57. Elmabaredy, A., Elkholy, E., & Tolba, A. A. (2020). Web-based adaptive presentation techniques to enhance learning outcomes in higher education. *Research and Practice in Technology Enhanced Learning*, 15(1), 1-18.
58. Ennouamani, S., & Mahani, Z. (2017). An overview of adaptive e-Learning systems. In *2017 eighth international conference on intelligent computing and information systems (ICICIS)*, 342-347. IEEE.

59. Evans, J. C., Yip, H., Chan, K., Armatas, C., & Tse, A. (2020). Blended learning in higher education: professional development in a Hong Kong university. *Higher Education Research & Development*, 39(4), 643-656.
60. Fatimah, A. S., & Santiana, S. (2017). Teaching in 21st century: Students-teachers' perceptions of technology use in the classroom. *Script Journal: Journal of Linguistic and English Teaching*, 2(2), 125.
61. Felder, R. M., & Silverman, L. K. (1988). Learning and teaching styles in engineering education. *Engineering education*, 78(7), 674-681.
62. Felder, M. R., & Brent, R. (2005). Understanding Student Differences. *Journal of Engineering Education*, 94, 1, 57-72.
63. Felder, M. R., & Spurlin, J. E. (2005). Applications, Reliability, and Validity of the Index of Learning Styles. *Intl. Journal of Engineering Education*, 21(1), 103-112.
64. Feldman, J., Monteserin, A., & Amandi, A. (2015). Automatic detection of learning styles: state of the art. *Artif Intell Rev* 44, 157–186
65. FitzGerald, E., Jones, A., Kucirkova, N., & Scanlon, E. (2018). A literature synthesis of personalised technology-enhanced learning: what works and why. *Research in Learning Technology*, 26.
66. Fletcher, J. D. (2019). Adaptive instructional systems and digital tutoring. In *International Conference on Human-Computer Interaction*, 615-633. Springer, Cham.
67. Freedman, R. D., Stumpf, S. (1980). Learning style theory: less than meets the eye. *Academy of Management Review Journal*, vol. 6., 297-299.
68. Freire, M. & Fernández-Manjón, B. (2016). Metadata for Serious Games in Learning Object Repositories, In *IEEE Revista Iberoamericana de Tecnologías del Aprendizaje*, vol. 11, no. 2, 95-100.
69. Fri, C., & Elouahbi, R. (2021). Machine Learning and Deep Learning applications in E-Learning Systems: A Literature Survey using Topic Modeling Approach. In *2020 6th IEEE Congress on Information Science and Technology (CiSt)* (267-273). IEEE.
70. Furner, J. (2020). Definitions of “Metadata”: A Brief Survey of International Standards. *Journal of the Association for Information Science and Technology*, 71(6), E33-E42.
71. Gajwani, J., & Chakraborty, P. (2021). Students' Performance Prediction Using Feature Selection and Supervised Machine Learning Algorithms. In *International Conference on Innovative Computing and Communications* (pp. 347-354). Springer, Singapore.
72. Garrick, B., Pendergast, D., & Geelan, D. (2017). Introduction to the philosophical arguments underpinning personalised education. In *Theorising personalised education*, 1-16. Springer, Singapore.
73. Gilbert, B. (2015). Online learning revealing the benefits and challenges. *Education Masters*. Paper 303.

74. Goodyear, P. (2020). Design and co-configuration for hybrid learning: Theorising the practices of learning space design. *British Journal of Educational Technology*, 51(4), 1045-1060.
75. Guimaraes, M. (2018). Data warehouse and data mining with SQL server. *Journal of Computing Sciences in Colleges*, 34(1), 233-234.
76. Gunesekera, A. I., Bao, Y., & Kibelloh, M. (2019). The role of usability on e-Learning user interactions and satisfaction: A literature review. *Journal of Systems and Information Technology*.
77. Gupta, M., & Batra, G. (2021). Investigation of Machine Learning Assistance to Education. In *2021 5th International Conference on Computing Methodologies and Communication (ICCMC)* (pp. 777-782). IEEE.
78. Hadullo, K., Oboko, R., & Omwenga, E. (2017). A model for evaluating e-Learning systems quality in higher education in developing countries. *International Journal of Education and Development using ICT*, 13(2).
79. Hamzah, A. (2020). A Prototype of Effective Online Teaching Tools with Adaptive Navigation Support. In *IOP Conference Series: Materials Science and Engineering*, Vol. 722, No. 1, p. 012058.
80. Hardy, I., Decristan, J., & Klieme, E. (2019). Adaptive teaching in research on learning and instruction. *Journal for educational research online*, 11 (2019) 2, 169-191.
81. Hariyanto, D., & Kohler, T. (2017). An adaptive user interface for an e-Learning system by accommodating learning style and initial knowledge. In *International Conference on Technology and Vocational Teachers (ICTVT 2017)*. Atlantis Press.
82. Herder E., Sosnovsky S., & Dimitrova V. (2017). Adaptive Intelligent Learning Environments. In: Duval E., Sharples M., Sutherland R. (eds) *Technology Enhanced Learning*. Springer, Cham.
83. Henze, N. (2005). Personal Readers: Personalized Learning Object Readers for the Semantic Web. In *AIED*, Vol. 5, 274-281.
84. Honey, P. (2004). Honey and Mumford Learning Styles Questionnaire, PeterHoney Learning (2001).
85. Honey, P., & Mumford, A. (1992). *The manual of learning styles* (Vol. 3). Maidenhead: Peter Honey.
86. Hussein, A. M. A., & Al-Chalabi, H. K. M. (2020). Pedagogical Agents in an Adaptive E-Learning System. *SAR Journal - Science and Research*, 3/2020, 1, 24-30.
87. IMS Learning Design Best Practice and Implementation Guide, Version 1.0 Final Specification, IMS Global Learning Consortium Inc. (2003). [Online]. Available at: http://www.imsglobal.org/learningdesign/ldv1p0/imsld_bestv1p0.html
88. IMS Content Packaging Information Model, Version 1.1.4, IMS Global Learning Consortium Inc. (2004). Available at: <http://www.imsglobal.org/content/packaging/>.

89. Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 1-11.
90. Jingga, K., & Sunindyo, W. D. (2020). Component-based Development Using Moodle As Alternative for E-Learning Software Development. In *2020 12th International Conference on Information Technology and Electrical Engineering (ICITEE)*, 125-130, IEEE.
91. Jeremic, Z., Jovanovic, J., & Gasevic, D. (2013). Personal Learning Environments on Social Semantic Web. *Semantic Web Journal*, Vol. 4, No. 1, 23-51.
92. Jovanovic, J. (2006). *Semantic Web Technologies for Dynamic Assembly of Personalized Learning Content*, Andrejević Foundation, Belgrade
93. Jovanović, J., Gašević, D., & Devedžić, V., (2006). Ontology-based Automatic Annotation of Learning Content. *International Journal on Semantic Web and Information System*, Vol. 2, No. 2, 91-119.
94. Julianto, I. T., Rohmanto, R., Sarifudin, U., & Widiyanto, S. R. (2021). Performance Comparison of Data Mining Algorithms Which Occupy the Top: C4. 5 and SVM. *Jurnal Mantik*, 4(4), 2499-2507.
95. Kadam, V. (2020). Thematic Issue Intelligent Data Mining for Data Analysis and Knowledge Discovery. *Recent Advances in Computer Science and Communications (Formerly: Recent Patents on Computer Science)*, 13(3), 433-434.
96. Karagiannis I., & Satratzemi M. (2020). Implementation of an Adaptive Mechanism in Moodle Based on a Hybrid Dynamic User Model. In: Auer M., Tsiatsos T. (eds) *The Challenges of the Digital Transformation in Education*. ICL 2018. Advances in Intelligent Systems and Computing, vol 916. Springer, Cham.
97. Khamparia, A. & Pandey, B. (2020). Association of learning styles with different e-Learning problems: a systematic review and classification. *Education and Information Technologies*, 25(2), 1303-1331.
98. Khan, J. A. (2018). *A visual adaptive authoring framework for adaptive hypermedia* (Doctoral dissertation, University of Warwick).
99. Khan, A., & Ghosh, S. K. (2021). Student performance analysis and prediction in classroom learning: A review of educational data mining studies. *Education and information technologies*, 26(1), 205-240
100. Koper, R., & Olivier, B., (2004). Representing the Learning Design of Units of Learning. *Educational Technology & Society*, Vol. 7, N. 3, 97-111.
101. Kotecha, A. (2019). Learning styles. *InnovAiT*, 12(5), 276-280.
102. Кречетов, И. А., & Романенко, В. В. (2020). Реализация методов адаптивного обучения. *Вопросы образования*, (2).
103. Kukartsev, V. V., Chzhan, E. A., Tynchenko, V. S., Antamoshkin, O. A., & Stupina, A. A. (2018). Development of adaptive educational course in the SibFU E-Learning system. *J. of Siber. Fed. Univer. Humanities and Social Sci.*, 11(5), 740–52.

104. Kumar Basak, S., Wotto, M., & Belanger, P. (2018). E-Learning, M-learning and D-learning: Conceptual definition and comparative analysis. *E-Learning and Digital Media*, 15(4), 191-216.
105. Lal, I. B., & Sachi, S. (2021). An Overview of Data Mining Techniques. *International Journal of Advanced Research in Science, Communication and Technology (IJARSCT)*, Vol. 1, 1, 66-71.
106. Lee, J., & Park, O. (2008). Adaptive instructional systems. *Handbook of research on educational communications and technology*, 469-484.
107. Li, X., Wang, X., & Gu, X. (2019). A design framework for adaptive e-Learning environment. In *Fourth International Workshop on Pattern Recognition*, Vol. 11198, p. 111980. International Society for Optics and Photonics.
108. Li, L. X., Huo, Y., & Lin, J. C. W. (2021). Cross-Dimension Mining Model of Public Opinion Data in Online Education Based on Fuzzy Association Rules. *Mobile Networks and Applications*, 1-14.)
109. Lozano, R., Merrill, M. Y., Sammalisto, K., Ceulemans, K., & Lozano, F. J. (2017). Connecting competences and pedagogical approaches for sustainable development in higher education: A literature review and framework proposal. *Sustainability*, 9(10), 1889.
110. Martin, F., Chen, Y., Moore, R. L., & Westine, C. D. (2020). Systematic review of adaptive learning research designs, context, strategies, and technologies from 2009 to 2018. *Educational Technology Research and Development*, 68(4), 1903-1929.
111. Mödritscher, F., Luengo, V., Law, E. L. C., Hoppe, H. U. & Stegmann, K. (2016). Grand Challenge Problem 7: Towards Adaptive and Adaptable Learning in Massive Online Courses. In *Grand Challenge Problems in Technology-Enhanced Learning II: MOOCs and Beyond*, 33-37. Springer, Cham.
112. Mudrák, M., Turcani, M. & Burianová, M. (2018). Creation of personalized learning courses in adaptive LMS. *Proceedings of DIVAI*, 118-129.
113. Mudrák, M. (2017). Analysis and implementation of adaptive course in Moodle, *15th International Conference on Emerging eLearning Technologies and Applications (ICETA), Stary Smokovec, 2017*, 1-6.
114. Mumford, A. (1999). *Effective learning*. London. CIPD Publishing.
115. Musumba, G. W., & Wario, R. D. (2018). Towards a Context-Aware Adaptive e-Learning Architecture. In *Annual Conference of the Southern African Computer Lecturers' Association*, 191-206. Springer, Cham.
116. Nagy, Z. (2018). *Artificial Intelligence and Machine Learning Fundamentals: Develop real-world applications powered by the latest AI advances*. Packt Publishing Ltd.
117. Naj'iyah, A. L., & Suyatna, A. (2021). Learning Strategies Design to Accommodate Learning Styles, Initial Knowledge and Reduce The Differences of Scientific Reasoning and Argumentation Performance. *Journal of Physics: Conference Series*, Vol. 1788, No. 1, p. 012031. IOP Publishing.

118. Nejdil, W., Wolf, B., Qu, C., Decker, S., Sintek, M., Naeve, A., ... & Risch, T. (2002). EDUTELLA: a P2P networking infrastructure based on RDF. In *Proceedings of the 11th international conference on World Wide Web*, 604-615.
119. Nokelainen, P. (2004). Conceptual definition of the technical and pedagogical usability criteria for digital learning material. *EdMedia+ Innovate Learning*, 4249-4254. Association for the Advancement of Computing in Education (AACE).
120. Ochoa, X., & Ternier, S. (2017). Technical learning infrastructure, interoperability and standards. *Technology Enhanced Learning*, 145-155. Springer, Cham.
121. Ouadoud, M., Chafiq, T., Rida, N., & Chkouri, M. (2019). Generate a Meta-Model Content for Collaboration Space of Learning Management System Compatible with IMS-LD. *International Association of Online Engineering*. Retrieved April 26, 2021 from <https://www.learntechlib.org/p/207193/>.
122. Pang, G., Shen, C., Cao, L., & Hengel, A. V. D. (2021). Deep learning for anomaly detection: A review. *ACM Computing Surveys (CSUR)*, 54(2), 1-38.
123. Papadimitriou, A., & Gyftodimos, G. (2017). The Role of Learner Characteristics in the Adaptive Educational Hypermedia Systems: The Case of the MATHEMA. *International Journal of Modern Education and Computer Science*, 9, 55-68.
124. Papaterpos, C.M., Zafiris, P.A., Georgantis, N.P., & Papatheodorou, T.S. (2002). Web-Based Adaptive Educational Systems. In: Chin W., Patricelli F., Milutinović V. (eds) *Electronic Business and Education. Multimedia Systems and Applications Series*, vol 20., 91-123. Springer, Boston, MA.
125. Peng, H., Ma, S., & Spector, J. M. (2019). Personalized adaptive learning: an emerging pedagogical approach enabled by a smart learning environment. *Smart Learning Environments*, 6(1), 1-14.
126. Pittich, D., & Tenberg, R. (2020). Hybrid Learning Landscapes in vocational education. *Journal of Technical Education (JOTED)*, 8(2), 1-12.
127. Premlatha, K. R., & Geetha, T. V. (2015). Learning content design and learner adaptation for adaptive e-Learning environment: a survey. *Artificial Intelligence Review*, 44(4), 443-465.
128. Putro, B. E., & Saepurohman, T. (2020, April). A Classification Approach to Predicting Beef Knuckle Quality using the Decision Tree and Naïves Bayes Method: Case Study: Tiga Bersaudara Factory. In *2020 IEEE 7th International Conference on Industrial Engineering and Applications (ICIEA)*. 779-783. IEEE.
129. Raj, N. S., & Renumol, V. G. (2018). Architecture of an adaptive personalized learning environment (APLE) for content recommendation. In *Proceedings of the 2nd International Conference on Digital Technology in Education*, 17-22.
130. Rajagopalan, G. (2021). Descriptive Data Analysis Basics. In *A Python Data Analyst's Toolkit* (pp. 101-116). Apress, Berkeley, CA.
131. Raschka, S., & Mirjalili, V. (2017). *Python Machine Learning: Machine Learning and Deep Learning with Python*. Scikit-Learn, and TensorFlow. Second edition ed.

132. Rasheed, R. A., Kamsin, A., & Abdullah, N. A. (2020). Challenges in the online component of blended learning: A systematic review. *Computers & Education, 144*, 103701.
133. Recker, M., Walker, A., & Willey, D. (2001). "Collaboratively filtering learning objects", In D. A. Wiley (Ed.) *The Instructional Use of Learning Objects*, AECT, Bloomington, USA.
134. Reis, R. C. D., Isotani, S., Rodriguez, C. L., Lyra, K. T., Jaques, P. A., & Bittencourt, I. I. (2018). Affective states in computer-supported collaborative learning: Studying the past to drive the future. *Computers & Education, 120*, 29-50.
135. Rimale, Z., Benlahmar, E. H., & Tragha, A. (2017). A New Responsive SCORM Design (RSCOD) Approach Based Semantic Learning Object (SLO) Using SharePoint Learning Kit (SLK). In *Proceedings of the 2nd international Conference on Big Data, Cloud and Applications*, 1-6.
136. Rodrigues, H., Almeida, F., Figueiredo, V., & Lopes, S. L. (2019). Tracking e-Learning through published papers: A systematic review. *Computers & Education, 136*, 87-98.
137. Romero, C., & Ventura, S. (Eds.). (2006). *Data mining in e-Learning* (Vol. 4). WIT press.
138. Romero, C., & Ventura, S. (2020). Educational data mining and learning analytics: An updated survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 10*(3), e1355
139. Rosson, M. B., & Carroll, J. M. (2009). Scenario based design. *Human-computer interaction. boca raton, FL*, 145-162.
140. Rotondo, A., & Quilligan, F. (2020). Evolution Paths for Knowledge Discovery and Data Mining Process Models. *SN Computer Science, 1*(2), 1-19.
141. Rozo, H., & Real, M. (2019). Pedagogical Guidelines for the Creation of Adaptive Digital Educational Resources: A Review of the Literature. *Journal of Technology and Science Education, 9*(3), 308-325.
142. Sáiz-Manzanares, M. C., Rodríguez-Díez, J. J., Díez-Pastor, J. F., Rodríguez-Arribas, S., Marticorena-Sánchez, R., & Ji, Y. P. (2021). Monitoring of Student Learning in Learning Management Systems: An Application of Educational Data Mining Techniques. *Applied Sciences, 11*(6), 2677.
143. Şahin, M., & Yurdugül, H. (2020). Educational data mining and learning analytics: past, present and future. *Bartın Üniversitesi Eğitim Fakültesi Dergisi, 9*(1), 121-131.
144. Salas, R. P. (2020). Reusable Learning Objects: An Agile Approach. In *2020 IEEE Frontiers in Education Conference (FIE)*, 1-6. IEEE.
145. Salloum, S. A., Alshurideh, M., Elnagar, A., & Shaalan, K. (2020). Mining in educational data: review and future directions. In *Joint European-US Workshop on Applications of Invariance in Computer Vision* (pp. 92-102). Springer, Cham.
146. Sarrikoski, L., Salojarvi, S., Del Corso, D., & Ovcin, E., (2000). The 3DE: An Environment for the Development of Learner-Oriented Customized Educational Packages, *ASEE/IEEE-Frontiers in Education Conference 2000*.

147. Sariyalçinkaya, A. D., Karal, H., Altinay, F., & Altinay, Z. (2021). Reflections on Adaptive Learning Analytics: Adaptive Learning Analytics. In *Advancing the Power of Learning Analytics and Big Data in Education* (pp. 61-84). IGI Global.
148. Schneider, J., & Handali, J. (2019). Personalized explanation in machine learning: A conceptualization. *arXiv preprint arXiv:1901.00770*.
149. Sfenrianto, S., Hartarto, Y. B., & Akbar, H. (2018). An adaptive learning system based on knowledge level for english learning. *International Journal of Emerging Technologies in Learning (iJET)*, 13(12), 191-200.
150. Shershneva, V., Vainshtein, Y., Kochetkova, T. & Esin, R. (2019). Technological approach to development of adaptive e-Learning system. In *SHS Web of Conferences*, Vol. 66, p. 01014. EDP Sciences.
151. Shen, Y. H. (2018). Design of Digital Network Shared Learning Platform based on SCORM Standard. *International Journal of Emerging Technologies in Learning*, 13(7).
152. Shrestha, S., & Pokharel, M. (2020). Data Mining Applications Used in Education Sector. *Journal of Education and Research*, 10(2), 27-51.
153. Soltani, A., & Izquierdo, A. (2019). Adaptive learning under expected and unexpected uncertainty. *Nature Reviews Neuroscience*, 20(10), 635-644.
154. Sorokina, S. (2020). Data science and machine learning in higher educational technologies. *BBK 1 E91*, 96
155. Stefanovic N., Stefanovic D., & Arsovic B. (2013). Adaptivity in E-Learning LMS platform, *Metallurgia International*, vol 18, no.3, 56-162
156. Stoyanov, S., & Kirschner, P. (2017). Erratum to: Expert concept mapping method for defining the characteristics of adaptive E-Learning: ALFANET project case. *Educational Technology Research and Development*, 65(2), 503-503.
157. Stojanović, Lj., Staab, S., & Studer, R., (2001), eLearning based on the Semantic Web, In *Proceedings of the WebNet 2001 - World Conference on the WWW and the Internet*, Orlando, Florida, USA, October, 2001.
158. Supangat, S., & Mohd Zainuri, B. S. (2020). Development of E-Learning System Using Felder and Silverman's Index of Learning Styles Model. *Development of E-Learning System Using Felder and Silverman's Index of Learning Styles Model*, 9(5), 8554-8561.
159. Sweta, S. (2021). Framework for Adaptive E-Learning System. In *Modern Approach to Educational Data Mining and Its Applications*, 51-62. Springer, Singapore.
160. Tawafak, R. M., AlSideir, A., Alfarsi, G., Al-Nuaimi, M. N., Malik, S. I., & Jabbar, J. (2019). E-Learning vs. traditional learning for learners satisfaction. *E-Learning*, 29(3), 388-397.
161. Terzieva, T., & Rahnev, A. (2018). Basic stages in developing an adaptive e-Learning scenario. *Int. J. Innov. Sci. Eng. Technol*, 5, 50-54.
162. Tjong, Y., Sugandi, L., Nurshafita, A., Magdalena, Y., Evelyn, C., & Yosieto, N. S. (2018). User Satisfaction Factors on Learning Management Systems Usage. In *2018*

- International Conference on Information Management and Technology (ICIMTech)*, 11-14. IEEE.
163. Turel, V. (2019). Adaptive Hypermedia in Education. In *Advanced Methodologies and Technologies in Modern Education Delivery*, 178-191. IGI Global.
 164. Truong, H. M. (2016). Integrating learning styles and adaptive e-Learning system: Current developments, problems and opportunities. *Computers in human behavior*, 55, 1185-1193.
 165. Urgo, K., Arguello, J., & Capra, R. (2019). Anderson and krathwohl's two-dimensional taxonomy applied to task creation and learning assessment. In *Proceedings of the 2019 ACM SIGIR International Conference on Theory of Information Retrieval*, 117-124.
 166. Van Assche, F., & Massart, D., (2004). Federation and Brokerage of Learning Objects and Their Metadata, In *Proceedings of the IEEE International Conference on Advanced Learning Technologies, ICAALT 2004*, Joensuu, Finland.
 167. Villegas-Ch, W., Román-Cañizares, M., & Palacios-Pacheco, X. (2020). Improvement of an online education model with the integration of machine learning and data analysis in an LMS. *Applied Sciences*, 10(15), 5371.
 168. Villegas-Ch, W., Roman-Cañizares, M., Jaramillo-Alcázar, A., & Palacios-Pacheco, X. (2020a). Data Analysis as a Tool for the Application of Adaptive Learning in a University Environment. *Applied Sciences*, 10(20), 7016.
 169. Wang, G., Luo, P., Lin, L., & Wang, X. (2017). Learning object interactions and descriptions for semantic image segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 5859-5867.
 170. Wang, Y., Xia, Y., He, T., Tian, F., Qin, T., Zhai, C., & Liu, T. Y. (2019). Multi-agent dual learning. In *Proceedings of the International Conference on Learning Representations (ICLR) 2019*.
 171. Williams, B. W., Byrne, P. D., Williams, N. V., & Williams, M. V. (2017). Dreyfus and Dreyfus and indicators of behavioral performance: a study of measurement convergence. *Journal of Continuing Education in the Health Professions*, 37(1), 50-54.
 172. Xie, H., Chu, H. C., Hwang, G. J., & Wang, C. C. (2019). Trends and development in technology-enhanced adaptive/personalized learning: A systematic review of journal publications from 2007 to 2017. *Computers & Education*, 140, 103599.
 173. Yang, C., Chiang, F. K., Cheng, Q., & Ji, J. (2021). Machine Learning-Based Student Modeling Methodology for Intelligent Tutoring Systems. *Journal of Educational Computing Research*, 0735633120986256.
 174. Yousaf, N., Arshad, A., Nouman, M., & Arshad, U. (2018). Towards adaptive and responsive web design: A systematic literature review. *Language*, 1, 40.
 175. Забунов, С., & Гайдарова, М. (2010) Сравнение между алгоритмично-формални и самоопределящо-креативни методи за индивидуализация в електронното обучение. *Списание на Софийския Университет за електронно обучение*, 2010/4

176. Zagulova, D., Boltunova, V., Katalnikova, S., Prokofyeva, N., & Synytsya, K. (2019). Personalized E-Learning: Relation Between Felder–Silverman Model and Academic Performance. *Applied Computer Systems*, 24(1), 25-31.
177. Zajac, M., & Piekarczyk M., (2003). Algorytmy metod uczenia się w systemie komputerowego wspomaganie nauczania woparcie o metodologię Reusable Learning Objects (RLO). *Informatyka Teoretyczna i Stosowana*, Vol. 3, No. 5, 167-177.
178. Zapata-Rivera, D. (2020). Open Student Modeling Research and its Connections to Educational Assessment. *International Journal of Artificial Intelligence in Education*, 1-17.

БИОГРАФИЈА АУТОРА

Бранка Арсовић, рођена је 4. августа 1972. год. у Ужицу. Основне академске студије је завршила 1996. год. на Природно-математичком факултету у Крагујевцу, Универзитета у Крагујевцу, на Институту за Математику и информатику, смер Рачунарство и информатика и стекла звање Дипломирани математичар за рачунарство и информатику. Школовање наставља на истом факултету, где уписује постдипломске, магистарске студије, на катедри за Математику, група Информатика. Завршава магистарске студије са просечном оценом 10,00 и 2009. год. стиче звање магистра информатичких наука, одбравивши магистарску тезу под називом Напредне информационе технологије и образовни рачунарски софтвери у математичком образовању. Докторске студије уписује 2017. год. на Факултету техничких наука у Чачку, Универзитета у Крагујевцу, смер Информационе технологије.

По завршеним студијама заснива радни однос у Техничкој школи „Радоје Марић“ у Ужицу, као професор математике, касније и информатике. Положила је државни испит. Од 2000. год. ради на Педагошком факултету Ужице (тада Учитељски факултету у Ужицу), као асистент Информатике и повремено Методике наставе математике, а од 2019. год. као самостални стручно-технички сарадник за информационе системе и технологије, на истом факултету. Хонорарно је радила на ВПТШ у Ужицу и ПМФ-у у Крагујевцу.

Све време школовања и стручног усавршавања интезивно се бави научно-истраживачким радом. Тако да је аутор и коаутор 65 научних и стручних радова, који су објављени у међународним и домаћим часописима, монографијама и зборницима радова. Излагала је на бројним међународним и домаћим научним конференцијама. Аутор је 5 књига, од тога се 4 користе у факултетској настави, а три су монографије националног значаја. Учесник је више домаћих и међународних научних пројеката.

ДОДАТАК

Образац 1

А) ИЗЈАВА АУТОРА О ОРИГИНАЛНОСТИ ДОКТОРСКЕ ДИСЕРТАЦИЈЕ

Ја, Бранка Б. Арсовић, изјављујем да докторска дисертација под насловом:

“РАЗВОЈ АДАПТИВНОГ СИСТЕМА ЗА ЕЛЕКТРОНСКО УЧЕЊЕ ЗАСНОВАНОГ НА
НАУЦИ О ПОДАЦИМА“

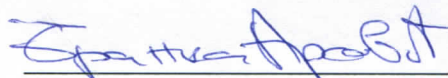
која је одбрањена на Факултету техничких наука у Чачку,

Универзитета у Крагујевцу представља *оригинално ауторско дело* настало као резултат *сопственог истраживачког рада*.

Овом Изјавом такође потврђујем:

- да сам *једини аутор* наведене докторске дисертације,
- да у наведеној докторској дисертацији *нисам извршио/ла повреду* ауторског нити другог права интелектуалне својине других лица,
- да умножени примерак докторске дисертације у штампаној и електронској форми у чијем се прилогу налази ова Изјава садржи докторску дисертацију истоветну одбрањеној докторској дисертацији.

У Чачку, 15. јул 2021. године,


потпис аутора

Б) ИЗЈАВА АУТОРА О ИСКОРИШЋАВАЊУ ДОКТОРСKE ДИСЕРТАЦИЈЕ

Ја, Бранка Б. Арсовић,

дозвољавам

не дозвољавам

Универзитетској библиотеци у Крагујевцу да начини два трајна умножена примерка у електронској форми докторске дисертације под насловом:

“РАЗВОЈ АДАПТИВНОГ СИСТЕМА ЗА ЕЛЕКТРОНСКО УЧЕЊЕ
ЗАСНОВАНОГ НА НАУЦИ О ПОДАЦИМА“

која је одбрањена на Факултету техничких наука у Чачку,

Универзитета у Крагујевцу, и то у целини, као и да по један примерак тако умножене докторске дисертације учини трајно доступним јавности путем дигиталног репозиторијума Универзитета у Крагујевцу и централног репозиторијума надлежног министарства, тако да припадници јавности могу начинити трајне умножене примерке у електронској форми наведене докторске дисертације путем *преузимања*.

Овом Изјавом такође

дозвољавам

не дозвољавам¹

¹ Уколико аутор изабере да не дозволи припадницима јавности да тако доступну докторску дисертацију користе под условима утврђеним једном од Creative Commons лиценци, то не искључује право припадника јавности да наведену докторску дисертацију користе у складу са одредбама Закона о ауторском и сродним правима.

припадницима јавности да тако доступну докторску дисертацију користе под условима утврђеним једном од следећих *Creative Commons* лиценци:

1) Ауторство

2) Ауторство - делити под истим условима

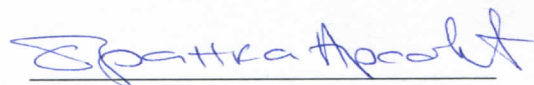
3) Ауторство - без прерада

4) Ауторство - некомерцијално

5) Ауторство - некомерцијално - делити под истим условима

6) Ауторство - некомерцијално - без прерада ⁱⁱ

У Чачку, 15. јул 2021. године,



потпис аутора

ⁱⁱ Молимо ауторе који су изабрали да дозволе припадницима јавности да тако доступну докторску дисертацију користе под условима утврђеним једном од *Creative Commons* лиценци да заокруже једну од понуђених лиценци. Детаљан садржај наведених лиценци доступан је на: <http://creativecommons.org.rs/>