

RĪGAS TEHNISKĀ UNIVERSITĀTE
E-studiju tehnoloģiju un humanitāro zinātņu fakultāte
Tālmācības studiju centrs

Ieva Vītoliņa

Doktora studiju programmas „E-studiju tehnoloģijas un pārvaldība” doktorante

**E-IEKĻAUŠANAS PROCESU UN
TEHNOLOĢISKO RISINĀJUMU PĒTĪJUMI**

Promocijas darbs

Zinātniskais vadītājs
Dr. phys.
ATIS KAPENIEKS

Rīga 2021

ANOTĀCIJA

Promocijas darba autore: **Ieva Vītoliņa**

Promocijas darba tēma: E-iekļaušanas procesu un tehnoloģisko risinājumu pētījumi.

Promocijas darba pētījuma jautājums: Kā galvenais pētījuma jautājums ir izvirzīts: Kādi tehnoloģiskie risinājumi ar indivīdu raksturojošiem faktoriem ļauj prognozēt indivīda e-iekļaušanas pakāpi e-studiju vidē digitālo prasmju mācību kursā?

Promocijas darba pētījuma objekts: Zināšanu radīšanas un pārneses process indivīda e-iekļaušanu prognozējošā informācijas sistēmā.

Promocijas darba mērķis: Izstrādāt indivīda e-iekļaušanas prognozes modeli e-studiju videi.

Promocijas darba uzdevumi mērķa sasniegšanai:

1. Izstrādāt e-iekļaušanu prognozējošu algoritmisko modeli:

1.1. Veikt pieejamo literatūras un citu avotu izvērtējumu e-iekļaušanas procesu jomā.

1.2. Veikt pieejamo literatūras un citu avotu izvērtējumu e-iekļaušanas prognozēšanas tehnoloģijām un metodēm.

1.3. Izveidot e-iekļaušanu prognozējošu algoritmisko modeli.

2. Izveidot e-iekļaušanu prognozējošu tehnoloģisko modeli (prototipu).

3. Novērtēt e-iekļaušanu prognozējošo tehnoloģisko modeli profesionālās izglītības iestāžu pedagogu e-iekļaušanas pakāpes noteikšanai.

Promocijas darba struktūra: Promocijas darbu veido ievads, 4 nodaļas, secinājumi, bibliogrāfiskais saraksts un 10 pielikumi. Promocijas darba pamatteksts ir 184 lapaspuses, tas satur 52 attēlus, 35 tabulas. Bibliogrāfiskajā sarakstā ir ietverti 387 nosaukumu informācijas avoti.

ABSTRACT

Author: **Ieva Vītolīņa**

Topic of the Doctoral Thesis: Research of the e-inclusion processes and technological solutions.

The Main Research Question: What technological solutions, using the factors characterizing the individual, allow to predict the degree of e-inclusion of the individual in the e-learning environment in the digital skills acquisition course?

The Object of the Research: The object of the research is the process of knowledge creation and transfer in the information system predicting the e-inclusion of the individual.

The Main Aim of the Doctoral Thesis: The research aims to develop a model that predicts an individual's e-inclusion in the e-learning environment.

The Tasks of the Doctoral Thesis:

To achieve the goal of the Doctoral Thesis, the following tasks are set:

1. To develop an algorithmic model predicting e-inclusion of individuals:
 - 1.1. To analyze the scientific literature and other sources related to the e-inclusion processes.
 - 1.2. To analyze the scientific literature and other sources related to the predictive technologies and methods.
 - 1.3. To create an algorithmic model predicting e-inclusion of individuals.
2. To create a technological model (prototype) predicting e - inclusion of individuals.
3. To evaluate the technological model predicting the e-inclusion of the teachers of the vocational education institutions.

Structure of the Doctoral Thesis: The Doctoral Thesis consists of an introduction, 4 sections, conclusions, references and 10 appendices. The total number of pages is 184, not including appendices. The Bibliography contains 387 titles. The Doctoral Thesis has been written in Latvian.

Saturs

ANOTĀCIJA.....	2
ABSTRACT.....	3
IEVADS.....	6
Pētījuma problēmsituācija un pamatojums.....	6
Pētījuma objekts.....	8
Pētījuma priekšmets.....	8
Pētījuma mērķis.....	8
Pētījuma jautājumi.....	8
Pētījuma darba uzdevumi.....	10
Aizstāvēšanai izvirzītās tēzes.....	10
Pētījuma metodes.....	11
Pētījuma posmi.....	11
Pētījuma bāze.....	12
Pētījuma zinātniskā novitāte, teorētiskā un praktiskā nozīme.....	12
Rezultātu aprobācija.....	13
Promocijas darba struktūra.....	15
1. E-IEKĻĀUŠANAS UN TĀS PROCESU ANALĪZE.....	16
1.1. Metodes izvēle e-iekļaušanu aprakstošā modeļa izveidē.....	16
1.2. E-iekļaušanas un tās procesu modelis.....	22
1.3. Kopsavilkums un secinājumi par e-iekļaušanu un tās procesu tendencēm.....	40
2. E-IEKĻĀUŠANAS PROGNOZĒŠANAS TEHNOLOĢIJU UN METOŽU ANALĪZE.....	43
2.1. Prognozēšanas, mācību analītikas un saistīto jēdzienu skaidrojums.....	44
2.2. Prognozējošu modeļu izveides metodes un tehnoloģijas.....	46
2.3. Prognozējošu modeļu novērtēšanas metodes un veikspējas rādītāji.....	49
2.4. Studentu sasniegumu prognozēšanā izmantoto pazīmju raksturojums.....	54
2.5. Studentu sasniegumus prognozējošo modeļu raksturojums.....	56
2.6. Prognozējošu informācijas sistēmu darbības procesi mašīnmācīšanās tehnoloģiju kontekstā.....	61
2.7. Prognozējoša modeļa izveides process un tā pielietojums e-iekļaušanu prognozējošā modeļa izveidē.....	62
2.8. E-iekļaušanu prognozējošā modeļa izveides posmi.....	68
2.9. Kopsavilkums un secinājumi par tehnoloģiju un metožu lietojumu studentu sasniegumus prognozējošā modeļa izveidē.....	70
3. INDIVĪDA E-IEKĻĀUŠANU IETEKMĒJOŠO FAKTORU UN PROGNOZĒJOŠO MODEĻU PĒTĪJUMS ZINĀŠANU RADĪŠANAS UN PĀRNESES PROCESA KONTEKSTĀ.....	72
3.1. Zināšanu pārvaldības teorijā balstīti e-iekļaušanu ietekmējoši faktori.....	73
3.2. Datu ieguve un sagatavošana pētījumiem par prognozējošo modeļu izveidi un iespējamo e-iekļaušanu ietekmējošo faktoru pārbaudi.....	75
3.3. Lineārās regresijas pieejā balstīta e-iekļaušanu prognozējošā modeļa izveide un prognozi ietekmējošo faktoru izvērtējums.....	88
3.4. Indivīda e-iekļautību raksturojošu klasteru izveide un e-iekļautību ietekmējošo faktoru atšķirību izvērtējums klasteros.....	105
3.5. Indivīda e-iekļautības modelēšana ar klasifikācijas algoritmiem un e-iekļautības faktoriem.....	112
3.6. Indivīda e-iekļautību prognozējošā algoritmiskā modeļa izveide.....	121
3.7. Kopsavilkums un secinājumi par indivīda e-iekļaušanu ietekmējošiem faktoriem un prognozējošo modeli.....	131
4. TEHNOLOĢISKAIS MODELIS UN TĀ NOVĒRTĒJUMS INDIVĪDA E-IEKĻAUTĪBAS PROGNOZĒŠANAI.....	133

4.1. E-iekļaušanu prognozējošas sistēmas funkcionālās prasības un galvenie darbības principi.....	133
4.2. E-iekļaušanu prognozējošas sistēmas prototips.....	145
4.3. E-iekļaušanu prognozējošā algoritmiskā modeļa un prototipa novērtējums.....	149
4.4. Kopsavilkums un secinājumi par e-iekļaušanu prognozējošo tehnoloģisko modeli un tā novērtējumu.....	154
SECINĀJUMI.....	156
IZMANTOTĀ LITERATŪRA.....	159
PIELIKUMI.....	185

IEVADS

Pētījuma problēmsituācija un pamatojums

Aizvien vairāk informācijas, nodarbinātības, mājsaimniecības, izglītības un valsts pārvaldes pakalpojumi ir pieejami digitālā veidā. Informācijas un komunikācijas tehnoloģijas (IKT) ir kļuvušas par neatņemamu ikdienas sastāvdaļu. E-iekļaušana ir ikviena indivīda un sabiedrības kopumā iesaistišana jebkurās valsts un sabiedrības aktivitātēs ar IKT starpniecību. E-iekļaušanas politikas mērķis ir samazināt atšķirības, kādas pastāv dažādiem indivīdiem IKT lietošanā un sekmēt to, ka ikviens indivīds IKT efektīvi izmanto izglītībai, personības pilnveidei un profesionālajai izaugsmei, tādējādi veicinot tautsaimniecības izaugsmi un indivīdu pilnvērtīgu iekļaušanos informācijas sabiedrības norisēs (*DiMaggio un Bonikowski, 2008; FreshMinds, 2008; Johansson un Tjäder, 2013*).

Lai arī e-iekļaušanas politikas stratēģiskie mērķi Eiropas Savienībā (ES) ir noteikti 2006. gadā, tos neizdodas sasniegt. 2021. gada 10. marta Eiropas Komisijas paziņojumā „Digitālais kompass līdz 2030. gadam – Eiropas ceļam digitālajā gadu desmitā” norādīts, ka joprojām sabiedrībā pastāv plaša starp tiem, kuriem ir iespējams izmantot digitālo tehnoloģiju sniegtās priekšrocības, un tiem, kuriem nav, tāpēc Eiropas Komisijas iecere 2030. gadam ir „digitāla sabiedrība, kas nevienu neatstāj malā” (*European Commission, 2006; European Commission, 2021*).

Statistikas dati liecina, ka indivīdi nepilnvērtīgi izmanto tehnoloģiju piedāvātās iespējas. *Eurostat (European Commission, 2017)* apkopotie dati liecina, ka 2017. gadā, lai arī 96,7 % ES iedzīvotāju ir prasmes, kā darboties internetā, iedzīvotāji izmanto internetu nepilnīgi, negūstot tehnoloģiju piedāvāto iespēju priekšrocības. Piemēram, tikai 67,6 % izmanto internetu, lai meklētu informāciju par precēm un pakalpojumiem, 51 % izmanto internetbankas, 16,8 % izmanto, lai meklētu darba piedāvājumus, 7,35 % – lai apgūtu e-studiju kursus.

ES pastāvīgi atzinusi digitālo pamatprasmju nozīmi visiem iedzīvotājiem un iekļāvusi tās gan 2006. gadā Rīgas e-iekļaušanas deklarācijā, gan 2010. gadā digitālajā programmā „Eiropa 2020” (*European Commission, 2006; European Commission, 2010*). Digitālās prasmes ir atzītas par vienu no astoņām pamatprasmēm, kas ir būtiski svarīgas ikkatram cilvēkam (Eiropas Padome, 2006; Eiropas Padome, 2018). Tomēr 2019. gadā ES tikai 56 % pieaugušo bija digitālās pamatprasmes (Eiropas Revīzijas palāta, 2021).

Neapstiprinās to pētnieku prognozes, kas uzskata, ka atšķirības starp indivīdu digitālām prasmēm un to lietošanu izzudīs laika gaitā un ka nav nepieciešams ietekmēt e-iekļaušanas procesa norisi (*ITU, 2006; Samuelson 2003*). Gluži pretēji, vairāki pētnieki norāda, ka atšķirības starp indivīdiem, to spējām pilnvērtīgi lietot tehnoloģijas nevis samazinās, bet gan pieaug (*Haight, Quan-Haase un Corbett, 2014*). E-iekļaušanas procesa veicināšanas aktualitāti nosaka tehnoloģiju attīstība, jo nemitīgi parādās arvien jaunas tehnoloģiju iespējas, tādējādi indivīdiem nepārtraukti ir jāattīsta prasmes izmantot jaunās tehnoloģijas (*European Commission, 2021; Yu u. c., 2018*). Attīstoties un mainoties tehnoloģijām, saglabājas problēma saistībā ar digitālo prasmju un iemaņu trūkumu. Eiropa cieš no arvien lielāka profesionālo IKT prasmju trūkuma un digitālo prasmju deficīta (*European Commission, 2012; Santos, Azevedo un Pedro, 2013*). Šis nepilnības daudzus indivīdus atstumj no digitālās

sabiedrības un ekonomikas un neļauj izpausties. Eiropas Komisija ir noteikusi definējusi mērķi līdz 2030. gadam panākt, ka vismaz 80 % visu pieaugušo ir apguvuši digitālās pamatprasmes un ES informācijas un komunikācijas tehnoloģiju nozarē ir nodarbināti 20 miljoni speciālistu.

Lai veicinātu indivīdu e-iekļaušanu, ir izstrādāti ES politikas plānošanas dokumenti, īstenoti dažādi pētījumi par e-iekļaušanas procesiem gan ES, gan citviet pasaulē. Vairāku pētījumu rezultāti raksturo e-iekļaušanu, pamato e-iekļaušanas nepieciešamību, dod rekomendācijas par e-iekļaušanas deklarācijas pilnveidi un īstenošanu (*FreshMinds*, 2008). Pētītas dažādas mērķgrupas: cilvēki ar īpašām vajadzībām, vecāka gadagājuma cilvēki, dažādas minoritāšu un sociālās atstumtības riska grupas, iedzīvotāji ekonomiski neattīstītos reģionos (*Abad*, 2014; *Aerschot* un *Rodousakis*, 2008). Sniegti ieteikumi valsts pārvaldes un privātā sektora e-pakalpojumiem, lai to kvalitāte atbilstu mērķgrupu vajadzībām un lietošanas iespējām (*Achituv* u. c., 2008; *Bélangier* un *Carter*, 2009; *European Commission*, 2006). Dotas digitālās prasmes veicinošas rekomendācijas (*DLHLEG*, 2008), kā arī rekomendācijas e-apmācības īstenošanai (*Casacuberta*, 2007). Pētījumi ir vērsti uz to, kā nodrošināt tehnoloģiju pieejamību (*Rapaport*, 2009).

Līdzšinējie e-iekļaušanas pētījumi lielākoties ir virzīti uz dažādu sociāldemogrāfisko, ekonomisko un ģeogrāfisko rādītāju atšķirību noteikšanu starp indivīdiem, kuri izmanto informācijas un komunikācijas tehnoloģijas un kuri tās neizmanto (*Drabowicz*, 2014; *Haight*, *Quan-Haase* un *Corbett* 2014; *Hidalgo* u. c., 2020). Tomēr ir pētījumi, kuros norādīts, ka būtiski ir ne tikai sociāldemogrāfiskie un ekonomiskie rādītāji, bet nepieciešams meklēt arī jaunus e-iekļaušanu raksturojošos faktorus (*Sanz* un *Turlea* 2012). Pētījumu skaits, kuros meklētas sakarības starp e-iekļautu indivīdu un faktoriem, kas raksturo indivīdu, tā uzvedību e-iekļaušanas procesā, tajā skaitā digitālo prasmju apguves procesos, lai rezultātā sekmētu indivīdu e-iekļaušanu, ir nepietiekams.

Vairāki pētījumi liecina par to, ka ir nepieciešams meklēt sakarības, kas raksturo e-iekļautus indivīdus, vadoties vienlaikus no vairākiem faktoriem (*De Haan*, 2004). Nepieciešams turpināt e-iekļaušanas procesu izpēti, identificējot faktorus, kas ietekmē e-iekļaušanas procesu tā, ka indivīdi apgūst jaunās tehnoloģijas un jēgpilni tās lieto (*Guillen-Gamez* u. c., 2020; *Hatlevik* u. c., 2015). Šobrīd nav visaptverošas metodes, kas skata e-iekļaušanas procesu no digitālo prasmju jēgpilnas lietošanas aspekta.

Esošo pētījumu rezultāti nav palīdzējuši e-iekļaušanas procesā iesaistītajiem – gan tiem, kas vada šo procesu administratīvajā līmenī vai piedalās kā speciālisti, gan indivīdiem, kurus nepieciešams iekļaut. Sociālie un demogrāfiskie parametri vieni paši nespēj izskaidrot atšķirības, kas parādās motivācijā, IKT pieejamībā, digitālajās prasmēs un IKT lietošanā (*Zillien* un *Hargittai*, 2009). Lai arī ir veikti pētījumi par e-iekļaušanas procesiem, tomēr nav vienota skatījuma, kā veicināt to, ka jaunapgūtās digitālās prasmes tiek jēgpilni lietotas. Esošie e-iekļaušanas pētījumi ir aprakstoši, tie konstatē, ka pastāv atšķirības IKT lietošanā dažādām grupām, salīdzinot tās pēc vienas vai vairākām indivīdus raksturojošām sociodemogrāfiskām, ekonomiskām vai citām pazīmēm, un veic šo grupu aprakstu.

Vairums esošo pētījumu attiecas uz tādām e-iekļaušanas riska grupām kā vecāka gadagājuma cilvēki, imigranti, cilvēki ar īpašām vajadzībām. Tomēr mūsdienās rodas jaunas, agrāk neapvertas riska grupas, piemēram, jaunieši un indivīdi, kam nepieciešams mainīt nodarbošanos vai kuriem profesionālajā darbībā jāprot izmantot IKT (*Csordás*, 2020; *Drabowicz*, 2014; *Sanz* un *Turlea*, 2012). Būtiska loma digitālās plaisas novēršanā ir izglītības

nozarē nodarbinātajiem, kam digitālā izglītība vienlaikus izvirza prasības būt gan digitālo prasmju ekspertiem, lai tās mācītu citiem, gan pastāvīgi pilnveidot savas profesionālās digitālo tehnoloģiju izmantošanas prasmes mācību procesā, kā tas norādīts ES Digitālās izglītības rīcības plānā 2021.–2027. gadam (*European Commission, 2020; LR Izglītības un zinātnes ministrija, 2021*). Izglītības iestāžu pedagogu digitālās prasmes tiek novērtētas kā nepietiekamas (*Instefford un Munthe, 2017; Jerrim un Sims, 2019*). Šo grupu digitālās iekļaušanas pētījumi ir nelielā skaitā.

Datu un mācību analītikas iespējas mācību sasniegumu veicināšanā tiek akcentētas ES Digitālās izglītības rīcības plānā 2018.–2020. gadam. Šajā plānā tiek uzsvērts arī tas, ka nepieciešami pētījumi izglītības jomā saistībā ar mākslīgo intelektu un mācību analītiku (*European Commission, 2018*). Lai gan literatūrā ir pieejami dažādi mācību analītikas pieejas izmantošanas gadījumi, tomēr visaptveroša mācību analītikas pieeja digitālo prasmju apguves procesa veicināšanai, kas nodrošinātu indivīda e-iekļaušanu, joprojām trūkst.

Pētījuma objekts

Pētījuma objekts ir zināšanu radīšanas un pārneses process indivīda e-iekļaušanu prognozējošā informācijas sistēmā.

Pētījuma priekšmets

Pētījuma priekšmets ir indivīda e-iekļaušanu prognozējoša modeļa izstrāde.

Pētījuma mērķis

Pētījuma mērķis ir izstrādāt indivīda e-iekļaušanas prognozes modeli e-studiju videi.

Pētījuma jautājumi

Galvenais pētījuma jautājums ir: kādi tehnoloģiskie risinājumi ar indivīdu raksturojošiem faktoriem ļauj prognozēt indivīda e-iekļaušanas pakāpi e-studiju vidē digitālo prasmju mācību kursā.

Lai pārbaudītu, cik lielā mērā ar lineārās regresijas modeli, izmantojot iepriekš noteiktos iespējamus e-iekļaušanas faktoros, kas raksturo zināšanu plūsmu starp instruktoru un indivīdu, var prognozēt e-iekļautības pakāpi profesionālo izglītības iestāžu pedagogiem, kuri apgūst digitālās prasmes instruktora vadībā e-vidē, definēti šādi pētījuma jautājumi:

- 1) cik lielā mērā pastāv saistība starp studenta vērtējumu instruktora vēlmei dalīties ar zināšanām un studenta e-iekļautības pakāpi;
- 2) cik lielā mērā pastāv saistība starp studenta apmierinātības līmeni ar e-mācību materiāliem un e-iekļautības pakāpi;
- 3) cik lielā mērā pastāv saistība starp studenta apmierinātības līmeni ar e-vidi un studenta e-iekļautības pakāpi;
- 4) cik lielā mērā pastāv saistība starp studenta vēlmi mācīties un studenta e-iekļautības pakāpi;
- 5) cik lielā mērā pastāv saistība starp studenta spējām mācīties un studenta e-iekļautības

pakāpi;

6) cik lielā mērā ir iespējams prognozēt studenta e-iekļautības pakāpi, vadoties no studenta ieinteresētības līmeņa un spējām mācīties, studenta apmierinātības līmeņa ar e-mācību materiāliem un e-vidi un instruktora vēlmi dalīties ar zināšanām.

Lai noskaidrotu iespējamās e-iekļaušanas faktorus, kas raksturo zināšanu plūsmu starp instruktoru un indivīdu, un atšķirības profesionālo izglītības iestāžu pedagogiem, kuri apgūst digitālās prasmes instruktora vadībā e-vidē un kuriem ir dažādas e-iekļautības pakāpes, definēti šādi pētījuma jautājumi:

1) kā studentu vērtējums instruktora vēlmei dalīties ar zināšanām atšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes pēc mācību kursa beigām nelieto;

2) kā studentu apmierinātības līmenis ar e-mācību materiāliem atšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes pēc mācību kursa beigām nelieto;

3) kā studentu apmierinātības līmenis ar e-vidi atšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes pēc mācību kursa beigām nelieto;

4) kā studentu vēlme mācīties atšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes pēc mācību kursa beigām nelieto;

5) kā studentu spējas mācīties atšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes pēc mācību kursa beigām nelieto.

Lai noskaidrotu, cik lielā mērā, izmantojot klasifikācijā balstītas metodes un iepriekš noteiktos indivīda e-iekļautību raksturojošos faktorus, iespējams paredzēt e-iekļautību profesionālo izglītības iestāžu pedagogiem, kuri apgūst digitālās prasmes instruktora vadībā klātienē un attālinātās nodarbībās e-vidē, definēti šādi pētījuma jautājumi:

1) kuri klasifikatori ģenerē modeļus ar augstākiem veiktspējas rādītājiem, paredzot indivīda e-iekļautību;

2) vai ir tāds klasifikators, ar kuru ģenerētie modeļi uzrāda augstākos veiktspējas rādītājus visiem mācību kursiem;

3) kā dažādiem datu kopu veidiem atšķiras modeļu veiktspējas rādītāji.

Lai noskaidrotu, cik lielā mērā, kombinējot lineārās regresijas, klasteranalīzes un klasifikācijas metodes, ir iespējams izveidot e-iekļautību prognozējošu modeli ar augstākiem veiktspējas rādītājiem, salīdzinot ar atsevišķi modeļu rādītājiem, kā arī vienlaikus atpazīstot pēc iespējas vairāk digitālās atstumtības riska studentus, definēti šādi pētījuma jautājumi:

1) kādām lineārās regresijas, klasteranalīzes un klasifikācijas modeļu kombinācijām, prognozējošā modeļa veiktspējas rādītāji ir augstāki;

2) cik procentu no visiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos, modelis spēj prognozēt kā piederošus riska grupai;

3) cik procentu no modeļa prognozētajiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos, reāli pieder riska grupai.

Lai novērtētu e-iekļaušanu prognozējošā modeļa veiktspēju un atbilstību mērķiem,

definēti šādi pētījuma jautājumi:

1) cik procentu no visiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos, modelis spēj prognozēt kā piederošus riska grupai;

2) cik procentu no modeļa prognozētajiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos, reāli pieder riska grupai;

3) cik lielā mērā ir iespējams ar modeli (būtiski nepazeminot modeļa veiktspējas rādītājus) prognozēt e-iekļautību indivīdiem, kas apgūst digitālās prasmesursos, kas atšķiras no tiem kursiem, ar kuru datiem ir apmācīts prognozējošais modelis.

Lai novērtētu e-iekļaušanu prognozējošā modeļa novirzi, definēti šādi pētījuma jautājumi:

1) par cik procentiem izmainās modeļa un to veidojošo modeļu prognozes pārklājums, tas ir skaits tam, cik modelis no visiem riska grupas studentiem – profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos, spēj atklāt;

2) par cik procentiem izmainās modeļa un to veidojošo modeļu prognozes precizitāte, tas ir, cik no visiem prognozētajiem riska grupas studentiem - profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos, tiešām nelietos jaunapgūtās prasmes;

3) par cik procentiem izmainās modeļa un to veidojošo modeļu F mēra vērtība, kas raksturo kopējo modeļa kvalitāti.

Pētījuma darba uzdevumi

Promocijas darba mērķa sasniegšanai definēti vairāki darba uzdevumi.

1. Izstrādāt e-iekļaušanu prognozējošu algoritmisko modeli.

1.1. Veikt pieejamo literatūras un citu avotu izvērtējumu e-iekļaušanas procesu jomā.

1.2. Veikt pieejamo literatūras un citu avotu izvērtējumu e-iekļaušanas prognozēšanas tehnoloģijām un metodēm.

1.3. Izveidot e-iekļaušanu prognozējošu algoritmisko modeli.

2. Izveidot e-iekļaušanu prognozējošu tehnoloģisko modeli (prototipu).

3. Novērtēt e-iekļaušanu prognozējošu tehnoloģisko modeli profesionālās izglītības iestāžu pedagogu e-iekļaušanas pakāpes noteikšanai.

Aizstāvēšanai izvirzītās tēzes

1. Indivīda e-iekļaušanu var prognozēt, izmantojot lineāro regresiju, klasteranalīzi, klasifikatorus un mākslīgā intelekta metodes.

2. Tehnoloģiski prognozēt indivīda e-iekļaušanas pakāpi ļauj šādi faktori: apmierinātības līmenis ar e-vidi un e-mācību materiāliem, ko indivīds izmanto jaunu digitālo prasmju apguvē; indivīda spēja un ieinteresētība apgūt jaunas digitālās prasmes; instruktora vēlme dalīties ar zināšanām.

3. Indivīda e-iekļaušanu prognozējošais modelis ir izmantojams digitālo prasmju apguves laikā e-iekļaušanas pakāpes prognozēšanai profesionālās izglītības pedagogiem Latvijā.

Pētījuma metodes

Promocijas darba teorētiskajā daļā ir izmantotas šādas teorētiskās metodes.

1. Zinātniskās literatūras un ES politikas plānošanas dokumentu izpēte un analīze e-iekļaušanas procesu jomā. Zinātniskās literatūras izpēte un analīze par studentu raksturojošajiem faktoriem zināšanu pārvaldības aspektā. Zinātniskās literatūras izpēte un analīze par studentu raksturojošo faktoru analīzes iespējām, tendencēm un tehnoloģiskajiem risinājumiem indivīda e-iekļaušanas pakāpi prognozējošā modeļa izstrādei.

2. *4EM (For Enterprise Modeling)* metode zināšanu strukturēšanai par e-iekļaušanu, tās mērķiem, biznesa likumiem, jēdzieniem, resursiem, dalībniekiem, procesiem.

Praktiskās daļas izstrādei ir izmantotas šādas empīriskās metodes.

1. Datu ieguves metodes.

1.1. Studentu aptaujas e-studiju vidē *Moodle* e-iekļaušanas faktoru noteikšanai e-iekļaušanas prognozēšanas (algoritmiskajam) modelim.

1.2. Studentu aptaujas e-pastā un telefonaptaujas studentu reālās e-iekļaušanas noteikšanai e-iekļaušanas prognozēšanas (algoritmiskajam) modelim.

2. Datu analīzes metodes.

2.1. Centrālās tendences analīze, lai raksturotu pētījuma izlases kopas galvenās pazīmes.

2.2. Pīrsona korelācijas analīze, lai noteiktu saistību starp e-iekļaušanas pakāpi un studentu raksturojošiem datiem.

2.3. Daudzfaktoru lineārās regresijas metodes, lai noteiktu e-iekļaušanas riska faktoru ietekmi uz studenta e-iekļaušanas pakāpi.

2.4. Datizraces metodes. Klasteranalīzei – *Expectation maximization* un pudurošanas pēc vidējiem (*kMeans*) algoritmi, lai noteiktu studentu klasterus. Klasificēšanas metodes – *LMT (Logistic Model Tree)*, *LWL (Locally Weighted Learning)*, naivais Beijesa (*Naive Bayes*) klasifikators, vienkāršā loģistiskā regresija, *OneR* klasifikators studenta e-iekļautības paredzēšanai.

3. E-iekļaušanu prognozējošā algoritmiskā un tehnoloģiskā modeļa izstrādei un novērtēšanai ir izmantotās šādas metodes.

3.1. Starpnozaru standarta process datizracei *CRISP-DM* un mašīnmācīšanās *CRISP-ML(Q)* modeļu izstrādei un kvalitātes novērtēšanai.

3.2. Datizraces metodes.

3.3. Desmitkārtu šķērsvalidācija tehnoloģiskā modeļa novērtēšanai.

3.4. Pārpratumu matricas, pārklājuma, precizitātes un F mēra vērtību noteikšana modeļa veikspējas novērtēšanai.

Pētījuma posmi

Pētījums ir veikts vairākos posmos.

2008.–2010. gads: pētīta e-iekļaušanas problēmsfēra, veikta literatūras analīze, izmantojot *EKD* modelēšanas pieeju. Izstrādāts pētījuma teorētiskais pamatojums un metodika.

2010.–2013. gads: veikts izvērtējums e-iekļaušanas prognozēšanas tehnoloģijām un metodēm, balstoties uz zinātnieka M. Nisena zināšanu pārvaldības teoriju, pētīti profesionālo skolu pedagogi, kuri apguva digitālās prasmes kombinētās mācīšanās kursā (e-studijas un

klātienēs nodarbības); veikta datu analīze un izveidoti indivīda e-iekļaušanas pakāpi raksturojoši lineārās regresijas vienādojumi.

2013.–2014. gads: sāka tehnoloģiskā modeļa izstrāde.

2014. gads: aktualizēts e-iekļaušanas problēmsfēras apraksts un veikta klasteranalīze profesionālo skolu pedagogiem, kuri apguva digitālās prasmes.

2014.–2016. gads: papildus iegūti dati par pedagogiem, kas apguva digitālās prasmes.

2019.–2021. gads: aktualizēts e-iekļaušanas problēmsfēras apraksts, aktualizēts izvērtējums e-iekļaušanas prognozēšanas tehnoloģijām un metodēm, izstrādāts un novērtēts e-iekļaušanu prognozējošs algoritmiskais un tehnoloģiskais modelis.

Pētījuma bāze

Pētījuma bāze ir dati par 767 profesionālo skolu pedagogiem, kuri no 2011. līdz 2012. gadam e-studiju sistēmas *Moodle* vidē apguva kursus digitālo prasmju pilnveidei, un 160 profesionālo skolu pedagogiem, kuri šos kursus apguva no 2014. līdz 2016. gadam. Dati vākti attiecīgi no 2011. līdz 2012. gadam un no 2014. līdz 2016. gadam.

Pētījuma zinātniskā novitāte, teorētiskā un praktiskā nozīme

Promocijas darba pētījuma novitāte

Izstrādāts modelis indivīda e-iekļaušanas prognozēšanai, kas satur jaunu tehnoloģiju (algoritmu), kura izveidē izmantotas lineārās regresijas, klasteranalīzes, klasificēšanas metodes, lai noteiktu indivīda e-iekļaušanas risku un to ietekmējošos faktorus.

Promocijas darba teorētiskais nozīmīgums

1. Izstrādātais e-iekļaušanas prognozēšanas tehnoloģiskais modelis atspoguļo jaunu tehnoloģiju (algoritmu) indivīda e-iekļaušanas noteikšanā digitālo prasmju apguves kontekstā.
2. Izstrādātais programmatūras prototips indivīda e-iekļaušanas prognozēšanai nodrošina iespēju analizēt un novērtēt indivīda riska faktorus turpmākajiem pētījumiem šajā problēmsfērā.
3. E-iekļaušanas prognozēšanas teorētiskie aspekti nodrošina teorētisko bāzi turpmākajiem pētījumiem šajā problēmsfērā.

Promocijas darba praktiskais nozīmīgums

1. E-iekļaušanas algoritmiskais modelis dod iespēju prognozēt indivīda e-iekļaušanas risku, noteikt indivīda riska faktorus digitālo prasmju apguves kontekstā un pieņemt atbilstošus lēmumus risku novēršanai, tādējādi veicinot sabiedrības e-iekļaušanu.
2. Izstrādātais e-iekļaušanas prognozēšanas programmatūras prototips var tikt izmantots digitālo prasmju apguvesursos, lai noteiktu faktorus, kas traucē indivīdam sasniegt tādus mācīšanās rezultātus, kas nodrošinātu jēgpilnu jaunapgūto prasmju izmantošanu profesionālām vajadzībām.
3. Ar izstrādāto e-iekļaušanas prognozēšanas programmatūras prototipu atklātos riska faktorus ir iespējams izvērtēt un novērst, gatavojot jaunus digitālo prasmju apguves kursus.

4. Izstrādātais e-iekļaušanas prognozēšanas programmatūras prototips var tikt izmantots digitālo prasmju apguves kursos kā atbalsta rīks instruktoram, lai tas lemtu par indivīdam piemērotāko mācīšanās pieeju.
5. Izstrādātais e-iekļaušanas prognozēšanas modelis var tikt izmantots e-studiju sistēmu izstrādē, studentu uzvedības analīzes rīku izveidē, mācību analītikas rīku izstrādē.

Rezultātu aprobācija

Darba līdzšinējo rezultātu aprobācija ir notikusi vairākās starptautiskajās konferencēs, atspoguļojot tos **ziņojumos**.

1. Vītoliņa I. Knowledge management model to facilitate e-inclusion. In 7th International JTEFS/BBCC Conference „Sustainable Development. Culture. Education” May 5–8, 2009, Daugavpils University, Daugavpils, Latvia.
2. Vītoliņa I. Assessment of learning outcomes and collaborative efforts in computer supported environments. In RTU 50th International Scientific Conference, October 16, 2009 in Riga, Latvia.
3. Vītoliņa I. E-inclusion modeling to improve digital skills of society. Liepājas Universitātes 13. starptautiskā zinātniskā konference „Sabiedrība un kultūra: haoss un harmonija” Liepāja, 2010. gada 28.–29. aprīlis.
4. Vītoliņa I. Wiki approach and student engagement in the learning process. 8th International JTEFS/BBCC Conference „Sustainable Development. Culture. Education” May 17–19, 2010, Paris, France.
5. Vītoliņa I. E-inclusion process and digital skill development of society. 9th International JTEFS/BBCC Conference „Sustainable Development. Culture. Education”: May 18–21, 2011, Siauliai University, Lithuania.
6. Vītoliņa I., Kapenieks A. 2012. A Study of the e-inclusion process in a real-life e-course delivery context . 10th International JTEFS/BBCC Conference ”Sustainable Development. Culture. Education”: May 22–25, 2012 Savonlinna, Finland.
7. Vītoliņa I., Kapenieks A. E-inclusion and knowledge flows in e-course delivery. Proceedings of the 5th International Conference on Computer Supported Education CSEDU 2013, Aachen, Germany, 6–8 May, 2013, pp. 417–422. Aachen: SCITEPRESS, 2013. ISBN 9789898565532.
8. Vītoliņa I. Zināšanu plūsmu analīze e-iekļaušanas procesā. Rīgas Tehniskā universitātes 54. starptautiskā konference, Latvija, Rīga 14.10.2013.
9. Vītoliņa I. A. User analysis for e-inclusion in a blended learning course delivery context. Rēzeknes Augstskolas starptautiskā konference „Sabiedrība, integrācija, izglītība”, 2014. gada 23. maijs.
10. Vitolina I., Kapenieks A. E-inclusion prediction modelling in blended learning courses. 23rd International Conference on Interactive Collaborative Learning (ICL2020), 2020, September, 23–25.

11. Vītoliņa I., Kapenieks A. (2021). Comparison of e-inclusion prediction models in blended learning courses. 19th International Conference on e-Society (ES 2021), 2021, March 3–5.

12. Vītoliņa I., Kapenieks A. Modeling the e-inclusion prediction system. 13th International Conference on Computer Supported Education CSEDU 2021, April 23–25.

Raksti pilna teksta konferenču rakstu krājumos

[1] Vītoliņa I. (2009). A knowledge management model to promote e-inclusion. *Proceedings of the 7th International JTEFS/BBCC Conference „Sustainable Development. Culture. Education”*: Research and Implementation of Education for Sustainable Development, Latvija, Daugavpils, 5.–8. maijs, 2009, pp. 6–38.

[2] Vītoliņa I. (2011). E-inclusion modeling to improve digital skills of society. *Liepājas Universitātes 13. starptautiskā zinātniskā konferences “Sabiedrība un kultūra” rakstu krājums*, 869.–878. lpp.

[3] Vītoliņa I., Kapenieks A. (2013). E-inclusion measurement by e-learning course delivery. *Procedia Computer Science*, 26, pp. 101–112.

[4] Vītoliņa I., Kapenieks A. (2013). E-inclusion and knowledge flows in e-course delivery. *Proceedings of the 5th International Conference on Computer Supported Education CSEDU 2013*, pp. 417–422.

[5] Vītoliņa I., Kapenieks A. (2013). Factors predicting e-inclusion in a blended learning course delivery context. *Reorientation of teacher education towards sustainability through theory and practice.*, pp. 199–212.

[6] Vītoliņa I., Kapenieks A. (2014). User analysis for e-inclusion in a blended learning course delivery context. *Proceedings of the International Scientific Conference*, Vol. 2, pp. 367–378.

[7] Vitolina, I. (2015). E-inclusion process and societal digital skill development. *Discourse and Communication for Sustainable Education*, 6(1), pp. 86–94.

[8] Vitolina, I. (2015). E-inclusion modeling for blended e-learning course. *Procedia Computer Science*, 65, pp. 744–753.

[9] Vitolina I., Kapenieks A. (2021). E-inclusion prediction modelling in blended learning courses. *Educating Engineers for Future Industrial Revolutions: Proceedings of the 23rd International Conference on Interactive Collaborative Learning (ICL2020)*, Volume 1 23, pp. 327–337.

[10] Vītoliņa I., Kapenieks A. (2021). Comparison of e-inclusion prediction models in blended learning courses. *Proceedings of the 19th International Conference on e-Society (ES 2021)*, pp. 101–108.

[11] Vītoliņa I., Kapenieks A., Grada I. (2021). Modeling the e-inclusion prediction system. *Proceedings of the 13th International Conference on Computer Supported Education CSEDU 2021 – Vol. 2*, pp. 258–265.

Promocijas darba struktūra

Saskaņā ar promocijas darba uzdevumu, tika izveidota pētījuma struktūra, kas sastāv no ievada, četrām daļām, nobeiguma, pielikumiem, literatūras avotiem.

1. nodaļā ir dots e-iekļaušanas apraksts, identificēta e-iekļaušanas problēmsfēra. 2. nodaļā atspoguļotas e-iekļaušanas prognozēšanas tehnoloģijas un metodes. 3. nodaļā atspoguļota indivīda e-iekļaušanu prognozējoša modeļa un tajā izmantotā algoritma izstrāde. 4. nodaļā ir aprakstīts e-iekļaušanu prognozējošais tehnoloģiskais modelis (prototips) un novērtēts e-iekļaušanu prognozējošais tehnoloģiskais modelis profesionālas izglītības iestāžu pedagogu e-iekļaušanas pakāpes noteikšanai. Darba noslēguma daļā ir apkopoti promocijas darba rezultāti un secinājumi, kā arī turpmāko pētījumu virzieni un iespējas. Darbam pievienoti 10 pielikumi. 1. pielikums ir darba nodaļu izveides procesa shematisks attēlojums atbilstoši pētījuma darba uzdevumiem. 2. pielikums satur promocijas darbā izmantotās definīcijas, terminu skaidrojumus, akronīmus un saīsinājumus. 3. pielikums ir promocijas darbā ievietoto attēlu saraksts. 4. pielikums ir promocijas darbā ievietoto tabulu saraksts. 5. pielikumā ir dots e-iekļaušanas procesus aprakstošs modelis. 6. pielikums satur pētījumos izmantoto aptaujas anketu paraugus. 7. pielikums satur piemērus e-iekļaušanas faktoru un pakāpes mainīgo atbilstības pārbaudei normālsadalījumam. 8. pielikums atspoguļo prototipa klašu diagrammas. 9. pielikums satur piemērus prototipa kodam. 10. pielikumā ir doti prototipa ekrāna skati.

1. E-IEKĻĀUŠANAS UN TĀS PROCESU ANALĪZE

Aizvien vairāk informācijas, nodarbinātības, mājsaimniecības, izglītības un valsts pārvaldes pakalpojumi ir pieejami digitālā veidā. Informācijas un komunikācijas tehnoloģijas (IKT) ir kļuvušas par neatņemamu ikdienas sastāvdaļu. E-iekļaušana ir vērsta uz to, lai IKT kā, piemēram, personālie un portatīvie datori, internets, viedtālrunis dažādu aktivitāšu veikšanai, – izglītības ieguvei, profesionālai darbībai ir noderīgas ikvienam indivīdam neatkarīgi no tā, vai viņš ir gados jauns vai vecs, sieviete vai vīrietis, cilvēks ar īpašām vajadzībām vai pārstāv kādu etnisko minoritāti, dzīvo pilsētā vai lauku teritorijā. E-iekļaušana ir ikviena indivīda un sabiedrības kopumā iesaistīšana jebkurās valsts un sabiedrības aktivitātēs ar IKT starpniecību. E-iekļaušanas politikas mērķis ir samazināt atšķirības, kādas pastāv cilvēkiem IKT lietošanā un sekmēt to, ka ikviens IKT izmanto efektīvi izglītībai, personības pilnveidei un profesionālajā darbībā, tādējādi veicinot tautsaimniecības izaugsmi un ikviena indivīda pilnvērtīgu iekļaušanos informācijas sabiedrības norisēs.

Lai arī e-iekļaušanas politikas stratēģiskie mērķi ES ir noteikti 2006. gadā, tos neizdodas sasniegt. 2021. gada 10. marta Eiropas Komisijas paziņojumā “Digitālais kompass līdz 2030. gadam – Eiropas ceļam digitālajā gadu desmitā” norādīts, ka joprojām sabiedrībā pastāv plaša starp tiem, kuriem ir iespējams izmantot digitālo tehnoloģiju sniegtās priekšrocības un kuriem nav (*European Commission, 2006; European Commission, 2021*).

Šajā nodaļā ir atspoguļota e-iekļaušanas un tās procesu analīze, kas ir sākotnējais posms e-iekļaušanu prognozējošā modeļa izveidei atbilstoši *CRISP-DM* un *CRISP-ML (Q)* metodēm.

Nodaļas mērķis ir pētīt e-iekļaušanas un tās procesu problemātiku, lai meklētu atbildi uz jautājumu, kā sekmēt e-iekļaušanas un tās procesu mērķu sasniegšanu, un precizētu e-iekļaušanas tvērumu, kas tiks pētīts promocijas darbā. Lai sasniegtu mērķi, šajā nodaļā veikti šādi uzdevumi:

1) strukturētas iegūtās zināšanas no ES politikas dokumentiem un dažādiem pētījumiem par e-iekļaušanu ar uzņēmuma modelēšanas metodi *4EM*;

2) izveidots e-iekļaušanu aprakstošs modelis, dodot visaptverošu ieskatu par e-iekļaušanu un tās procesiem;

3) noteikti e-iekļaušanu prognozējošā modeļa mērķi promocijas darba kontekstā.

Nodaļa sastāv no trīs apakšnodaļām. Pirmajā apakšnodaļā ir atspoguļota metodes izvēle e-iekļaušanu aprakstošā modeļa izveidei. Otrajā apakšnodaļā ir dots e-iekļaušanu aprakstošais modelis. E-iekļaušanas esošās situācijas analīze ietver e-iekļaušanas raksturojumu, tās stratēģiskos mērķus, problēmas, kas kavē sasniegt mērķus, iesaistītās mērķgrupas un resursus, likumus vai noteikumus, kas jāņem vērā e-iekļaušanas procesā, kā arī galvenos e-iekļaušanas jēdzienus. Trešā nodaļa satur kopsavilkumu un secinājumus par e-iekļaušanu aprakstošo modeli, e-iekļaušanas un tās procesu mērķi, to sasniegšanas kritērijiem promocijas darba kontekstā.

1.1. Metodes izvēle e-iekļaušanu aprakstošā modeļa izveidē

Uzņēmuma modelēšanas metodes

Viena no metodēm zināšanu ieguvei ir uzņēmuma modelēšana (*Bubenko u. c., 1998*). Saskaņā ar J. Bubenko (2007) teoriju uzņēmuma modelēšana ir process, kura rezultātā tiek

radīts modelis, kas atspoguļo uzņēmumu no dažādiem aspektiem. Šajā kontekstā uzņēmums var būt gan privāts uzņēmums, gan kāda organizācija vai arī kāds objekts vai parādība, piemēram, sociāla kustība. Uzņēmuma modelēšanas metodi parasti izmanto, lai, pirmkārt, attīstītu uzņēmuma darbību, radot nākotnes vīziju, stratēģiju, mērķus. Otrkārt, uzņēmuma modelēšanas metodi lieto, lai uzlabotu uzņēmuma darbības kvalitāti. Uzņēmuma modelēšanas metode satur vadlīnijas zināšanu ieguvei, analīzei, to prezentēšanai sistemātiski un strukturēti.

Uzņēmuma modelēšanas metodes aspekti e-iekļaušanas procesam

Uzņēmuma modelēšanas pieeja paredz, ka modelējamais objekts tiek apskatīts no vairākiem aspektiem, veidojot vairākus modeļus, bet rezultātā nodrošinot, ka tie ir savstarpēji saistīti un dod visaptverošu skatījumu par modelējamo objektu. Svarīgākie objekta modelēšanas aspekti ir (*Sandkuhl* u. c., 2014):

1) Mērķu un problēmu perspektīva. Jābūt definētiem nākotnes mērķiem. Lai sasniegtu mērķus, jāapzinās problēmas, šķēršļus, izaicinājumus, kas jāpārvar. Jāizprot, kā mērķi un problēmas savstarpēji ir saistīti.

2) Biznesa procesu perspektīva. Jānosaka, kādas darbības – procesi tiek veikti organizācijā, lai varētu izvērtēt to efektivitāti.

3) Organizācijas struktūras perspektīva. Jānosaka, kādas struktūrvienības, personas to veido, kādas ir to lomas, uzdevumi, atbildības, veicot biznesa procesus.

4) Tehnisko komponentu perspektīva. Jānosaka, kādi resursi ir nepieciešami, lai veiktu biznesa procesus, lai organizācijas struktūrā iesaistītās personas veiktu tām paredzētos uzdevumus.

5) Produkta perspektīva. Jānosaka, kas ir organizācijas darbības galarezultāts – produkts vai pakalpojums un no kā tas sastāv.

6) Jēdzienu perspektīva. Precīzi jādefinē jēdzieni, lai tie būtu vienoti, modelējot no dažādiem skatu punktiem – gan mērķus, gan procesus.

7) Biznesa likumu perspektīva. Modelējot biznesa procesus, jāievēro iepriekš zināmi likumi un noteikumi.

Modelēšanas mērķis nosaka to, no kādām perspektīvām jāapskata modelējamais objekts un kura no perspektīvām ir dominējošā. Piemēram, ja mērķis ir saprast, kā savstarpēji saistītas uzņēmuma struktūrvienības, kādus uzdevumus tās veic, tad vadošā ir organizācijas struktūras perspektīva. To var papildināt ar biznesa procesu, produktu, likumu, tehniskām komponentēm. Savukārt, ja mērķis ir noteikt, kādas izmaiņas organizācijā kopumā ir nepieciešams veikt, lai uzlabotu organizācijas darbību, tad dominējošais ir skatījums no mērķu un problēmu perspektīvas, kas papildināts un sasaistīts ar jēdzienu, organizatorisko, biznesa procesu un tehnisko perspektīvu. Šajā gadījumā ar uzņēmuma modelēšanas metodi var atklāt problēmu cēloņus un iespējamus risinājumus.

Promocijas darbā e-iekļaušanas modelēšanas mērķis ir radīt e-iekļaušanu aprakstošu modeli, kas precīzē un nosaka būtiskus ES e-iekļaušanas politikas īstenošanai nepieciešamos procesus, lai promocijas darbā meklētu atbilstošus tehnoloģiskos risinājumus.

E-iekļaušana promocijas darbā tiek skatīta no mērķu un problēmu perspektīvas, sasaistot un papildinot ar skatījumiem no organizatoriskās, procesu, jēdzienu, tehniskās perspektīvas.

Uzņēmuma modelēšanas rezultātu attēlošanas veids un e-iekļaušanas modeļa attēlojums

Modelēšanas rezultāts tiek dokumentēts un attēlots vienā no veidiem: (1) vizuālā (piemēram, ar diagrammām) vai (2) teksta (piemēram, strukturēts teksts vai tabulas) veidā

(Sandkuhl u. c., 2014).

Zināšanu vizualizācija veicina zināšanu izplatīšanu un jaunu radīšanu (Eppler un Burkhard, 2004). Papildus faktu attēlošanai zināšanu vizualizācijas mērķis ir attēlot pieredzi, attieksmi, vērtības, viedokļus, lai tos citi varētu pielietot korekti. Zināšanu vizualizācijā izmanto diagrammas, kartes, animācijas u.c. līdzekļus. Izstrādājot un ieviešot uzņēmumu stratēģijas, zināšanu vizualizācija uzlabo uzņēmumu stratēģiju analīzi, attīstību, formulējumus, komunikāciju un ieviešanu (Burkhard un Eppler, 2005). Stratēģiju vizualizēšana (Kaplan un Norton, 2004) palīdz veidot labāku izpratni. Lietojot iepriekš definētus formālus grafiskos apzīmējumus modeļiem, tiek nodrošināts, ka modeļi saprotami ikvienam (Sandkuhl u. c. 2014).

Lai sekmētu to, ka izveidotais e-iekļaušanas modelis ir ērtāk analizējams un uztverams tā lietotājiem, promocijas darbā e-iekļaušanas modelis ir attēlots vizuāli, nevis aprakstīts tikai tekstuāli.

Izvirzītie kritēriji e-iekļaušanas modelēšanas metodei un metodes izvēle promocijas darbā

Izvēloties uzņēmuma modelēšanas metodi promocijas darbam e-iekļaušanas modelēšanai, autore vadījās no šādiem kritērijiem: metode ļauj vizuāli (ar iepriekš definētiem apzīmējumiem) modelēt objektu no vairākām perspektīvām (vismaz no šādām: mērķi, problēmas, organizācijas struktūra, jēdzienu, procesu perspektīva).

Uzņēmuma modelēšanai ir radītas vairāk kā simts metodes. Vairums metodes ļauj objektu modelēt no vairākām perspektīvām (Sandkuhl u. c., 2014). Lai izvēlētos metodi e-iekļaušanas modelēšanai, autore apskatīja vairākas uzņēmuma modelēšanas metodes: *AKM* (Lillehagen un Krogstie, 2008), *ArchiMate* (Lankhorst, Proper un Jonkers, 2009), *ARIS* (Scheer un Nüttgens, 2000), *EKD* (pilnveidota par *4EM*). Salīdzinot uzņēmuma modelēšanas metodes, autore secināja, ka visas apskatītās metodes ļauj rezultātus vizualizēt, izmantojot iepriekš definētus apzīmējumus. Analīzes perspektīvas no mērķu un problēmu skatupunkta nodrošina *EKD*, *ArchiMate*, lai gan arī pārējo metožu aprakstos ir minēts, ka metodi var pielāgot dažādām perspektīvām. Izvērtējot metožu dokumentācijas pieejamības ērtumu un esošās iestrādes modelēšanā, promocijas darbā e-iekļaušanas modelēšanai tika izvēlēta *EKD* (pilnveidota par *4EM*, turpmāk tekstā – *4EM*) metode.

***4EM* metode**

4EM metode ir viena no uzņēmumu modelēšanas metodēm, kas apvieno zināšanu strukturēšanu un vizualizāciju, ļauj veidot modeļus, kas nosaka tālāku uzņēmuma vai kāda objekta stratēģisko attīstību un uzlabo tā darbības kvalitāti. Metodes autoriem pilnveidojot *EKD* metodi, tā ieguva nosaukumu *4 Enterprise Modeling (4EM)* un 2014. gadā metodes autori ir publicējuši tās aprakstu un ieteikumus metodes pielietojumam (Sandkuhl u. c., 2014).

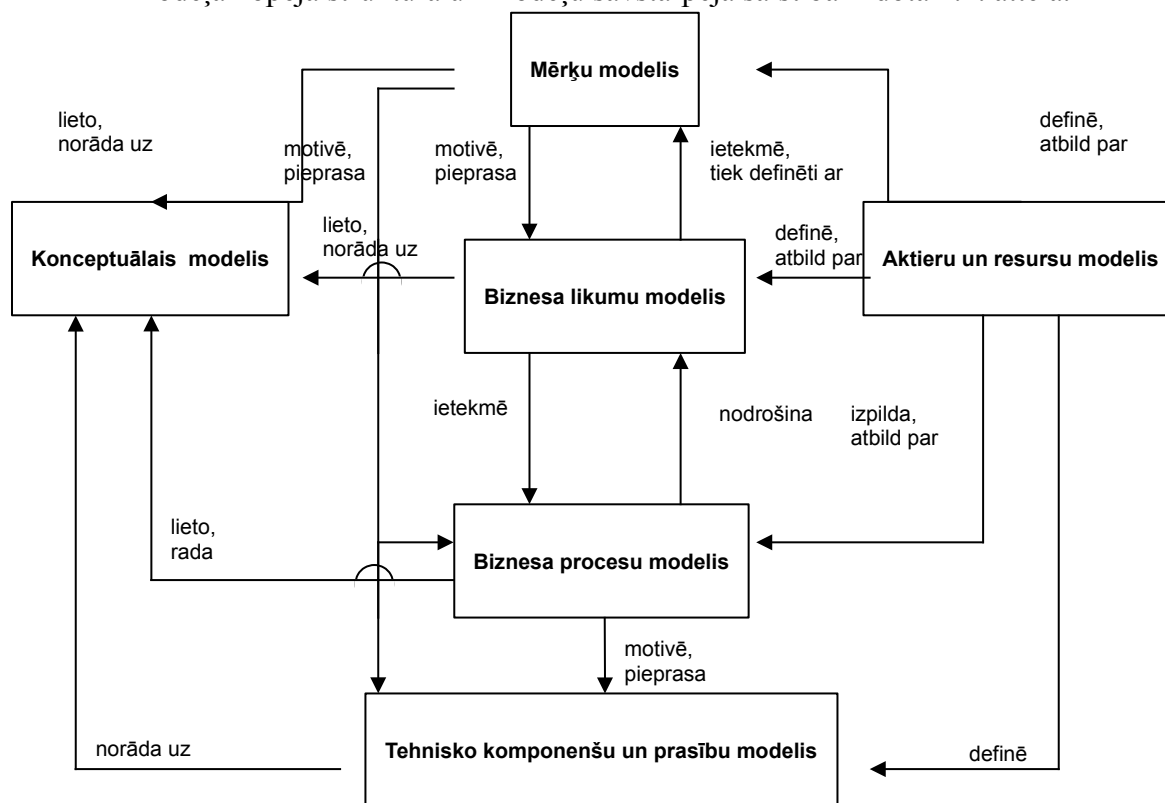
4EM metode ir plaši izmantota gan uzņēmumu stratēģijas plānošanā, biznesa procesu pārstrukturēšanā, zināšanu pārvaldē, informācijas sistēmu prasību noteikšanā, jaunu produktu un servisa konceptu izstrādē utt. Metode izmantota tādās organizācijās kā *British Aerospace*, *Telia*, *Volvo*, *Verbundplan*, *Siemens*, *Ericsson*, *Public Power Corporation of Greece*, Rīgas Dome, RRC Koledža, Vācijas Sarkanajā Krustā, Vidzemes reģiona alternatīvo sociālo pakalpojumu sistēmas izveidei (Rīgas Tehniskā universitāte un nozares ekspertu grupa, 2010; Sandkuhl u. c., 2014; Stale, 2006).

4EM apakšmodeļi e-iekļaušanas procesa modelēšanā

Ar 4EM metodi veido vienotu modeli. Tas sastāv no sešiem savstarpēji saistītiem apakšmodeļiem: mērķu modelis; biznesa likumu modelis; jēdzienu modelis; dalībnieku un resursu modelis; biznesa procesu modelis; tehnisko komponentu un prasību modelis. Katrs no apakšmodeļiem risina noteikta līmeņa problēmas un izmanto noteiktas komponentes (Stecjuka un Kirikova, 200X).

Saites starp komponentēm dažādos apakšmodeļos ļauj izsekot līdzī visā modelī, kāpēc parādās konkrēti biznesa likumi, procesi, dalībnieki un tehniskās komponentes un prasības.

4EM modeļa kopējā struktūra un modeļu savstarpējā saistība ir dota 1.1. attēlā.



1.1. att. 4EM modeļa struktūra un apakšmodeļu savstarpējā saistība (tulkots no (Bubenko, 2001a)).

Mērķu modelis. Mērķu modelis stratēģiskā līmenī atspoguļo organizācijas mērķus kopā ar faktoriem, kuri ietekmē mērķu sasniegšanu, t.i., problēmas, vājās vietas, draudi, cēloņi, ierobežojumi un iespējas. Mērķu modelis kā komponentes izmanto mērķus, problēmas, vājās vietas, draudus, cēloņus, ierobežojumus, iespējas.

Promocijas darbā aprakstītais e-iekļaušanas modelēšanas process neietver modelēšanas semināru, kurā varētu gūt idejas par dažādiem e-iekļaušanas politikas mērķiem. E-iekļaušanas modelis tiek veidots ar nolūku saprast, kādi faktori ietekmē e-iekļaušanas procesu un e-iekļaušanas politikas mērķu sasniegšanu, tāpēc kā pamats promocijas darbā e-iekļaušanas mērķu modelim izmantoti 2006. gadā Rīgā pieņemtajā Eiropas ministru deklarācijā par e-iekļaušanu noteiktie mērķi (European Commission, 2006). Tie detalizēti un papildināti ar literatūrā pieejamo e-iekļaušanas problēmu un iespēju uzskaitījumu.

Biznesa likumu modelis. Biznesa likumu modelis atspoguļo uzņēmuma iekšējos noteikumus, saskaņā ar kuriem tas darbojas, un dažādus ārējus noteikumus, kas regulē

uzņēmuma darbību. Biznesa likumi ietekmē mērķu sasniegšanu, kontrolē vai ierobežo biznesa procesu izpildi, tie nosaka jēdzienus konceptuālajā modelī un dalībniekus dalībnieku un resursu modelī, kā arī definē informācijas sistēmas funkcijas. Biznesa likumu modelis izmanto komponenti: likums.

Kā likumi e-iekļaušanas modelī apkopoti no zināšanu avotiem iegūtas sakarības, apgalvojumi, atziņas, kas sekmē vai kavē e-iekļaušanas mērķi.

Jēdzienu modelis. Jēdzienu modelis definē lietas un parādības, kas izmantotas modeļos. Jēdzienu modelis izmanto komponentes – jēdziens (koncepts) un atribūts.

E-iekļaušanas jēdzienu modelis parāda saistību dažādiem ar e-iekļaušanu saistītiem jēdzieniem un terminiem.

Biznesa procesu modelis. Biznesa procesu modelis atspoguļo uzņēmumā esošos biznesa procesus un datu plūsmas starp tiem. Biznesa procesu modelis izmanto komponentes: process, ārējs process, informācija vai materiāls.

E-iekļaušanas biznesa procesu modelis parāda procesus, kas indivīdam jāīsteno, lai varētu uzskatīt, ka indivīds ir e-iekļauts attiecībā uz konkrētu tehnoloģiju.

Dalībnieku un resursu modelis. Dalībnieku un resursu modelis atspoguļo, kā uzņēmumā dažādas iesaistītās personas un institūcijas (dalībnieki) un resursi savā starpā ir saistīti. Dalībnieku un resursu modelis izmanto komponentes: loma un resurss.

Dalībnieku un resursu modelī ir attēlota e-iekļaušanas procesu mērķgrupa, kā piemēram, cilvēki ar īpašām vajadzībām, imigranti, bezdarbnieki u.c. sociālās grupas. Šajā modelī ir attēloti arī e-iekļaušanas procesu virzītāji – atbildīgās institūcijas, kā Eiropas Komisija, valsts pārvalde, privātais sektors u.c. Modelis ietver arī resursus, kas iesaistīti e-iekļaušanas procesos, kā, piemēram, IKT un ES fondus.

Tehnisko komponentu un prasību modelis. Tehnisko komponentu un prasību modelis sistēmas koncepcijas līmenī atspoguļo augsta līmeņa sistēmas prasības un mērķus, kuri tiek apvienoti komponentēs jeb apakšsistēmās/funkcionālajos moduļos. Tehnisko komponentu un prasību modelis izmanto komponentes informācijas sistēmas (IS) mērķis, IS prasība, IS problēma. E-iekļaušanas modelī autore neveido tehnisko komponentu un prasību modeli.

E-iekļaušanas modeļa veidošanas process

Uzsākot e-iekļaušanas modeļa veidošanu, saskaņā ar uzņēmuma modelēšanas ekspertu rekomendācijām (Stirna un *Persson*, 2018), vispirms tika veikti šādi priekšdarbi:

1) Definēts ietvars un modeļa mērķis.

Problēma: neskatoties uz to, ka Eiropas Komisija ir izvirzījusi mērķus un uzdevumus indivīdu e-iekļaušanai, plānotie rezultāti netiek sasniegti. Modeļa mērķis ir noskaidrot iespējamo rīcību, kas veicinātu indivīdu iekļaušanu e-studiju tehnoloģiju kontekstā. Modeļa izveides laikā nepieciešams noskaidrot, kuru apakšmērķu sasniegšana ir būtiska, kādi nosacījumi ietekmē mērķu sasniegšanu, atklāt mērķgrupas un nepieciešamos resursus.

2) Ierobežota problēma, norādīts, kas attiecas uz problēmu un modeļa mērķi.

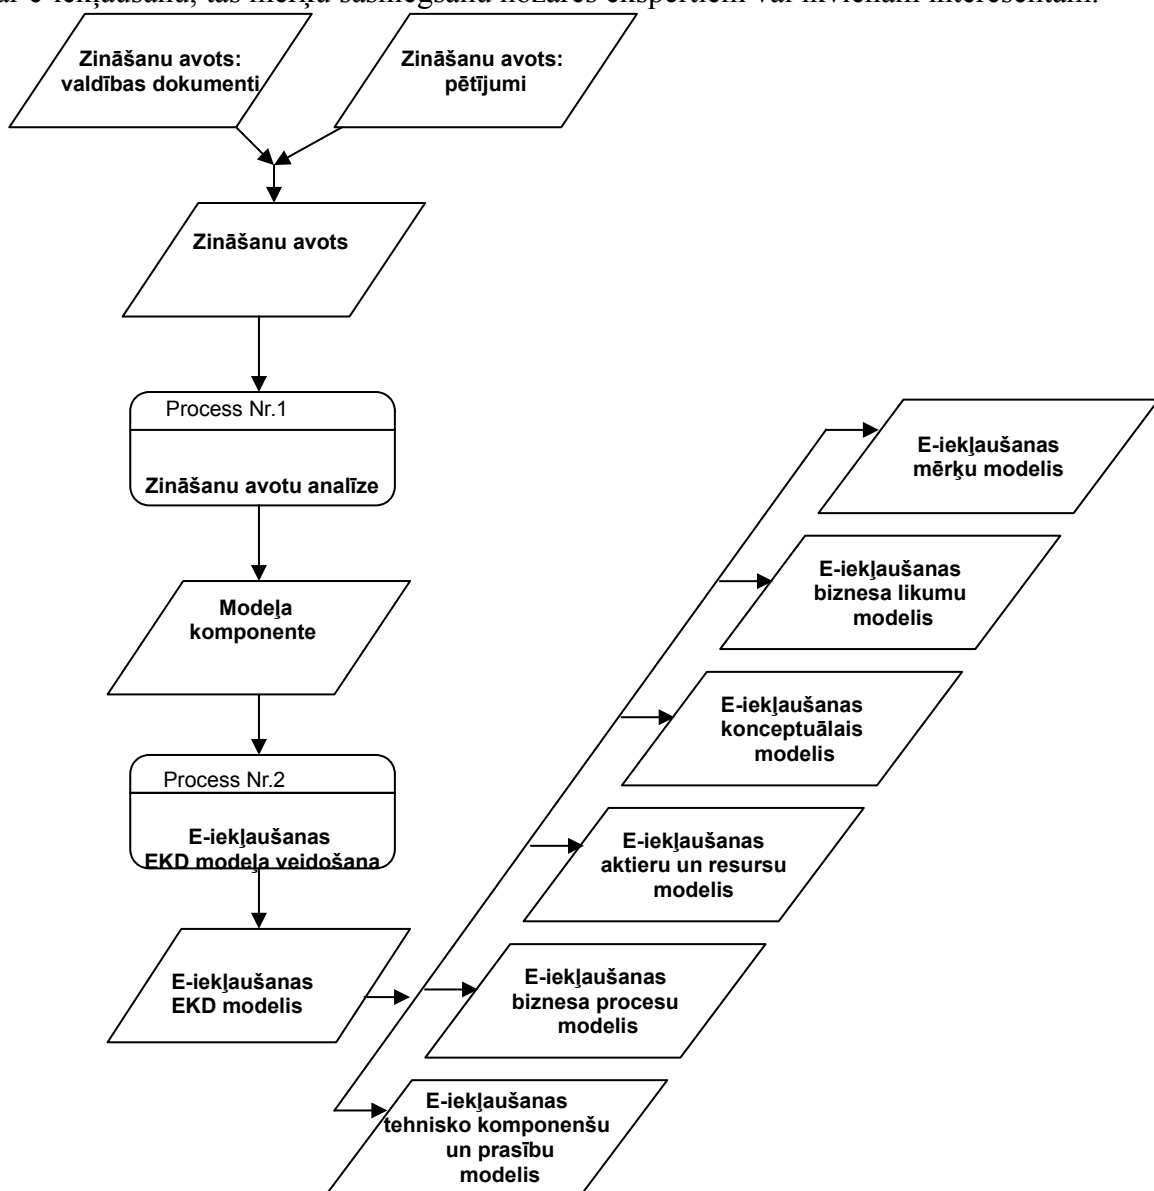
Ierobežojums: e-iekļaušanas problemātika primāri tiek skatīta ES kontekstā, tiek izmantoti ES politikas plānošanas dokumenti, kas attiecas uz e-iekļaušanu.

3) Noteikti svarīgākie modeļa objekti.

Svarīgākie modeļa objekti ir e-iekļaušanu mērķa modelis sasaistīts ar biznesa likumu modeli, resursiem, kā arī e-iekļaušanas procesu modelis.

4) Noteikts modeļa lietotājs, modeļa pielietojums.

Modeļa lietotājs – autore, pielietojums – ar modeli tiek aprakstīta un precizēta promocijas darba problēma un mērķis. Citi modeļa pielietojumi: kā informējošs un izglītojošs materiāls par e-iekļaušanu, tās mērķu sasniegšanu nozares ekspertiem vai ikvienam interesentam.



1.2. att. E-iekļaušanas modeļa veidošanas process.

Modeļa veidošanas noteikumi ir aprakstīti *4EM* vadlīnijās. Saskaņā ar *4EM* vadlīnijām modeļa veidošanas process ietver modelēšanas semināru, kurā piedalās eksperti, atbildīgās personas par lēmumu pieņemšanu, iespējamie rezultātu radītāji un lietotāji, kā arī citas personas. Semināra laikā tiek ģenerētas idejas, kas attiecas uz uzņēmuma nākotni, mērķiem, procesiem. Noformulētas atbilstoši *4EM* modelēšanas prasībām, tās tiek iekļautas uzņēmuma modelī. Tomēr, modelējot e-iekļaušanu, autore veic atkāpes no *4EM* vadlīnijām, netiek organizēts modelēšanas seminārs, bet kā zināšanu avoti tiek izmantoti dokumenti – ES vai zinātnieku pētījumi, ES politikas plānošanas dokumenti un ziņojumi par sasniegto, statistikas dati.

E-iekļaušanas modeļa veidošanas procesa shēma ir dota 1.2. attēlā. Shēmas attēlošanā izmantota *4EM* modelēšanas metodika procesu modeļa pierakstam.

Veidojot e-iekļaušanas modeli, vispirms analizē zināšanu avotus. Tad iegūtās zināšanas tiek pārvērstas par modeļa komponenti. Komponenti iezīmē modelī, sasaista ar citām komponentēm, veidojot kādu no sešiem apakšmodeļiem: e-iekļaušanas mērķu modeli, likumu modeli, resursu un dalībnieku modeli, procesu modeli, jēdzienu modeli. Veido saites starp apakšmodeļiem, atbilstoši *4EM* vadlīnijām.

Kā modelēšanas rezultātu iegūst e-iekļaušanas *4EM* modeli, kas sastāv no pieciem apakšmodeļiem.

E-iekļaušanas *4EM* modeli autore veidoja no 2009. gada decembra līdz 2010. gada janvārim, bet papildināja laika posmā no 2012. gada janvāra līdz 2014. gada maijam un no 2018. gada aprīļa līdz 2021. gada aprīlim.

E-iekļaušanas modeļa zināšanu avotu apraksts

Kā zināšanu avoti darba procesā ir izmantoti divu veidu dokumenti: (1) ar e-iekļaušanu saistīti Eiropas Komisijas, ES valstu un Latvijas valdības oficiālie dokumenti (deklarācijas, stratēģijas, ziņojumi utml.) un (2) pētījumi par e-iekļaušanu un tās procesiem pasaulē, lielākoties ES. Vairāki no šiem pētījumiem veikti ES finansētos projektos, meklējot atbildes, kāpēc kavējas e-iekļaušana un, sniedzot rekomendācijas.

1.2. E-iekļaušanas un tās procesu modelis

Kā darba procesa rezultāts ir iegūts e-iekļaušanas un tās procesu *4EM* modelis, kas sastāv no e-iekļaušanas mērķu modeļa, likumu modeļa, resursu un dalībnieku modeļa, jēdzienu modeļa, procesu modeļa.

Kad modeļi izveidoti, tad starp tiem atbilstoši *4EM* vadlīnijām, tiek veidotas savstarpējās saites. Saites veidotas starp mērķu modeli, likumu modeli un resursu modeli, starp procesu modeli un dalībnieku un resursu modeli, kā arī jēdzienu modeli.

E-iekļaušanas mērķu modelis un tā sasaiste ar biznesa likumu, dalībnieku, resursu, jēdzienu modeļiem

Vispirms ir veidots e-iekļaušanas mērķu modelis, vadoties no e-iekļaušanas deklarācijas, ES digitālās politikas dokumentiem un zinātnieku pētījumiem.

E-iekļaušana ir viens no ES digitālās politikas mērķiem vairāk nekā 10 gadu garumā, ko neizdodas sasniegt. ES e-iekļautības politiskais mērķis ir definēts 2006. gadā, kad Eiropas Komisija publicēja Rīgā pieņemto e-iekļaušanas deklarāciju, nosakot, ka nepieciešams pārvarēt ikviena indivīda un sabiedrības kopumā atstumtību, izslēgšanu un uzlabot ekonomiskos rādītājus, nodarbinātības iespējas, dzīves kvalitāti un sociālo līdzdalību. Deklarācijā e-iekļaušanas politisko mērķi ir paredzēti sasniegt, veicinot IKT lietošanu un samazinot atšķirības IKT lietošanā (*European Commission, 2006*).

Deklarācija tika noteikti stratēģiskie mērķi un skaitliskie rādītāji, kas līdz 2010. gadam bija jāsasniedz. 1.3. attēlā ir dots e-iekļaušanas politiskais mērķis (Mērķis Nr. 1) un seši stratēģiskie mērķi: (Mērķis Nr. 2. - Mērķis Nr. 7):

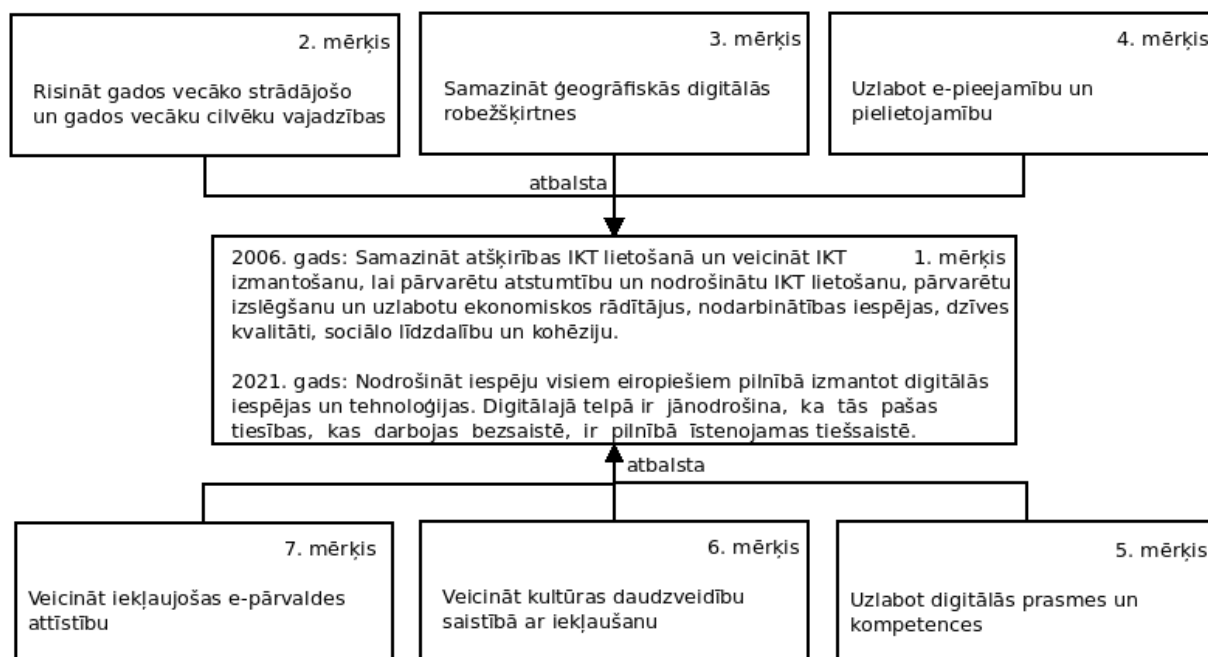
- risināt gados vecāko strādājošo un gados vecāku cilvēku vajadzības;
- samazināt ģeogrāfiskās digitālās robežšķirtnes;
- uzlabot e-pieejamību un lietojamību;
- uzlabot digitālās prasmes un digitālo pratību;
- veicināt kultūras daudzveidību saistībā ar iekļaušanu;

- veicināt iekļaujošas e-pārvaldes attīstību.

Tomēr e-iekļaušanas deklarācijas mērķi pilnībā netika sasniegti un 2010. gadā Eiropas Komisija nāca klajā ar Digitālo programmu Eiropai, kurā tika nosprausti ES digitālās jomas mērķi 2020. gadam (*European Commission, 2010*). Digitālā programma akcentēja digitālā vienotā tirgus izveides nepieciešamību, tostarp norādot uz problēmām. Joprojām problēma ir nepietiekami ieguldījumi tīkla infrastruktūrā, nav nodrošināta pieeja platjoslas tīkliem gan ar vadu, gan bezvadu tehnoloģijām, un jāveicina ieguldījumus jaunajos ātrajos atvērtajos un konkurētspējīgajos interneta tīklos. Saglabājusies problēma saistībā ar digitālo prasmju un iemaņu trūkumu. Eiropa cieš no arvien lielāka profesionālo IKT prasmju trūkuma un digitālo prasmju deficīta. Šīs nepilnības daudzus indivīdus atstumj no digitālās sabiedrības un ekonomikas, un neļauj izpausties IKT apguves veicinošajai iedarbībai uz ekonomiskās ražības pieaugumu. Digitālo tehnoloģiju izmantošanu kavē kibernetikas pieaugums un iespējamā neuzticība tīkliem. Sabiedrība neiesaistīsies arvien sarežģītākās tiešsaistes darbībās, ja nebūs pārliecības, ka var uz tīkliem pilnīgi paļauties. Digitālā programma Eiropai aktualizē 2006. gadā e-iekļaušanas deklarācijā nospraustos mērķus – samazināt ģeogrāfiskās digitālās robežšķirtnes, nodrošinot ātru un īpaši ātru piekļuvi internetam, uzlabot digitālās prasmes un iemaņas, veidot iekļaujošus digitālos pakalpojumus gan e-pārvaldē, gan ikvienā citā jomā cilvēkiem ar īpašām vajadzībām un gados vecākiem cilvēkiem, kā arī veidot digitālo uzticību un raudzīties, lai pieaugtu sociālā iekļautība un sabiedrības ieguvumi no IKT.

2019. gadā Eiropas Komisija publicēja digitālo stratēģiju nākamajiem desmit gadiem, un 2021. gada 10. martā Eiropas Komisija piedāvāja Digitālo kompasu (*European Commission, 2020; European Commission, 2021*). Digitālais kompass satur ES digitālos mērķus 2030. gadam un uzsver, ka 2030. gada iecere ir “digitāla sabiedrība, kura nevienu neatstāj malā”. Eiropas Komisija kā globālu problēmu norāda, ka ir parādījusies jauna digitālā plaša – ne tikai starp labi savienotām pilsētu teritorijām un laukiem un attāliem rajoniem, bet arī starp tiem, kuri var pilnībā izmantot bagātīgu, pieejamu un drošu digitālo telpu ar pilnu pakalpojumu klāstu, un tiem, kuri nevar. Digitālais kompass turpina īstenot e-iekļautības mērķus uzsverot, ka digitālajā telpā ir jānodrošina, ka tās pašas tiesības, kas darbojas bezaistē, ir pilnībā īstenojamas tiešsaistē. Lai to nodrošinātu, cilvēkiem ir jābūt pieejamai drošai un kvalitatīvai piekļuvei internetam, iespējai apgūt digitālās prasmes, vieglai piekļuvei nediskriminējošiem digitālajiem pakalpojumiem, kur viens no pakalpojumu veidiem attiecas uz veselības nodrošināšanu. Digitālajā kompāsā atsevišķi nav uzsvērts, ka jārada gados vecākiem cilvēkiem, cilvēkiem ar īpašām vajadzībām, migrantiem vai citām e-iekļaušanas riska grupām iespējas izmantot tehnoloģiju sniegtās iespējas, bet norādīts, ka digitālā stratēģija attiecas uz ikvienu ES dzīvojošo, tādējādi var uzskatīt, ka Digitālā kompasa mērķi attiecas arī uz 2006. gadā e-iekļaušanas deklarācijā īpaši izdalīto riska grupu iesaistīšanu digitālās telpas priekšrocību izmantošanā.

Autore e-iekļaušanas mērķu modelī kā galvenos mērķus izmanto 2006. gada e-iekļaušanas deklarācijā izvirzītos mērķus, jo to sasniegšana ir aktuāla arī 2021. gadā publicētajā Eiropas Komisijas paziņojumā “Digitālais kompass līdz 2030. gadam – Eiropas ceļam digitālajā gadu desmitā”, kas definē līdz 2030. gadam sasniedzamos digitālos mērķus (1.3. att.).



1.3. att. E-iekļaušanas stratēģisko mērķu modelis atbilstoši Eiropas Komisijas e-iekļaušanas deklarācijai un Eiropas Komisijas digitālās stratēģijas 2030. gada mērķiem.

E-iekļaušanas stratēģisko mērķu modelis sastāv no 57 mērķiem/apakšmērķiem, kam piesaistītas 41 problēma, kas iegūtas, analizējot zināšanu avotus. Problēmas grupētas ap katru no mērķiem. Mērķu modelis dots 5. pielikumā (1. sadaļa). Promocijas darbā e-iekļaušanas mērķu modelis detalizētāk ir apskatīts vienlaicīgi ar biznesa likumu modeli, dalībnieku un resursu un jēdzienu modeļiem.

E-iekļaušanas biznesa likumu modelis, kas sastāv no 12 biznesa likumiem, ir dots 5. pielikumā (2. sadaļa). Biznesa likumi atbilstoši *4EM* metodikai atspoguļo noteikumus, ar kuriem saskaņā organizācija darbojas. E-iekļaušanas likumu modelī likumi norāda deklarācijā, Digitālajā programmā un zinātnieku pētījumos pastāvošos norādījumus, kas jāņem vērā, lai nodrošinātu sekmīgu e-iekļaušanas mērķu sasniegšanu. Biznesa likumi ietekmē stratēģisko mērķu sasniegšanu, tāpēc darbā biznesa likumi ir aprakstīti, sasaistot tos ar e-iekļaušanas stratēģiskajiem mērķiem.

E-iekļaušanas dalībnieku un resursu modelis sastāv no 17 lomām un 18 resursiem, modelis ir dots 5. pielikumā 3. sadaļā.

E-iekļaušanas jēdzienu modelis sastāv no 26 jēdzieniem un ir dots 5. pielikumā 4. sadaļā.

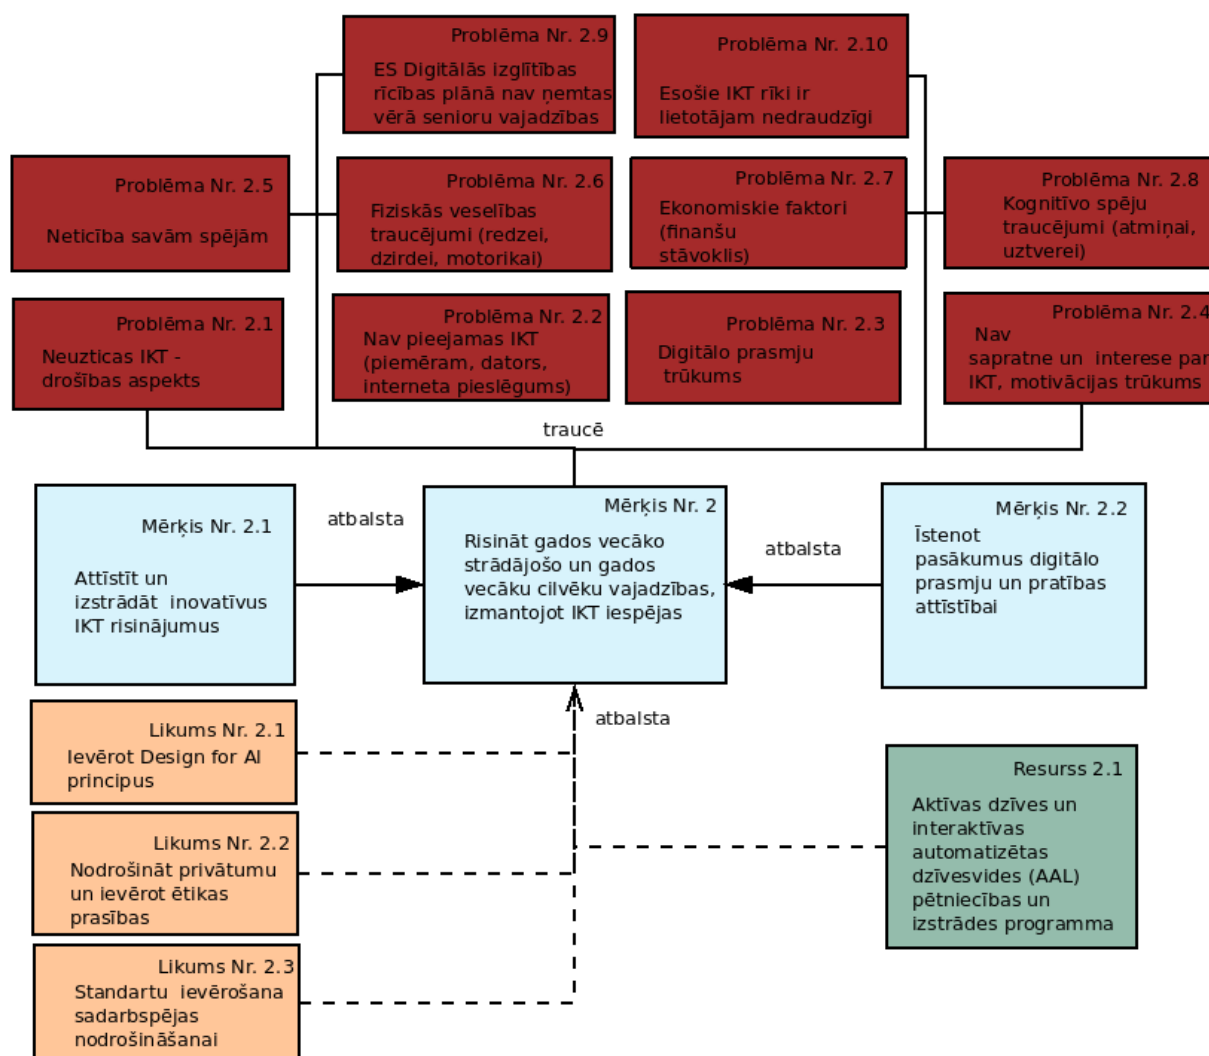
Stratēģiskais mērķis: *Risināt gados vecāko strādājošo un gados vecāku cilvēku vajadzības*

Viens no e-iekļaušanas modeļa stratēģiskajiem mērķiem ir risināt gados vecāko strādājošo un gados vecāku cilvēku vajadzības. Gados vecāku cilvēku skaits ES palielinās. Tiek prognozēts, ka līdz 2070. gadam iedzīvotāju skaits vecumā virs 65 būs 30 %, salīdzinājumā ar 20% 2019. gadā (*European Commission, 2020a*), līdz ar to vecāku cilvēku īpatsvars pieaugs un ir nepieciešams nodrošināt tiem pilnvērtīgas iespējas digitālajā telpā.

1.4. attēlā ir doti stratēģiskā mērķa *Risināt gados vecāko strādājošo un gados vecāku cilvēku vajadzības* sasniegšanas apakšmērķi, problēmas, likumi, kas jāņem vērā.

Atbilstoši e-iekļaušanas stratēģijai ir jānodrošina, ka gados vecāki cilvēki izmanto IKT un to risinājumus (Mērķis Nr. 2.1) un ka tiek īstenoti pasākumi digitālo prasmju pilnveidei (Mērķis Nr. 2.2).

Ar IKT un to risinājumu palīdzību vecāka gadagājuma cilvēkiem jāuzlabo nodarbinātību, darba apstākļus, produktivitāti, darba un privātās dzīves līdzsvaru, jāpaaugstina līdzdalība sabiedrībā, ekonomikā, pašizteikšanās iespējas, jānodrošina pieejamība precēm, pakalpojumiem, saturam. Būtiski ir attīstīt sociālās un veselības aprūpes IKT pakalpojumus un asistējošas tehnoloģijas. Piemēram, Digitālā programmā precīzē, ka līdz 2020. gadam jāpanāk, ka ir izveidoti jauni attālināti e-veselības pakalpojumi – tiešsaistes konsultācijas, portatīvas ierīces, kuras var izmantot hronisku slimību monitorēšanā. 2021. gadā Eiropas Komisija paziņojumā par digitālajiem mērķiem paredz, ka 2030. gadā 100 % Eiropas pilsoņu būs piekļuve medicīniskajai kartītei (“slimību e-vēsturei”). Tomēr jāņem vērā, ka IKT risinājumi, kas atbalsta aktīvu un veselīgu novecošanos ir jāpielāgo konkrētās valsts kontekstā (Soja u. c., 2019).



1.4. att. E-iekļaušanas stratēģiskā mērķa *Risināt gados vecāko strādājošo un gados vecāku cilvēku vajadzības, izmantojot IKT iespējas* problēmas un īstenošanas pamatlikumi.

Pētījumos kā šķēršļi (Problēmas Nr. 2.1–2.3) IKT un to risinājumu lietošanā tiek minēti - neuzticēšanās IKT (drošības aspekts), tehnoloģiju nepieejamība (nav pieslēguma internetam, nav pieejams dators) un digitālo prasmju trūkums (Choudrie, Ghinea un Songonuga, 2013; Olphert, Damodaran un May, 2005). Vēl viens būtisks šķērslis (Problēma Nr. 2.4) ir izpratnes trūkums, kāpēc būtu jāizmanto tehnoloģijas, daļai vecāka gadagājuma cilvēkiem nav

motivācijas lietot IKT, tie dod priekšroku tradicionāliem socializēšanās paņēmieniem (piemēram, tikšanās un sarunas klātienē) (Cullen u. c., 2007; Jung u. c., 2010; Olphert, Damodaran un May, 2005). Pētījumi norāda arī uz tādiem psiholoģiskiem šķēršļiem (Problēma Nr. 2.5) kā uztraukums par novecošanu, neticība spējai lietot datoru (Jung u. c., 2010). Senioru apmācībā un IKT lietošanā ir jāņem vērā arī šādi šķēršļi (Problēmas Nr. 2.6 – 2.8) – problēmas ar fizisko veselību (redzes, dzirdes, motorikas traucējumi), kognitīvās spējas (atmiņas, informācijas uztveres traucējumi), kā arī izplatīta problēma ir ierobežots finansējums (Ala-Mutka u. c., 2008).

Prasmju pilnveide ir viena no iespējām, kā nodrošināt dzīves kvalitāti visa mūža garumā, uzsvērts 2021. gada Eiropas Komisijas Zaļajā grāmatā par novecošanu (European Commission, 2021a). Eiropas nevalstisko organizāciju apvienība, kas aizstāv senioru tiesības, kritizē Eiropas Komisijas Digitālās izglītības rīcības plānu 2021.–2027. gadam, ka tas neietver senioru vajadzības (Problēma Nr. 2.9), un norāda, ka nepieciešams uzlabot pieejamību tiešsaistes mācību saturam, apmācību formu kā neformālo izglītību (AGE Platform Europe, 2020; European Commission, 2020b).

Lai veicinātu, ka seniori izmanto IKT risinājumus, tiem jāatbilst *Design for All* principiem (Likums Nr. 2.1), jo lietojamība ir viens no šķēršļiem (Problēmas Nr. 2.10), kas traucē apgūt IKT (Ala-Mutka u. c., 2008; European Commission, 2010). IKT risinājumu izveidē jāņem vērā privātuma nodrošināšana un ētikas prasības, kā arī jāievēro standarti un savietojamības prasības (Likumi Nr. 2.2 – 2.3) (European Commission, 2021).

Kā viens no resursiem, ar kura palīdzību veidot senioriem iekļaujošus IKT risinājumus, ir Aktīvas dzīves un interaktīvas automatizētas dzīvesvides pētniecības un izstrādes programma (*Ambient Assisted Living Joint programme*), kuru Eiropas Komisija īsteno, sākot no 2008. gada (*Ambient Assisted Living Joint programme*, 2014).

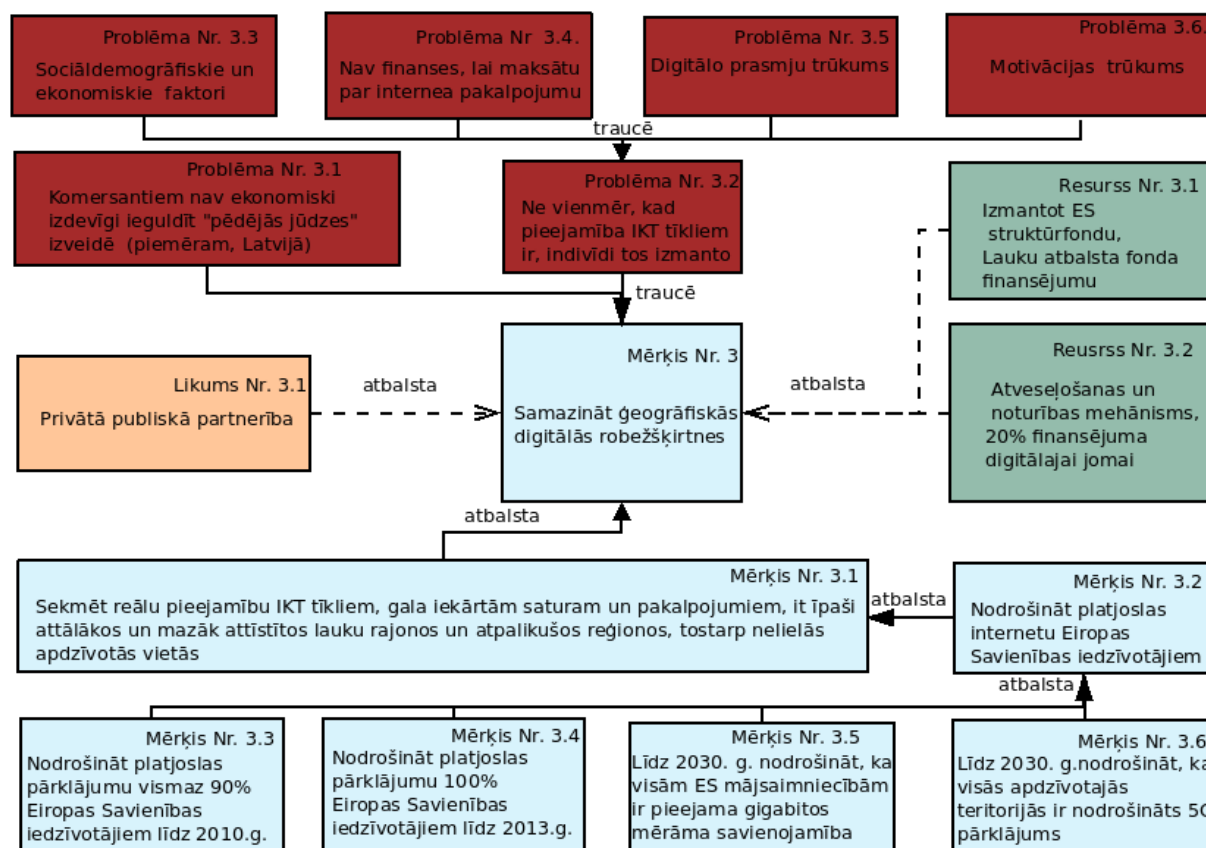
Stratēģiskais mērķis: Samazināt ģeogrāfiskās digitālās robežšķirtnes

Lai samazinātu ģeogrāfiskās digitālās robežšķirtnes, 2006. gada e-iekļaušanas deklarācija par mērķi izvirzīja nodrošināt ES reālu pieejamību IKT tīkliem un gala iekārtām, saturam un pakalpojumiem visur, jo īpaši attālākos un mazāk attīstītos lauku rajonos un atpalikušos reģionos, tostarp nelielās apdzīvotās vietās (1.5. att., Mērķis Nr. 3.1) (Armenta u. c., 2012; Chena un Liu, 2013; Gryczka, 2011; Sánchez, 2010; Townsend u. c., 2013; Warren, 2007). Piekļuve tīkliem un tehnoloģijām nav svarīga tikai privātām vajadzībām un izklaidei, tā ir nepieciešama arī izglītības nodrošināšanai un uzņēmumiem pakalpojumu sniegšanai. 2006. gadā tika izvirzīts mērķis nodrošināt platjoslas pieslēgumu vismaz 90% ES iedzīvotāju līdz 2010. gadam (Mērķis 3.2, 3.3). Šeit jāatzīmē, ka 2010. gadā šie rezultāti pilnībā netika sasniegti, atbilstoši Eiropas Komisijas statistikas datiem platjoslas pieslēgums tika nodrošināts 61 % mājokļu (*European Commission*, 2014).

2010. gadā Eiropas Komisijas Digitālajā programmā secināts, ka ir bijuši nepietiekami ieguldījumi tīklos un nākamajos gados jādara vairāk, lai nodrošinātu platjoslas izvēršanu un apguvi plašākās teritorijās, sasniedzot 100 % platjoslas pārklājumu ES iedzīvotājiem līdz 2013. gadam (Mērķis Nr. 3.4) (Eiropas Komisija, 2006; Eiropas Komisija 2010). Kā rāda statistikas dati, 2013. gadā neizdevās šo noteikumu nodrošināt pilnībā, platjoslas internets ir tikai 76 % mājokļu (*European Commission*, 2014).

Uz ģeogrāfiskām digitālām atšķirībām Eiropas Komisija norāda arī 2021. gadā paziņojumā par digitālajām prioritātēm līdz 2030. gadam (Eiropas Komisija, 2021). Eiropas

pilsoņi un uzņēmumi ne visos reģionos vienlīdz labi var izmantot digitālo tehnoloģiju sniegtās iespējas labākai un pārticīgākai dzīvei. Droša, veikspējīga un ilgtspējīga digitālā infrastruktūra ir Eiropas Komisijas mērķis, un līdz 2030. gadam būtu jāpanāk, ka visām ES mājsaimniecībām ir pieejama gigabitos mērāma savienojamība un visās apdzīvotajās teritorijās ir nodrošināts 5G pārklājums (Mērķis Nr. 3.5, Nr. 3.6). Vispārējai piekļuvei interneta pakalpojumiem ir jāklūst par ES iedzīvotāju pamattiesībām.



1.5. att. Stratēģiskā mērķa *Samazināt ģeogrāfiskās digitālās robežšķirtnes* problēmas, resursi un īstenošanas pamatlikums.

Neskatoties uz to, ka pastāvīgi tiek uzlabota pieejamība tehnoloģijām attālākos un mazāk attīstītos reģionos, joprojām pastāv digitālo iespēju atšķirības. Atbilstoši ES statistikas datiem platjoslas internetu 2019. gadā nelietoja 22 % mājsaimniecību (European Commission, 2020c).

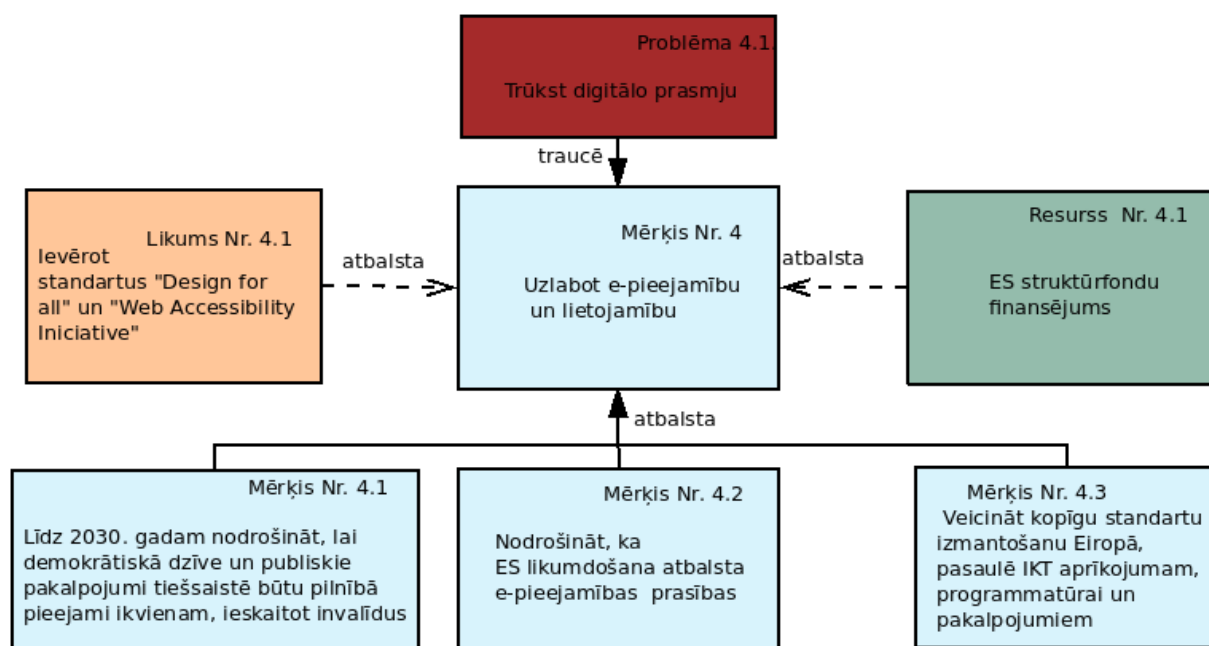
Lai panāktu tīklu pieejamību ikvienā, arī nomaļās teritorijās, EK stratēģijā norāda, ka jāīsteno privātā un publiskā partnerība, jāstimulē privātā sektora ieguldījumi (Likums Nr. 3.1). Jāatzīmē, ka šeit problēmas rada “pēdējās jūdzes” nodrošināšana (Problēma 3.1). Piemēram, Latvijā komersantiem nav ekonomiski izdevīgi ieguldīt “pēdējās jūdzes” nodrošināšanā. Tam iemesls ir reģionālā nelīdzsvarotība, vairāk kā 52 % iedzīvotāju ir Rīgā vai tās apkārtnē. Un tādējādi attālos reģionos iedzīvotājiem netiek nodrošināta kvalitatīva pieeja internetam (Helmane, 2019).

Tomēr situācijās, kad reģionos tiek nodrošināta interneta pieejamība, jāņem vērā pētījumos norādīto, ka visi indivīdi uzreiz šajos reģionos nesāks lietot IKT (Problēma Nr. 3.2). Pastāv traucējoši faktori, kā, piemēram, sociāldemogrāfiskie (Amy, 2011; Townsend u. c.,

2013) vai ekonomiskie – ierobežotais finansējums, iedzīvotāji nevar atļauties apmaksāt, piemēram, interneta pieslēgumu (Problēma Nr. 3.3, 3.4) (Cullen u. c., 2007). Būtisks šķērslis ir digitālo prasmju trūkums (Problēma Nr. 3.5) (Chena un Liu, 2013; Gryczka, 2011; Khalil Moghaddam un Khatoon-Abadi, 2013). Kā arī svarīgi ir, lai iedzīvotāji būtu motivēti lietot IKT (Problēma Nr. 3.6) (Peronard un Just, 2011).

Resursi, kurus Eiropas Komisija piedāvā tehnoloģiju pieejamības nodrošināšanai, ir struktūrfondi un Atveseļošanās un noturības mehānisms, kas paredz 20 % finansējuma digitālajai jomai (Resurss Nr. 3.1).

Stratēģiskais mērķis: *Uzlabot e-pieejamību un lietojamību*



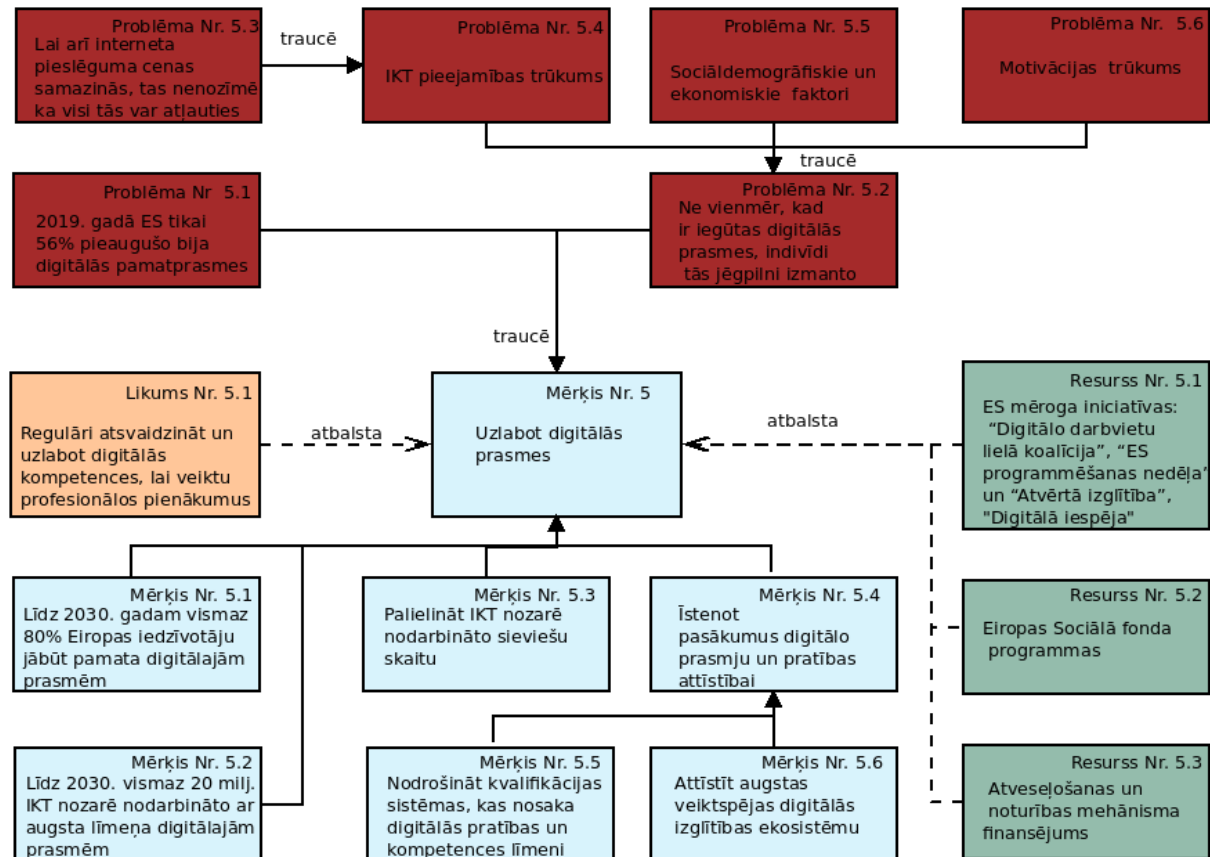
1.6. att. Stratēģiskā mērķa *Uzlabot e-pieejamību un lietojamību* īstenošanas problēma, pamatlikumi, resursi.

Atbilstoši ES statistikas 2019. gada datiem ES ir vairāk kā 80 miljonu iedzīvotāju ar īpašām vajadzībām (European Commission, 2020c). Informācijas un komunikācijas tehnoloģiju pieejamības un lietojamības nodrošināšana ir viens no e-iekļaušanas stratēģiskajiem mērķiem, kas ir aktuāls arī 2021. gadā. Eiropas Komisija ir noteikusi, ka līdz 2030. gadam ES jānodrošina, lai demokrātiskā dzīve un publiskie pakalpojumi tiešsaistē būtu pilnībā pieejami ikvienam, ieskaitot cilvēkus ar īpašām vajadzībām (1.6. attēls, Mērķis Nr. 4.1) (European Commission, 2021).

Lai uzlabotu e-pieejamību un lietojamību jānodrošina, ka ES likumdošana atbalsta e-pieejamību, jāīsteno e-pieejamības prasības ES likumdošanā par elektronisko sakaru un gala iekārtu aprīkojumu, jānodrošina, lai pilnībā tiktu ņemtas vērā lietotāju ar īpašām vajadzībām prasības, uzlabojot esošos likumus (Mērķis Nr. 4.2.) Nepieciešams ir ievērot e-pakalpojumu izstrādē dizains visiem ("Design for All") standartus un tīmekļa pieejamības ("Web Accessibility Initiative") standartus, kā arī jāpanāk, lai tas ir iestrādāts normatīvajos aktos (Likums Nr. 4.1) (Cullen u. c., 2007; Geiger u. c., 2011). Jāveicina kopīgu prasību un standartu izmantošanu Eiropā un visā pasaulē pieejamam un izmantojamam IKT aprīkojumam, programmatūrai un pakalpojumiem, atbalstot lietotāju iesaistīšanos, izmantojot

standartatbilstību (Mērķis Nr. 4.3). Nepieciešams ne tikai nodrošināt pieejamas un ērti lietojamas IKT, bet jānovērš arī digitālo prasmju trūkumu cilvēkiem ar īpašām vajadzībām (Problēma Nr. 4.1) (Benda, u. c., 2011; Farbeh-Tabrizi, 2012).

Stratēģiskais mērķis: *Uzlabot digitālās prasmes*



1.7. att. Stratēģiskā mērķa *Uzlabot digitālās prasmes* problēmas un īstenošanas pamatlikumi, resursi.

Iedzīvotāju digitālo prasmju uzlabošana ir viena no galvenajām jomām ESs digitālo mērķu kontekstā (European Commission, 2021). ES ir pastāvīgi atzinusi digitālo pamatprasmju nozīmi visiem iedzīvotājiem un iekļāvusi tās gan 2006. gadā e-iekļaušanas deklarācijā, gan 2010. gadā digitālajā programmā “Eiropa 2020” (European Commission, 2006; European Commission, 2010). Digitālās prasmes ir atzītas par vienu no astoņām pamatprasmēm, kas ir būtiski svarīgas ikkatram cilvēkam (Eiropas Padome, 2006; Eiropas Padome, 2018). Tomēr 2019. gadā ES tikai 56 % pieaugušo bija digitālo pamatprasmju (1.7. att., Problēma Nr. 5.1) (Eiropas Revīzijas palāta, 2021). Eiropas Komisija kā mērķi ir izvirzījusi līdz 2030. gadam panākt, ka vismaz 80 % visu pieaugušo ir apguvuši digitālās pamatprasmes un ES informācijas un komunikācijas tehnoloģiju nozarē ir nodarbināti 20 miljoni speciālistu, turklāt būtu jāpalielina šajā nozarē nodarbināto sieviešu īpatsvars (Mērķis Nr. 5.1–5.3) (European Commission, 2021).

Digitālo kompetenču un prasmju pamatkomponentes Eiropas Komisija ir identificējusi ietvarā *DigComp*, tās ir – informācijas un datu lietpratība, komunikācija un sadarbība, digitālā satura veidošana, drošība, problēmu risināšana. Eiropas Padome ieteikumos par mūžizglītību

digitālo kompetenci definē kā pārlicinātu, kritisku un atbildīgu digitālo tehnoloģiju izmantošanu mācību un darba vajadzībām un nolūkā piedalīties sabiedriskajā dzīvē (Eiropas Padome, 2018). Jāatzīmē, ka 2006. gada Eiropas Padomes ieteikumos šādi tika definētas digitālās prasmes. Digitālās izglītības rīcības plāns 2021.–2027. gadam paredz papildināt kompetences mākslīgā intelekta un datu jomā, lai atbalstītu mācību resursu izstrādi par mākslīgo intelektu, izstrādātie resursi domāti skolām, profesionālās izglītības un apmācības organizācijām un citiem apmācības sniedzējiem (*European Commission, 2020; Ferrari, 2013; LR Izglītības un zinātnes ministrija, 2021*). Viena no digitālās kompetences būtiskām pazīmēm ir, ka tā ir vērsta uz attīstību, tas ir, tā pastāvīgi balstās uz esošām un jauniegūtām prasmēm un zināšanām. Teorētiski indivīds, kam piemīt digitālā prasme, ir spējīgs adaptēt jaunās tehnoloģijas ātri un pieņemt jaunu sazināšanās veidu, līdz ar tā parādīšanos. Jo vairāk indivīds ir digitāli lietpratējs, jo vieglāk viņam ir pārslēgties uz jaunu “prasmes režīmu” (*Ng, 2012*). Digitālās kompetences attīstība notiek trīs līmeņos (*Abad, 2014*):

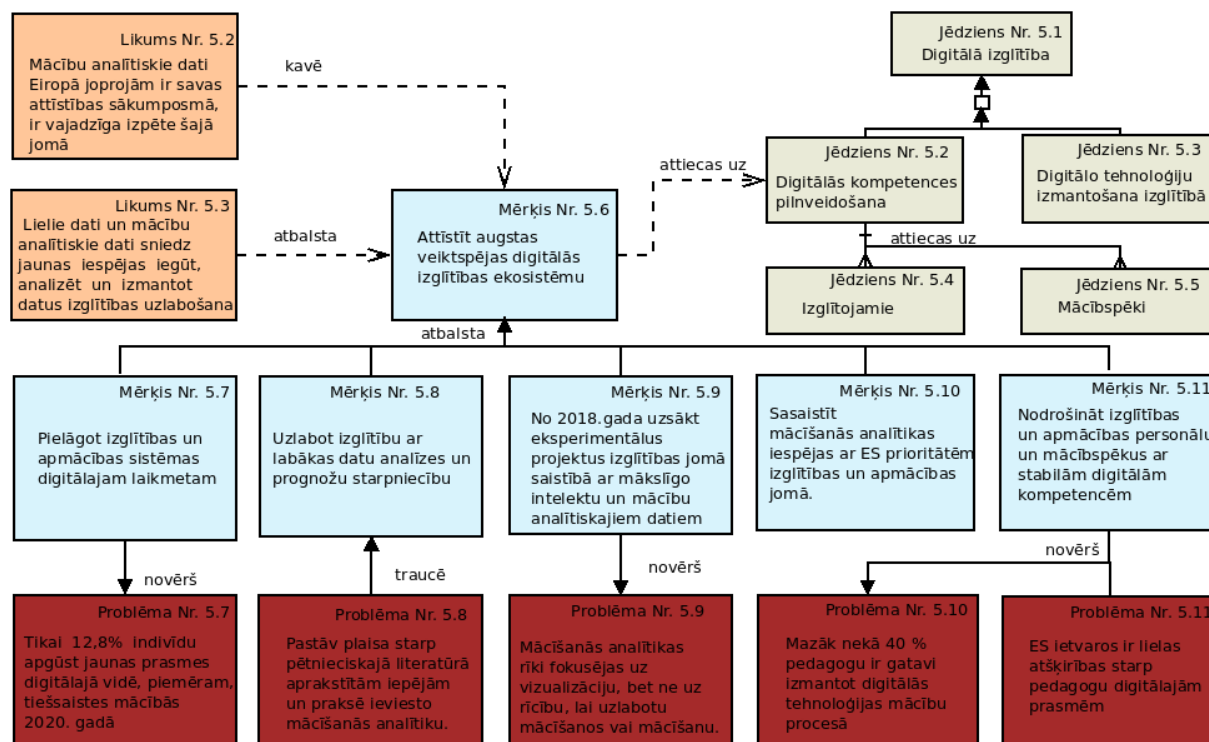
- digitālo prasmju attīstība, kas ietver tādas prasmes kā informācijas meklēšana, dokumentu sagatavošana, attēlu izveide un manipulācijas ar tiem, prezentāciju veidošana, satura publicēšana tīmeklī u.c. formālās, operacionālās prasmes, informācijas prasmes.
- IKT lietošana, kas ietver sekmīgu digitālo prasmju lietošanu dažādās dzīves situācijās, profesionālajā darbībā vai citur, lai sasniegtu noteiktus mērķus.
- digitālā transformācija, kas ietver spēju, ka esošo digitālo prasmju lietojums rada inovācijas un izraisa izmaiņas profesionālajā jomā vai personīgā, vai sociālā kontekstā.

Eiropas Komisija Digitālajā Kompasā, kas satur digitālos mērķus līdz 2030. gadam, un Digitālās izglītības rīcības plānā 2021.–2027. gadam norāda, ka digitālo prasmju uzlabošana būtu jāveicina, īstenojot pasākumus prasmju pilnveidei (Mērķis Nr. 5.4). Tie var notikt gan formālās izglītības, gan neformālās izglītības ietvaros. Regulāra prasmju pilnveide ir nepieciešama, lai uzturētu prasmes atbilstoši tehnoloģiju attīstības tendencēm (Likums Nr. 5.1) (*European Commission, 2010*). Nepieciešama efektīva IKT apmācība un sertifikācija ārpus formālās izglītības sistēmas, jānodrošina kvalifikācijas sistēmas, lai noteiktu digitālās kompetences līmeni (Mērķis Nr. 5.5). Būtiski ir attīstīt augstas veiktspējas digitālās izglītības ekosistēmu (Mērķis Nr. 5.6) (*European Commission, 2020b; European Commission, 2021*).

Digitālā izglītība aptver divus atšķirīgus, bet savstarpēji papildinošus aspektus: pirmkārt, digitālās kompetences pilnveidošanu gan izglītības ieguvējiem, gan izglītības sniedzējiem (pedagogiem) un, otrkārt, digitālo tehnoloģiju izmantošanu pedagoģiskajā darbā, izglītības un apmācības sistēmās (1.8. att., Jēdziens Nr. 5.1–5.5) (*European Commission, 2018*). Lai sekmētu digitālās izglītības ekosistēmas izveidi, nepieciešams nodrošināt infrastruktūru, savienojamību un digitālo aprīkojumu, atbilstošu izglītības un apmācības personālu un mācībspēkus ar stabilām digitālām kompetencēm, kvalitatīvu mācību saturu, lietotājdraudzīgus rīkus un drošas platformas, kas ievēro privātuma un ētikas standartus (*European Commission, 2020*). Būtiski ir panākt, ka izglītības un apmācības sistēmas tiek pielāgotas digitālajam laikmetam (Mērķis Nr. 5.7), un tiek izmantotas tiešsaistes sistēmas apmācību procesā, tomēr jānorāda, ka atbilstoši ES statistikas datiem 2020. gadā tikai 12,8 % pieaugušo iedzīvotāju izvēlas apgūt jaunas prasmes tiešsaistesursos (Problēma Nr. 5.7) (*Casacuberta, 2007; European Commission, 2020; European Commission, 2021b*). Digitālo prasmju apguve kombinētās mācīšanāsursos (angļu val. – *blended learning*) pētījumos tiek

vērtēta atzinīgi (*Gudmundsdottir un Vasbø, 2017; Guillen-Gamez u. c., Martínez-Alcalá u. c., 2018; Patmanthara u. c., 2018; Smith, 2014; Tucker u. c., 2009*).

Digitālās izglītības rīcības plāns 2018.–2020. gadam uzsver datu nozīmi digitālās izglītības nodrošināšanā, par vienu no prioritātēm izvirzot labākas datu analīzes un prognozēšanas nodrošināšanu (Mērķis Nr. 5.8) (*European Commission, 2018*). Digitālās izglītības rīcības plāns norāda uz nepieciešamību veikt eksperimentālus projektus izglītības jomā saistībā ar mākslīgo intelektu un mācību analītiku, lai sekmētu digitālās izglītības nodrošināšanu (Likums Nr. 5.3; Mērķis Nr. 5.9). Mācību analītika palīdz atklāt riska studentus un uzlabot mācību sasniegumus (*Herodotou u. c., 2019*).



1.8. att. Mērķa *Attīstīt augstas veiktspējas digitālās izglītības ekosistēmu* apakšmērķi, problēmas, saistītie likumi un jēdzieni digitālo prasmju uzlabošanas kontekstā.

Pētījumā par mācību analītikas lietojumu, kuru veica Eiropas Apvienotais pētījumu centrs (*Joint Research Centre*), norādīts, ka mācību analītikas potenciāls nav izmantots un pastāv atšķirības starp zinātniskajā literatūrā norādītām iespējām un praksē ieviesto mācību analītiku, jāņem vērā, ka ES mācību analītika ir tās izpētes sākumposmā (Likums Nr. 5.2, Problēma Nr. 5.8) (*Ferguson u. c., 2016; Maennel, 2020*). Neskatoties uz to, ka datu apjoms par studentiem pieaug, pētījumā, kur analizēti 252 mācību analītikas lietojumu, tiek secināts, ka ir maz pierādījumu par to, ka mācību analītika ietekmē studentu sasniegumu rādītājus (*Viberg u. c., 2018*). Diemžēl vairums mācību analītikas rīki fokusējas uz datu vizualizāciju, nevis uz ieteikumiem, kā rīkoties, lai uzlabotu izglītības procesu, tādēļ nepieciešami papildus pētījumi (Problēma Nr. 5.9). Būtiski ir sasaistīt mācību analītikas iespējas ar ES prioritātēm izglītības un apmācības jomā (Mērķis Nr. 5.10).

Lai gan sākotnēji 2006. gadā e-iekļaušanas deklarācija paredz, ka digitālo prasmju apguves pasākumiem jābūt pielāgotiem digitālās izslēgšanas riska grupām, kuras veido bezdarbnieki, imigrantiem, cilvēki ar zemu izglītības līmeni, cilvēki ar īpašām vajadzībām,

gados vecāki cilvēki, jaunieši nelabvēlīgos apstākļos, 2021. gadā Eiropas Komisija uzsver ikviena indivīda nodrošināšanu ar digitālām prasmēm, tajā skaitā arī nodarbināto, lai cilvēki var apgūt specializētas digitālās prasmes. Digitālās izglītības rīcības plānā kā svarīga mērķgrupa digitālo prasmju apguvei tiek uzrādīti izglītības darbinieki, pedagogi, kuriem ir nozīmīga loma tieši digitālās izglītības ieviešanā (Mērķis Nr. 5.11). Bet saskaņā ar ES pētījumu mazāk par 40 % no pedagogu ir gatavi izmantot digitālās tehnoloģijas mācību procesā un pastāv atšķirības ES ietvaros starp pedagogu digitālajām prasmēm (Problēma Nr. 5.10–5.11).

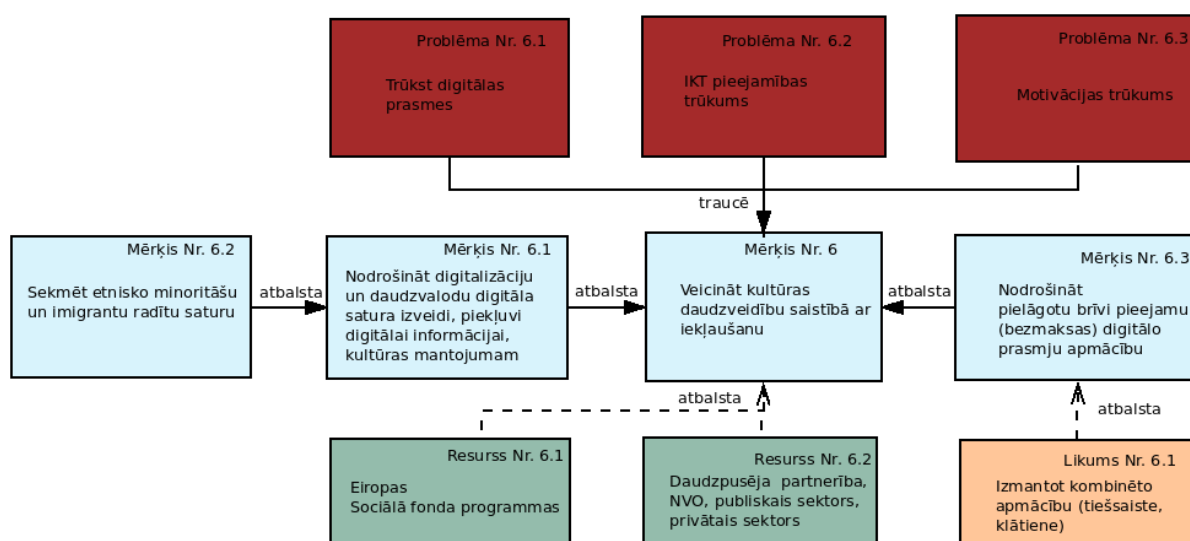
Pētījumi norāda, ka pastāv vairākas problēmas, ne vienmēr, kad indivīdi ir apguvuši digitālās prasmes, tie tās jēgpilni izmanto savām profesionālām vajadzībām vai personības pilnveidei. Pastāv dažādi šķēršļi - trūkst motivācija, nav pieejams interneta pieslēgums vai traucē sociāldemogrāfiskie vai ekonomiskie faktori (1.7. att., Problēmas Nr. 5.2–5.6).

Pasākumus digitālo prasmju uzlabošanai iespējams īstenot, izmantojot Eiropas Sociālā fonda finansējumu, publisko privāto partnerību, ES mēroga iniciatīvas, Atveseļošanās un noturības mehānisma finansējumu (1.7. att., Resurss Nr. 5.1–5.3).

Stratēģiskais mērķis: *Veicināt kultūras daudzveidību saistībā ar iekļaušanu*

Kultūras daudzveidības digitālajā telpā veicināšana ir mērķis gan e-iekļaušanas deklarācijā, gan Digitālajā programmā, savukārt 2021. gada ES Digitālajā kompāsā ir norādīts, ka ikvienam iedzīvotājam ir jānodrošina digitālajā vidē tās pašas tiesības, kas reālajā pasaulē (*European Commission, 2006; European Commission, 2010; European Commission, 2021*).

Imigranti un etniskās minoritātes, it īpaši gados vecāki cilvēki un cilvēki ar zemāku izglītību ir riska grupa, kas pakļautas atstumtībai digitālajā vidē, kā to apliecina pētījumi. (*Lupiañez u. c., 2015; Yu u. c., 2018*). Digitālā iekļaušana ir izšķiroša imigrantu garīgajai veselībai un labklājībai, sociālajai iekļaušanai, norādīts Starptautiskās imigrācijas organizācijas iniciatīvas par daudzveidību, iekļaušanu un sociālo kohēziju 2020. gada izdevumā (*DISC Initiative, 2020*).



1.9. att. Stratēģiskā mērķa *Veicināt kultūras daudzveidību saistībā ar e-iekļaušanu* problēmas un īstenošanas pamatlikumi, resursi.

Nepieciešams integrēt digitālajā vidē ikvienai Eiropā dzīvojošai tautībai, tai skaitā etniskajām minoritātēm un imigrantiem svarīgas vērtības.

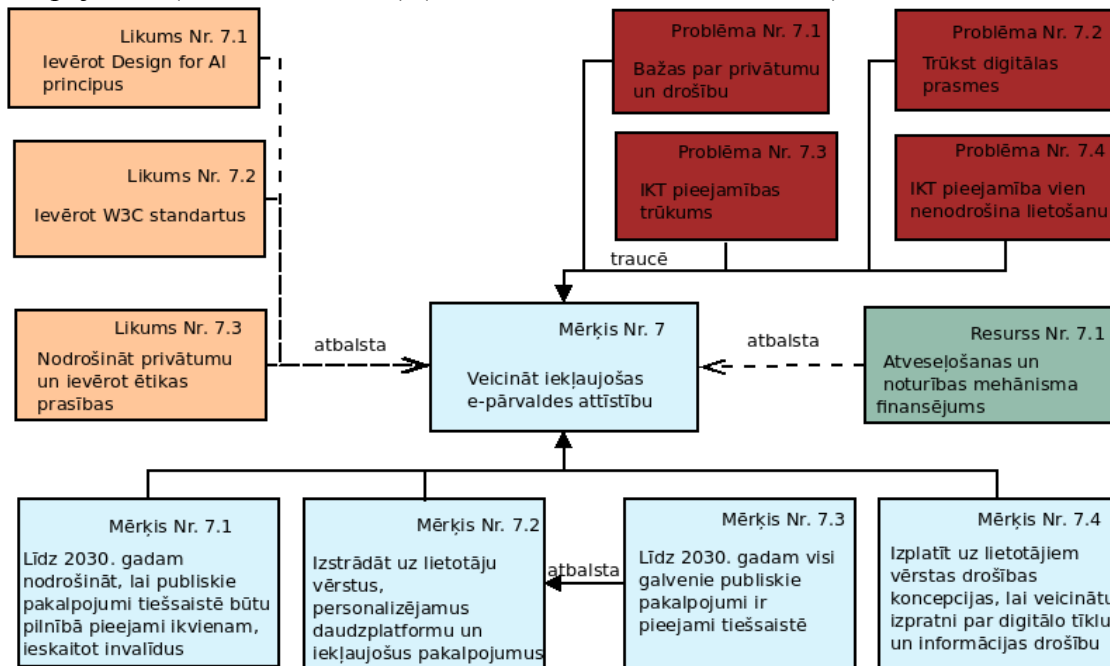
Lai sekmētu kultūras identitāti un valodu daudzveidību digitālajā telpā, jāsteno sekojošas aktivitātes: jānodrošina digitalizāciju un pieejama digitāla satura izveidi, plašu un arī starpvalstu piekļuvi digitālai informācijai un kultūras mantojumam (1.9. att. Mērķis Nr. 6.1). Digitālā programma nosaka, ka jānodrošina Eiropas digitālās bibliotēkas ilgtspējīgu izveidi. Būtiski ir sekmēt daudzvalodību un vietējo saturu visā Eiropā, kā arī Eiropas brīvības, tolerances, vienlīdzības, solidaritātes un demokrātijas vērtības. Pētījumi rāda, ka svarīgi ir sekmēt pašu indivīdu radītu saturu, kā piemēram, emuāru, ievietošanu tīmeklī un sociālo tīklu izmantošanu (Mērķis Nr. 6.2) (*Cullen u. c., 2007; Diminescu u. c., 2010*). Digitālā programma norāda, ka jāattīsta tulkošanas tehnoloģijas. IKT inovācijas un labas pieredzes apmaiņa visos līmeņos ir būtisks līdzeklis, lai to sasniegtu. Svarīgi ir, ka saturs ir pieejams no dažādām platformām (*Cullen u. c., 2007*).

Lai uzlabotu ekonomisko un sociālo līdzdalību, integrāciju, radošo izpausmju un uzņēmējdarbības iespējas imigrantiem un etniskajām minoritātēm jāsekmē viņu līdzdalību informācijas sabiedrībā. Īpašas pūles jāvelta nodarbinātības un darba produktivitātes uzlabošanai, tāpēc svarīgas ir speciālas brīvi pieejamas apmācības digitālo prasmju pilnveidei (Mērķis 6.3) (*Rissola un Centeno, 2011; Colucci u. c., 2017*). Jāņem vērā, ka nepieciešams pilnveidot pašu izglītības darbinieku zināšanas par IKT izmantošanu (*Driessen u. c., 2011; Kluzer, u. c., 2011; Rissola un Centeno, 2011*). Kā arī šeit parādās problēmas, ka imigrantiem nav pieejamas IKT un trūkst motivācija tās lietot, it sevišķi, ja prasmes ir nelielas (*Codagnone un Kluzer, 2011; Driessen u. c., 2011; Kluzer, u. c., 2011*). Pētījumi rekomendē izmantot speciāli (ne vispārīgu) mērķgrupai izstrādātu kombinētās mācīšanās pieeju (e-mācības un klātienē nodarbības) formālajā un neformālajā izglītībā (Likums Nr. 6.1) (*Colucci u. c., 2017; Rissola un Centeno, 2011*). Ņemot vērā to, ka indivīdu prasmju līmenis ir dažāds, pētījumi iesaka nodrošināt, ka apmācības tiek veiktas atbilstoši esošajam zināšanu līmenim (*Driessen u. c., 2011*). Lai izglītības aktivitātes būtu efektīvākas, nepieciešams veidot partnerības ar NVO, privāto sektoru, publisko sektoru, izmantot Eiropas Sociālā fonda programmas (*Rissola un Centeno, 2011*).

Stratēģiskais mērķis: *Veicināt iekļaujošas e-pārvaldes attīstību*

E-iekļaušanas deklarācija, Digitālā programma un 2021. gadā publicētie Digitālā Kompassa mērķi paredz, ka iekļaujoša e-pārvalde ir viena no ES digitālo mērķu prioritātēm (*European Commission, 2006; European Commission, 2010, European Commission, 2021*). Būtiski ir projektēt un izstrādāt uz lietotāju vērstus, personalizējamus, daudzplatformu un iekļaujošus pamatpakalpojumus, izmantojot un nodrošinot dažādus kanālus (piemēram, e-pasts, teksta ziņojumi) un platformas (telefons, TV) (*Cullen u. c., 2007*). Līdz 2030. gadam plānots, ka visi galvenie publiskie pakalpojumi ir pieejami tiešsaistē; katram iedzīvotājam ir piekļuve savai medicīniskajai e-kartītei un 80 % iedzīvotāju izmanto eID risinājumus, kā arī demokrātiskā dzīve un publiskie pakalpojumi ir pieejami ikvienam, ieskaitot cilvēkus ar īpašām vajadzībām (1.10 att., Mērķis. Nr. 7.1–7.3) (*European Commission, 2021*). Jāņem vērā, ka saskarnēm ir jābūt lietotājiem draudzīgām visiem komunikāciju kanāliem un visām mērķauditorijām, jāizmanto *Dizains visiem* principi (Likums Nr. 7.1). Labāku izpratni par cilvēku vēlmēm jāiegūst, iesaistot riska grupas pārstāvjus e-pakalpojuma izstrādē. Jāsekmē un jānodrošina pieeju visām publiskajām tīmekļa lapām saskaņā ar atbilstīgiem *W3C* tīmekļa

lapu pieejamības standartiem un vadlīnijām (Likums Nr. 7.2) (*European Commission, 2010*). Kā viens no mērķiem, kuru jāīsteno, lai nodrošinātu iekļaujošus publiskos pakalpojumus, ir izplatīt uz lietotāju vērstas drošības koncepcijas, lai palielinātu izpratni par digitālā tīkla un informācijas drošību (Mērķis Nr. 7.4), jo bažas par privātumu un drošību ir viens no šķēršļiem, kāpēc nelieto e-pakalpojumus (Problēma Nr. 7.1). Izstrādājot e-pakalpojumus, jānodrošina privātuma un ētikas prasības (Likums Nr. 7.3). Tomēr jāņem vērā, ka šķērslis ir IKT nepieejamība un zināšanu trūkums (Problēma Nr. 7.2, 7.3) (*Rana, u. c., 2013*). Pētījumi norāda, ka arī interneta pieejamības nodrošināšana vēl nenozīmē, ka cilvēki izmantos e-pakalpojumus (Problēma Nr. 7.4) (*Baird, Zelin II un Booker, 2012*).



1.10. att. Stratēģiskā mērķa *Veicināt iekļaujošas e-pārvaldes attīstību* problēmas, resursi un īstenošanas pamatlikumi.

Atvēršanās un noturības mehānisma finansējums ir izmantojams kā resurss iekļaujošu e-pakalpojumu izveidē (Resurss Nr. 7.1) (*European Commission, 2021*).

Secinājumi par stratēģisko mērķu un biznesa likumu modeli

E-iekļaušanas stratēģisko mērķu modelis atklāj, ka e-iekļaušanas mērķi ir virzīti uz tehnoloģiju pieejamības nodrošināšanu, samazinot ģeogrāfisko digitālo plaisu, digitālo prasmju uzlabošanu, iekļaujošu e-pārvaldi ar inovatīviem, daudzplatformu IKT risinājumiem. Daži mērķi ir vērsti uz konkrētām mērķauditorijām, piemēram, uz vecāku cilvēku, cilvēku ar īpašām vajadzībām, minoritāšu vai imigrantu e-iekļaušanu. Var secināt, ka e-iekļaušanas deklarācijā ir akcentētas dažas riska grupas, bet Digitālā programma un Digitālais kompass paplašina e-iekļaušanas mērķauditoriju, norādot, ka ikvienam indivīdam, ikvienā profesijā ir jāapzinās IKT potenciāls un jānodrošina to iekļaušana. Tāpat Digitālā programma, Digitālās izglītības rīcības plāns un zinātnieku pētījumi norāda, ka svarīgi ir uzlabot digitālās prasmes izglītības darbiniekiem, lai tie varētu pedagogiskajā darbībā izmantot IKT. Analizējot problēmas, kas traucē sasniegt mērķus, var redzēt, ka vairākkārt pie dažādiem stratēģiskiem mērķiem kā šķēršļi parādās nepieejamība IKT, digitālo prasmju trūkums un sociāldemogrāfiskie un ekonomiskie faktori.

Analizējot likumus vai noteikumus, kas ietekmē e-iekļaušanas mērķu sasniegšanu, var redzēt, ka tieši pasākumi **digitālo prasmju uzlabošanai** ir nepieciešami ikviena mērķa sasniegšanai.

E-iekļaušanas procesu modelis un tā saistība ar dalībnieku un resursu modeli

Tā kā e-iekļaušanas mērķu modeļa un likumu modeļu analīze parādīja, ka pasākumi **digitālo prasmju uzlabošanai** ir nepieciešami ikviena mērķa sasniegšanai, tad šajā apakšnodalā tiek veidots indivīdu e-iekļaušanas procesu modelis saistībā ar digitālo prasmju apguvi, attēlojot to kopā ar nepieciešamajiem resursiem un mērķauditoriju.

Pētījumi par sabiedrības e-iekļaušanas procesiem rāda, ka sākotnēji dominēja pieņēmums, ka nodrošinot indivīdiem tehnoloģiju pieejamību, tiks panākta šo indivīdu e-iekļaušana. Situāciju, kad daļai indivīdu ir pieejamas tehnoloģijas un daļai tās nav pieejamas dēvē par 1. paaudzes digitālo plaisu. Termins “digitālā plaisa” parādījās pagājušā gadsimta 90.-tajos gados ASV (*Rapaport, 2009*). Tehnoloģiju pieejamības nodrošināšana kā vienīgais nosacījums indivīdu e-iekļaušanai pētījumos tiek kritizēts (*Van Deursen un Van Dijk, 2009*). Pētījumi rāda, ka pārbaudot dažādas IKT (piemēram, e-pasts, interneta banka, biroja programmatūra, tīmeklis utml.), kam ir nodrošināta pieejamība un radīti nosacījumi to sākotnējai lietošanai – atklājas, ka tas vēl negarantē, ka tiks turpinātas šīs IKT lietot (*DiMaggio u. c., 2008; Hsieh, Rai un Keil, 2008; Matzat un Sadowski, 2012; Sanz un Turlea, 2012; Sundqvist u. c., 2020*). Novērtējot indivīdu prasmes izmantot e-pakalpojumus, pētījumos tiek secināts, ka ne visi indivīdi, kam ir pieejams internets, lieto e-pakalpojumus (*Van Deursen un Van Dijk, 2009*).

20. gs. beigās un 21. gs. sākumā uzsvars no tehnoloģiju pieejamības pētījumiem pārvietojās uz indivīdu grupu izpēti, kas atšķiras ar pieejamo tehnoloģiju lietošanu (*Zhao un Elesh, 2007*). Pastāvēja uzskats, ka viens no galvenajiem rīcības virzieniem e-iekļaušanas procesa veicināšanai ir attīstīt indivīdiem digitālās prasmes (*Achituv u. c., 2008; Casacuberta, 2007; Cullen u. c., 2007; ECDL, 2007; Erstad, 2010; European Commission, 2006; FreshMinds, 2007; DLHLEG, 2008; Matzat un Sadowski, 2012; Riga Dashboard, 2007*). Digitālo prasmju apguve kā viens no svarīgākajiem e-iekļaušanas mērķiem ir atzīts arī Latvijas progresa ziņojumā ES par e-iekļaušanu (*Latvia e-inclusion report, 2008*). Savukārt Eiropas Komisija kā vienu no būtiskākajiem šķēršļiem, kas apdraud centienus izmantot IKT, norāda profesionālo IKT prasmju un digitālo prasmju un iemaņu deficītu. Situācija, kad daļa indivīdu lieto tehnoloģijas, jo tiem ir prasmes, bet otra daļa nelieto tehnoloģijas, tiek dēvēta par 2. paaudzes digitālo plaisu (*OECD, 2010*).

Jāuzsver, ka jaunu digitālo prasmju apguve un to jēgpilna izmantošana ir divi atšķirīgi e-iekļaušanas procesa soļi, digitālo prasmju esamība vien vēl nenodrošina indivīda e-iekļautību (*Demoussis un Giannakopoulos, 2006; Gurstein, 2003; Ono un Zavodny, 2008; Lerchner, u. c., 2007*). Savukārt atšķirības digitālo prasmju sasniegumos bieži izskaidro atšķirības IKT lietošanas kvalitātē (*Livingstone un Helsper, 2007; Selwyn, 2004; Van Dijk, 2006*). Lai indivīds būtu e-iekļauts, pēc digitālo prasmju apguves indivīdam ir jālieto digitālās prasmes jēgpilni, tas ir, risinot kādu profesionālo vai privāto vajadzību, tādējādi sekmējot tautsaimniecības izaugsmi un iekļaujoties sabiedrībā (*Deursen, 2009; Van Dijk, 2006*). Svarīgi ir digitālo prasmju apmācību nodrošināt kopā ar prasmju jēgpilnu lietošanu (*Mariën un Van Audenhove, 2010*). Mūsdienās tiek ieviests jēdziens “3. paaudzes digitālā plaisa”, kas ir izveidojusies starp tiem, kas lieto jēgpilni tehnoloģijas, tas ir – ar tehnoloģiju starpniecību

gūst labumu profesionālām vajadzībām vai personības pilnveidei, un tiem, kuri tehnoloģijas lieto, bet neiegūst no tām ne profesionālām vajadzībām, ne privātām vajadzībām (*Robles un Torres-Albero, 2012*). Šādās situācijās veidojas IKT **lietošanas plaisa** jeb **plaisa starp indivīda zināšanām par IKT un IKT izmantošanu jēgpilni** (*Deursen, 2009; Van Dijk, 2006; Van Deursen un Van Dijk, 2015*). Plaisas vienā pusē atrodas tie indivīdi, kas lieto tehnoloģijas un iegūst sev dažādas priekšrocības no to pielietojuma, bet otrā pusē ir tie, kas neko neiegūst, lai gan arī šiem indivīdiem piemīt digitālās prasmes. Piemēram, pastāv atšķirības, kā topošie politiķi izmanto tehnoloģijas vēlēšanu kampaņām (*Herrnson u. c., 2007*). 3. paaudzes digitālā plaisa tiek raksturota ar digitālo nevienlīdzību (angļu val. – *digital inequalities*), kas pastāv starp dažādām indivīdu grupām.

Uzsvars no sākotnēji akcentētās tehnoloģiju pieejamības mūsdienās ir novirzījies uz jēgpilnu IKT lietošanu (*Zhao un Elesh, 2007, Yu u. c., 2017*). Autore promocijas darbā uzskata, ka **indivīds ir e-iekļauts, ja indivīds izmanto digitālās prasmes profesionālajām vai privātajām vajadzībām un savas personības izaugsmei** nevis, ja indivīds ir apguvis digitālās prasmes, bet tās neizmanto.

Lai nonāktu pie jēgpilnas IKT lietošanas ir vairāki e-iekļaušanas procesa posmi (1.11. att.). E-iekļaušanas process atkārtojas, parādoties jaunai informācijas un komunikācijas tehnoloģijai (*Van Dijk, 2006; Yu u. c., 2018*). Tehnoloģiju attīstība indivīdiem nemitīgi liek apgūt jaunas digitālās prasmes. E-iekļaušanas kontekstā ir jārunā par indivīda situatīvo e-iekļaušanu, kas attiecas uz konkrētas tehnoloģijas izmantošanu konkrētam mērķim konkrētā situācijā. Piemēram, ja indivīds sekmīgi izmanto saziņai ar kolēģiem Skype, tad indivīdu var uzskatīt par e-iekļautu šī viena rīka kontekstā, bet ne kopumā. Indivīda kopējo e-iekļautību veido tā situatīvās e-iekļaušanas kopums. Indivīda e-iekļaušanas process sastāv no četriem procesiem jeb posmiem (*van Dijk, 2006; Scheerder u. c., 2017; Yu u. c., 2018*):

1. posms: indivīdam ir motivācija lietot jauno tehnoloģiju;
2. posms: indivīdam jaunā tehnoloģija ir fiziski pieejama (1. paaudzes digitālā plaisa);
3. posms: indivīdam ir digitālās prasmes, kā lietot tehnoloģiju (2. paaudzes digitālā plaisa);
4. posms: indivīds lieto jauno tehnoloģiju jēgpilni, tas ir, risinot kādu profesionālo vai privāto vajadzību (3. paaudzes digitālā plaisa, digitālā nevienlīdzība).

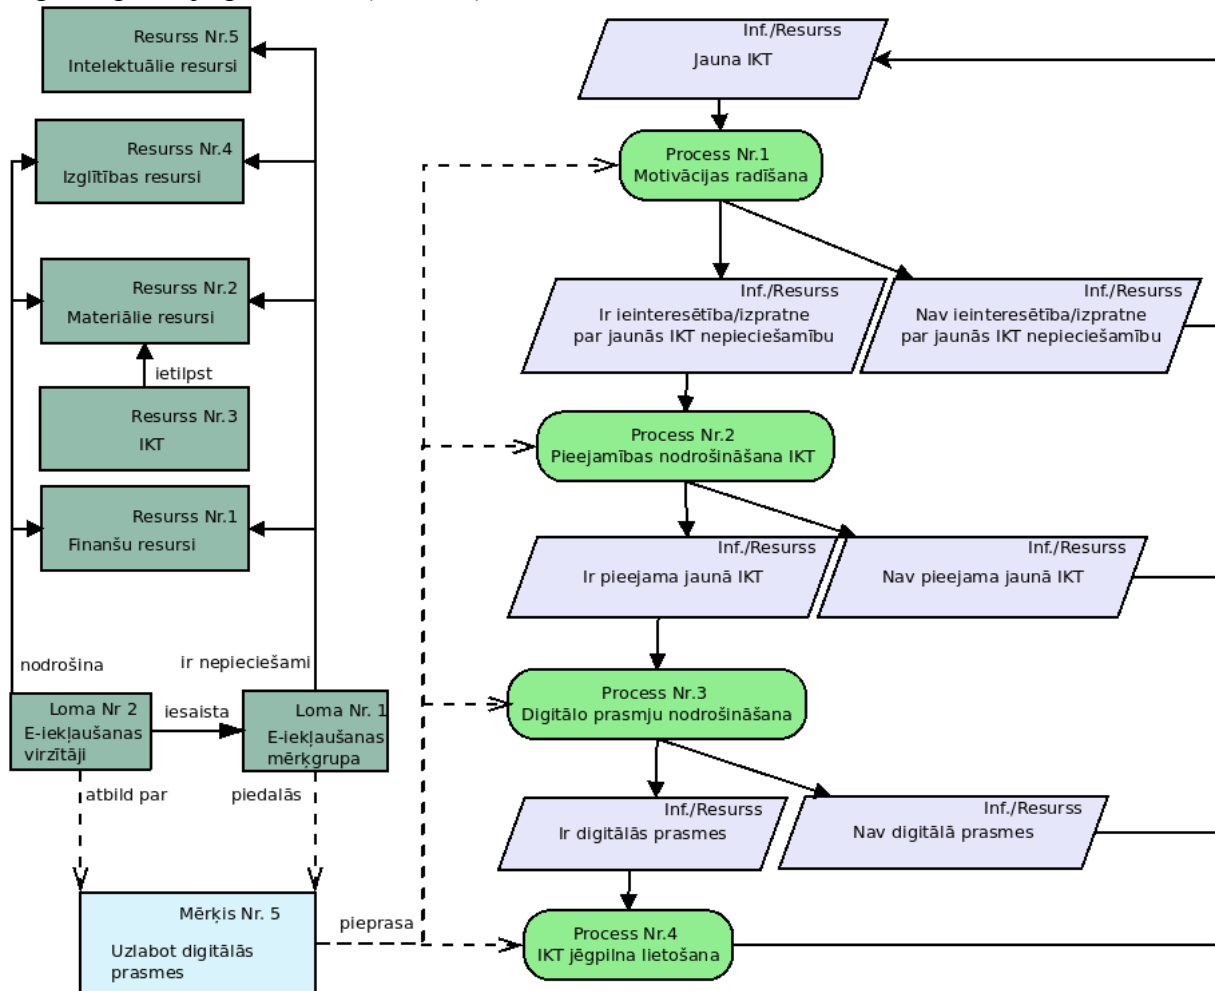
Plaisa vai atšķirības starp indivīdiem var rasties jebkurā e-iekļaušanas procesa posmā. Lai arī pētījumi rāda, ka pastāv pozitīva saistība starp IKT pieejamību, lietošanu un to ietekmi uz indivīdu (piemēram, ekonomiski ieguvumi), neviens no šiem minētajiem e-iekļaušanas procesa posmiem automātiski nenodrošina nākamā izpildīšanos (*Hilbert, 2010; Sundqvist u. c., 2020*).

Promocijas darbā tiks pētīts, kā nodrošināt, ka indivīds no e-iekļaušanas procesa 3. posma nonāk e-iekļaušanas noslēguma, 4. posmā un iegūtās digitālās prasmes jēgpilni lieto profesionālām vai privātām vajadzībām, kā panākt, ka samazinās jēgpilnas lietošanas plaisa.

E-iekļaušanas procesa resursi

Digitālā nevienlīdzība ir kompleksa un daudzšķautņaina problēma, kuras risināšanā no indivīda skatupunkta ir vajadzīgi finanšu, materiālie, izglītības un intelektuālie resursi (*De Haan, 2004; Payton 2003; Van Dijk and Hacker, 2003*) (1.11. att). Materiālie resursi iekļauj informācijas un komunikācijas tehnoloģijas, kas nepieciešamas, lai nodrošinātu digitālo prasmju apguvi. Izglītības resursi attiecas uz mācību materiāliem, izglītojošiem pasākumiem

digitālo prasmju apguvei. Intelektuālie resursi e-iekļaušanas kontekstā ir spēja darboties ar informāciju un iegūt jaunas prasmes, izmantojot IKT (*De Haan, 2004, Greene u. c., 2014*). E-iekļaušanas deklarācija, Digitālā programma, Digitālais kompass norāda, ka būtisks finanšu resurss, kuru organizācijas, kas īsteno e-iekļaušanu, var izmantot, ir ES fondi vai atbalsta programmas, kas nodrošina, e-iekļaušanas mērķauditorijai gan IKT, gan izglītības iespējas digitālo prasmju pilnveidei.(1.11. att).



1.11. att. Individā e-iekļaušanas procesa modelis.


E-iekļaušanas virzītāji un mērķgrupas

Detalizētāk e-iekļaušanā iesaistītās personas ir atklātas 1.12. attēlā. Tās ir grupētas divās daļās: (1) tie, kuri ir jāiekļauj, tas ir, e-iekļaušanas mērķgrupa; (2) tie, kas īsteno e-iekļaušanu.

Pamatojoties uz pētījumiem, ir noteiktas e-iekļaušanas kritiskās grupas sabiedrībā. Mērķgrupas ir noteiktas vadoties no tā, ka tām pētījumos ir identificētas problēmas, lai iekļautos vai arī balstoties uz statistikas datiem, kas apliecina to, ka mērķgrupa neizmanto IKT jēgpilni. Jāuzsver, ka bieži pētītas mērķgrupas, ko veido indivīdi, kam ir dažādu mērķgrupu pazīmes. Piemēram, tiek apvienoti vairāki sociālekonomiskie faktori kā ienākumu līmenis, vispārējā izglītība, vecums (*Hsieh, Rai un Keil, 2008*).

Viena no mērķgrupām ir vecāki cilvēki: strādājošie pirmspensijas vecumā, pensijas vecumā esošie indivīdi. Personas ar zemākiem ienākumiem un personas ar zemu vispārējo izglītības līmeni pētījumos tiek atzītas par e-iekļaušanas riska grupu, šai grupai ir grūtības nodrošināt IKT pieejamību, trūkst motivācijas apgūt jaunas zināšanas. Personas, kuras ietekmē

ģeogrāfiskais novietojums, var kļūt par riska grupu. Būtisks šķērslis cilvēkiem, kuri dzīvo attālākos un mazāk attīstītos lauku rajonos un atpalikušos reģionos, tostarp nelielās apdzīvotās vietās, ir platjoslas interneta pieejamība. Gan Eiropas Komisijas e-iekļaušanas deklarācija, gan Digitāla programma, gan pētījumi norāda, ka riska grupā ir personas no mazāk attīstītiem reģioniem (Kyung Hoon, Sei Kwon, Seong No un Jaekyung, 2010; Matzat un Sadowski, 2012; Oyedemi, 2012).



1.12. att. E-iekļaušanas mērķgrupas un procesa virzītāji.

Cilvēki ar īpašām vajadzībām ir grupa, kurai ir apgrūtināta IKT izmantošana, jo tehnoloģijas nav pielāgotas to vajadzībām, kā arī bieži tehnoloģiju apgūšanu kavē sociāldemogrāfiskie un ekonomiskie faktori (Vicente un Lopez, 2010). Pētījumi norāda, ka viena no grupām, kam nepieciešama ir e-iekļaušana ir sievietes, tomēr vienlaicīgi tiek norādīts, sievietēm izmantot IKT traucē viens vai vairāki sociālekonomiskie un demogrāfiskie faktori – bezdarbs, izglītības līmenis, vecums un ienākumi (Hilbert, 2011; Lin, u. c., 2012).

Nodarbinātības statuss ir atzīts par būtisku kritēriju cilvēku e-iekļaušanai. Bezdarbnieki ir viena no e-iekļaušanas mērķgrupām, kam nepieciešams pilnveidot IKT lietošanas prasmes, tas norādīts vairākos pētījumos (De Hoyos u. c., 2013; Basili, 2013).

E-iekļaušanas deklarācija norāda uz nepieciešamību pastiprinātu uzmanību pievērst imigrantu un etnisko minoritāšu iekļaušanai. Šīm mērķgrupām IKT spēlē nozīmīgu lomu valsts valodas apguvei, kas ir pamats šo personu ekonomiskai izaugsmei un sociālai iekļaušanai (Codagnone un Kluzer, 2011; Diminescu u. c., 2010; Driessen u. c., 2011; Jung u. c., 2010; Kluzer u. c., 2011; Rissola un Centeno, 2011).

Tomēr sociālā atstumtība, kas rodas no digitālās atstumtības, nav tikai dažu nelabvēlīgu grupu robežās (piemēram, cilvēkiem ar zemiem ienākumiem, zemu izglītību vai bezdarbniekiem), tā eksistē arī daudz augstāk vērtētās grupās kā cilvēkiem ar augstāko

izglītību, cilvēkiem, kas tehnoloģijas izmanto no bērnības (angļu val. – *digital native*), bet kuriem trūkst noteiktu digitālo prasmju un tiem, kam nav motivācijas lietot IKT (*Hargittai*, 2010). Pretēji uzskatam, ka paaudzei, kas ir iepazinusi internetu jau bērnībā, nav problēmu interneta lietošanā, tiek norādīts, ka šai paaudzei trūkst digitālās pratības, respektīvi, prasmes jēgpilni lietot internetu (informācijas un stratēģiskās prasmes) (*Van Deursen* un *Van Dijk*, 2009). Daudziem studentiem, kas studē, lai iegūtu augstāko izglītību, nepiemīt digitālā pratība (*Santos* u. c., 2013). Tie uzsāk tālākizglītību vai formālo izglītību, kad tiem trūkst prasmes, kā izmantot digitālās tehnoloģijas izglītības vajadzībām. Jaunieši kā riska grupa, kuru nepieciešams iekļaut, ir norādīta vairāku zinātnieku pēdējo gadu pētījumos (*Drabowicz*, 2014; *Hargittai* un *Hinnant*, 2008; *Li* un *Ranieri*, 2013; *Lichy*, 2011; *Sanz* un *Turlea*, 2012).

Digitālo prasmju uzlabošana ir būtiska komponente, kas jānodrošina topošajiem nodarbinātajiem un jāpilnveido esošajiem nodarbinātajiem. Viena no iekļaušanas mērķgrupām, kuru profesionālajā darbībā aizvien vairāk ir nepieciešams jēgpilni izmantot IKT iespējas, ir izglītības darbinieki. IKT izmantošanas aktualitāte izglītības darbinieku administratīvajā un mācību darbā ir uzsvērtā Eiropas Komisijas, Latvijas valdības dokumentos, kā arī dažādos pētījumos (*Altun*, 2019; Izglītības un zinātnes ministrija, 2006; *Rintamäki* un *Lehto*, 2018; *Roulston* u. c., 2019; *Uzunboylu* un *Tuncay*, 2010; *Záhorec* u. c., 2019). 2014. gadā LR Ministru kabineta atbalstītajās “Izglītības attīstības pamatnostādnes 2014.–2020. gadam” norādīts, ka nepieciešams turpināt profesionālās kapacitātes paaugstināšanu IKT jomā profesionālās izglītības mācībspēkiem un prakšu vadītājiem (Izglītības un zinātnes ministrija, 2014). Digitālās prasmes ir kļuvušas par “izdzīvošanai nepieciešamu prasmi”, bet skolotājiem bieži ir zems pašvērtējums savām prasmēm, lai tās atbilstu mācību procesa vai citām profesionālām vajadzībām. Ekonomiskās sadarbības un attīstības organizācijas (ESAO) 2018. gada pētījums (*Jerrim* un *Sims*, 2019) liecina, ka mazāk nekā 40 % pedagogu jūtas gatavi izmantot digitālās tehnoloģijas mācību procesā un ka ES ietvaros ir lielas atšķirības. ES Rīcības plānā digitālās izglītības jomā (2021.–2027.g.) ir paredzēts, ka jānodrošina izglītības un apmācības personāls un mācībspēki ar stabilām digitālām kompetencēm. Pedagogu apmācība ir nepieciešama gan, lai uzlabotu pedagogu digitālās prasmes, gan, lai vēlāk pedagogi kļūtu par augstas veiktspējas digitālās izglītības ekosistēmas sastāvdaļu. Digitālā kompetence ir viena no svarīgākajām skolotāja kompetencēm. Divās trešdaļās Eiropas izglītības sistēmu skolotāja profesijā nepieciešamā digitālā kompetence ir atspoguļota kompetences standartā kā viena no svarīgākajām skolotāja kompetencēm (*European Commission/EACEA/Eurydice*, 2019). Pētījumos ir uzsvērts izglītības darbinieku prasmju trūkums un nepieciešamība nodrošināt tiem digitālo prasmju pilnveidi, lai izglītības darbinieki spētu pilnvērtīgi izmantot IKT piedāvātās iespējas (*Abrantes*, u. c., 2007; *Cort* u. c., 2004). Jāuzsver, ka izglītības darbinieku digitālās prasmes ir būtiskas, jo pedagogi ir iesaistīti digitālo prasmju apmācībā gan jauniešiem, gan citām e-iekļaušanas mērķgrupām.

Otru grupu pārstāv tie, kuru mērķis ir nodrošināt, lai indivīdi būtu e-iekļauti (1.12. att). Šo mērķgrupu veido publiskā, privātā un nevalstiskā sektora organizācijas, kas īsteno sociālās un e-iekļaušanas mērķus, izmantojot IKT, vai veicina IKT izmantošanu, lai uzlabotu sociālekonomisko iekļaušanu sociāli atstumtām un riska grupām, kā arī personām, kurām draud izslēgšana. 2013. gadā veiktajā pētījumā par e-iekļaušanas īstenošanai ES, iesaistot 2752 organizācijas, ir uzsvērtā e-iekļaušanas īstenošanu daudzveidība (*Rissola* un *Garrido*, 2013). Lielākā daļa (58 %) organizāciju pārstāv publisko sektoru, visbiežāk šīs organizācijas

ir publiskās bibliotēkas, pašvaldību iestādes un valsts telecentri/interneta piekļuves punkti.

Nevalstiskā sektora organizācijas veido 40 % un to skaitā ir asociācijas, labdarības organizācijas, dažādi nodibinājumi un biedrības. Privātais sektors ir 6 % un to pārstāv mācību centri un interneta kafejnīcas. Pētījuma autori norāda, ka ES ir gandrīz 250 000 e-iekļaušanas organizāciju.

1.3. Kopsavilkums un secinājumi par e-iekļaušanu un tās procesu tendencēm

Šajā nodaļā, izmantojot *4EM* uzņēmumu modelēšanas metodi, tika pētīta e-iekļaušana un tās procesi, lai precizētu e-iekļaušanas tvērumu, kas tiks pētīts promocijas darbā. Iegūtās zināšanas no ES politikas dokumentiem un dažādiem pētījumiem par e-iekļaušanu tika strukturētas, un tika izveidots e-iekļaušanu aprakstošs modelis, dodot visaptverošu ieskatu par e-iekļaušanu un tās procesiem.

E-iekļaušanas problēmapgabals ietver plaša spektra uzdevumus, kurus ir nepieciešams īstenot, lai sasniegtu izvirzīto e-iekļaušanas politisko mērķi – samazināt atšķirības IKT lietošanā un veicināt IKT lietošanu ikvienam indivīdam, lai tādējādi veicinātu ekonomisko izaugsmi, attīstītu nodarbinātību, sekmētu sociālo iekļaušanos un dzīves kvalitāti. Galvenie virzieni, kur jāveic aktivitātes, ir vecāka gadagājuma cilvēku iekļaušana, pieejamības nodrošināšana IKT cilvēkiem ar īpašām vajadzībām, ģeogrāfiski attālo un ekonomiski mazattīstīto reģionu iekļaušana, dažādu etnisko minoritāšu un imigrantu iekļaušana, ikvienam pieejamas e-pārvaldes attīstība.

Tomēr par būtiskāko mērķi e-iekļaušanas kopējo mērķu sasniegšanā var uzskatīt **digitālo prasmju uzlabošanu**. Digitālās prasmes ir vienas no cilvēka pamatprasmēm. Digitālo prasmju svarīgums ir akcentēts atkārtoti gadu garumā ES politikas dokumentos. Uzlabot indivīdu digitālās prasmes ir mērķis, kas jau no 2006. gada tiek pastāvīgi izvirzīts, kā viena no prioritātēm ES digitālajās stratēģijās un e-iekļaušanas politikas dokumentos. Tomēr neizdodas sasniegt šo mērķi – panākt, ka ikvienam indivīdam ir pietiekams digitālo prasmju līmenis, lai tas iegūtu no digitālo tehnoloģiju lietojuma.

Uzlabojot indivīdu digitālās prasmes, tiek sekmēta arī citu e-iekļaušanas politikas mērķu sasniegšana, kā, piemēram, vecāka gadagājuma cilvēku vajadzību risināšana, veicināta iekļaujošas e-pārvaldes attīstība, samazinātas ģeogrāfiskās digitālās robežšķirtnes. Digitālās prasmes ir viens no būtiskākajiem priekšnoteikumiem indivīda e-iekļaušanai.

Pētītā literatūra norāda, ka fiziska pieejamība tehnoloģijām, vēl negarantē, ka indivīds šīs tehnoloģijas izmantos. Indivīda iesaiste digitālo prasmju apguvē arī vēl nenozīmē, ka indivīds nākotnē izmantos apgūtās prasmes. **Vissvarīgākā ikvienam indivīdam ir digitālo prasmju jēgpilna izmantošana, kas cieši ir saistīta gan ar tehnoloģiju pieejamību, gan digitālo prasmju apguvi**. Digitālo prasmju jēgpilna izmantošana ir jāskatās kontekstā ar digitālo prasmju apguvi, lai indivīds ar IKT palīdzību gūtu labumu profesionālām vajadzībām vai personības pilnveidei.

E-iekļaušana attiecas praktiski uz ikvienu iedzīvotāju, tai skaitā, jauniešiem, topošajiem nodarbinātajiem, cilvēkiem, kuri plāno mainīt nodarbošanos un izglītības darbiniekiem, kam tehnoloģijas ir nepieciešamas pedagoģiskajā darbībā.

Autore, vadoties no e-iekļaušanas procesu teorētiskās izpētes, indivīda e-iekļaušanu

prognozējošā tehnoloģiskā modeļa izstrādē nolemj ņemt vērā sekojošas atziņas:

1) Digitālās prasmes ir būtisks priekšnosacījums indivīda e-iekļaušanai. Tomēr fiziska pieejamība tehnoloģijām un digitālo prasmju esamība negarantē, ka indivīds šīs tehnoloģijas izmantos. Tikai jēgpilna digitālo prasmju izmantošana liecina par indivīda e-iekļautību.

Nepieciešams panākt efektīvu indivīdu pāreju no e-iekļaušanas procesa posma, kurā tas apgūst digitālās prasmes un nākamo, pēdējo e-iekļaušanas procesa posmu, kurā indivīds jēgpilni izmanto apgūtās digitālās prasmes.

2) Nepieciešams noteikt faktoros, kas sekmē indivīda pāreju uz pēdējo e-iekļaušanas procesa posmu, kurā indivīds izmanto apgūtās digitālās prasmes.

Šobrīd esošie pētījumi, galvenokārt, raksturo indivīdus, izmantojot sociāli demogrāfiskos un ekonomiskos faktoros kā dzimums, vecums, iegūtā izglītība, ienākumu līmenis un, vadoties no šiem faktoriem, izdara secinājumus, kāds vecums, dzimums un citi raksturojoši lielumi ir cilvēkiem, kuriem ir digitālās prasmes un kuri tās jēgpilni izmanto. Tomēr, jāņem vērā, ka sociāldemogrāfiskie un ekonomiskie faktori ir grūti izmaināmi lielumi, un jāmeklē ir indivīdu raksturojoši faktori zināšanu radīšanas un pārneses procesu kontekstā, kuri prognozē indivīda e-iekļaušanas iespējas, un būtiski ir, ka to vērtības ir iespējams ietekmēt, lai sasniegtu augstāku līmeni, ka indivīds izmantos apgūtās digitālās prasmes jēgpilni.

3) Nepieciešams digitālo prasmju apmācību indivīdu e-iekļaušanas nolūkā veikt interneta vidē, kombinējot to ar klātienē tikšanās. Mācības, izmantojot interneta vidi, atbilst ES Rīcības plānam digitālās izglītības jomā (2021–2027), kas aicina pielāgot izglītības un apmācības sistēmas digitālajam laikmetam. Aktuāla ir problēma, ka tikai neliels skaits indivīdu apgūst jaunas prasmes digitālajā vidē, piemēram, tiešsaistes mācībās - tikai 12,8 % 2020. gadā. Tāpēc ir svarīgi pētīt, kā efektīvāk nodrošināt digitālo prasmju apguvi, izmantojot internetā pieejamas mācību platformas.

4) Mērķauditorija - pedagogi. Pētījumi un ES politikas plānošanas dokumenti norāda, ka uzmanība e-iekļaušanas kontekstā ir jāpievērš ne tikai “tradicionālajām” riska grupām, bet praktiski ikvienam iedzīvotājam. Mērķauditorijas - pedagogu izvēles pamatojums balstās tajā, ka lielākajai daļai pedagogu nav pietiekamu digitālo prasmju. Ekonomiskās sadarbības un attīstības organizācijas (ESAO) 2018. gada pētījums (*Jerrim un Sims, 2019*) parādīja, ka mazāk nekā 40 % pedagogu jutās gatavi izmantot digitālās tehnoloģijas mācību procesā un ka ES ietvaros ir lielas atšķirības. Pedagogu izvēle kā e-iekļaušanas mērķgrupa atbilst arī ES Rīcības plānā digitālās izglītības jomā (2021–2027) prioritātēm, kas paredz, ka jānodrošina izglītības un apmācības personāls un mācībspēki ar stabilām digitālām kompetencēm. Digitālā kompetence ir viena no svarīgākajām skolotāja kompetencēm. Pedagogu apmācība ir nepieciešama gan, lai uzlabotu pedagogu digitālās prasmes, gan, lai vēlāk pedagogi kļūtu par augstas veiktspējas digitālās izglītības ekosistēmas sastāvdaļu. Pētījumi norāda, ka situācijās, kad tehnoloģijas ir pieejamas, tomēr ir grūti panākt, ka digitālo tehnoloģiju sniegtās priekšrocības tiktu izmantotas pedagoģiskajā darbā (*Cachia u. c., 2010*). Tāpēc ir svarīgi pētīt, kā efektīvāk nodrošināt un pilnveidot tieši pedagogu digitālās prasmes, lai tādējādi iegūtu no tehnoloģijām izglītības procesā.

5) ES Digitālās izglītības rīcības plāns norāda uz nepieciešamību izmantot mācību analītikas iespējas, sekmējot digitālo izglītību.

Autore promocijas darba kontekstā izvirza e-iekļaušanu prognozējošajam modelim šādus mērķus:

1) izmantojot mācību analītikas iespējas, noteikt indivīdu, kuram ir risks, ka tas nelietos

tiešsaistes un klātienē nodarbībās jaunapgūtās digitālās prasmes (risks, ka indivīds nebūs e-iekļauts);

2) noteikt indivīdam zināšanu radīšanas un pārneses procesu kontekstā riska faktorus, kasi ietekmē indivīda mācību rezultātu, tas ir, indivīda e-iekļautību.

Promocijas darba kontekstā digitālās prasmes apgūst pedagogi, tāpēc indivīdi, kuriem tiks prognozēts risks būt digitāli izslēgtiem, būs pedagogi.

2. E-IEKĻAUSĀNAS PROGNOZĒŠANAS TEHNOĻĪJU UN METOŽU ANALĪZE

Šīs nodaļas mērķis ir noteikt, kādas prasības indivīda e-iekļaušanu prognozējošajam modelim ir jāizvirza no prognozēšanas tehnoloģiju un metožu aspekta, lai īstenotu iepriekšējā nodaļā izvirzīto mērķi:

1) noteikt indivīdu, kuram ir risks, ka tas nelietos tiešsaistes un klātienēs nodarbībās jaunapgūtās digitālās prasmes (risks, ka indivīds nebūs e-iekļauts);

2) noteikt indivīdam zināšanu radīšanas un pārneses procesu kontekstā riska faktoros, kas ietekmē indivīda mācību rezultātu, tas ir, indivīda e-iekļautību.

Lai noteiktu, kādas prasības indivīda e-iekļaušanu prognozējošajam modelim ir jāizvirza no prognozēšanas tehnoloģiju un metožu aspekta, šajā nodaļā veikti šādi uzdevumi:

1) Izpētīta zinātniskā literatūra par prognozējošo modeļu izveides tehnoloģijām un metodēm, mācību analītiku, tās lietojumu indivīda e-iekļaušanu prognozējošo modeļu izveidē.

2) Veikti secinājumi par e-iekļaušanu prognozējošā modeļa izveidošanas, novērtēšanas un tā veikspēju raksturojošām metodēm un tehnoloģijām.

3) Veikta analīze par prognozējošo modeļu izveides procesa posmiem, uzdevumiem un rezultātiem.

4) Noteikti indivīda e-iekļaušanu prognozējošā modeļa izveides procesa posmi.

Tā kā zinātniskajā literatūrā pētījumi par indivīdu e-iekļaušanas prognozēšanu ir nelielā skaitā, šajā nodaļā ir apskatīti arī pētījumi, kur tiek analizēti dati un veiktas prognozes par studentu mācību sasniegumiem. Literatūrā ar mācību sasniegumiem parasti tiek saprasts, kādas noslēguma atzīmes students iegūs un vai students pabeigs vai nepabeigs (angļu val. - *dropout*) mācību kursu. Apskatītie pētījumi, galvenokārt, attiecas uz zināšanu un prasmju pilnveides kursiem pieaugušajiem, nevis vidējās vai augstākās izglītības ieguves procesu. Tomēr, lai iegūtu plašāku tvērumu par prognozējošo modeļu izveidi, autore literatūras apskatā ir ietvērusi arī modeļus, kurus izmanto augstākajā izglītībā. E-iekļaušanas prognozējošā modeļa darbība paredzēta kombinētās mācīšanās kursiem, tāpēc literatūras analīzē primāri prognozēšanas sistēmu tehnoloģijas un metodes ir apskatītas, koncentrējoties uz šāda veida mācību kursiem, kas apvieno klātienēs nodarbības ar patstāvīgu mācīšanos no internetā pieejamiem materiāliem. Plašāka priekšstata gūšanai autore izmanto arī pētījumus par studentu sasniegumus prognozējošiem modeļiem un tehnoloģijām *MOOC* platformās vai tiešsaistes kursus, par kuriem ir vairāk pieejama informācija (*Gitinabard* u. c., 2019).

Nodaļa sastāv no deviņām apakšnodaļām. Pirmajā apakšnodaļā ir atspoguļoti prognozēšanas, mācību analītikas un saistītie jēdzieni. Otrajā apakšnodaļā ir aprakstītas prognozējošo modeļu izveides metodes un tehnoloģijas. Trešajā apakšnodaļā raksturotas prognozējošu modeļu novērtēšanas metodes, veikspējas rādītāji un to uzlabošanas iespējas. Ceturtajā apakšnodaļā ir analizētas pazīmes, kas tiek izmantotas studentu sasniegumu prognozēšanā. Piektajā apakšnodaļā ir analizēti studentu sasniegumus prognozējošie modeļi, to izveidē izmantotie algoritmi, metodes un iegūtie modeļu veikspējas rādītāji. Sestajā apakšnodaļā ir raksturoti prognozēšanas sistēmas galvenie darbības procesi. Septītajā apakšnodaļā ir aprakstīts prognozējošu modeļu izveides process. Astotajā apakšnodaļā raksturots e-iekļaušanas prognozējošā tehnoloģiskā modeļa izveides process. Devītā apakšnodaļa satur kopsavilkumu un secinājumus par e-iekļaušanas prognozēšanas metodēm

un tehnoloģijām.

2.1. Prognozēšanas, mācību analītikas un saistīto jēdzienu skaidrojums

Promocijas darbā indivīda e-iekļaušanas process tiek apskatīts digitālo prasmju apguves un jēgpilnas lietošanas kontekstā. Lai noteiktu indivīda rīcību digitālo prasmju izmantošanā nākotnē, vadoties no indivīdu raksturojošiem datiem zināšanu radīšanas un pārneses procesā, e-iekļaušanas noteikšanas modelim ir nepieciešams izmantot prognozēšanas metodes un tehnoloģijas, kā arī mācību analītikas metodes.

Ar **prognozēšanu** tiek saprasta fakts, novērojumos vai pieņēmumos balstīta paredzēšana, nākotnes tēla veidošana ar noteiktu varbūtības pakāpi (Skujiņa, 2000). Prognozēšanas metodes var iedalīt kvalitatīvās un kvantitatīvās (Anderson u. c., 2012; Yabo un Yuelong, 1999):

- Kvalitatīvajā prognozēšanā tiek iegūts subjektīvs eksperta viedoklis. Kvalitatīvo prognozēšanu izmanto, ja nav pieejami objektam, par kuru jāveic prognozes, pagātnes dati. Parasti kvalitatīvo prognozēšanu izmanto ilgtermiņa lēmumu pieņemšanai. Kā piemērus kvalitatīvās prognozēšanas metodēm var minēt Delfi metodi (Rowe un Wright, 1999), žūrijas viedokļa metodi (angļu val. – *Jury of executive opinion*) (Klassen un Flores, 2001).
- Kvantitatīvās prognozēšanas metodes modelē nākotnes datus kā funkciju no pagātnes datiem. Pastāv divi nākotnes notikumu un apstākļu izzināšanas ceļi (Tilde, 2014): (1) mēģināt atklāt cēloņu-secu mehānismu; (2) mēģināt prognozēt nākotnes stāvokli, analizējot rādītāju laika rindu izolētā veidā. Kvantitatīvās metodes izmanto dažādas skaitliskas metodes sakarību noteikšanai un prognožu veikšanai.

Prognozējošā analītika (angļu val. – *predictive analytic*) ietver dažādas datizraces, prognozējošās modelēšanas, mašīnmācīšanās un statistikas metodes, lai balstoties uz pašreizējo un vēsturisko faktu analīzi, prognozētu nākotnes notikumus (Nyce un Cpcu, 2007).

Prognozējošā modelēšana (angļu val. – *predictive modeling*) ir modeļa izstrādes process, kas ģenerē iespējami akurātu (korektu) prognozi (Kuhn un Johnson, 2013).

Prognozēšana ir saistīta ar gandrīz katru zinātnes disciplīnu, un prognozēšana, izmantojot mācīšanās procesa datus, ir izglītības datizraces un mācību analītikas pētījumu aktuāla tēma (Rudin, 2012).

Pieaugot ar apmācības procesu saistīto datu pieejamībai, attīstās mācību analītikas nozare. Mācību analītika tiek uzskatīta par vienu no izglītības nozares aktuālākajām izpētes tēmām (Learnnovators, 2014). Mācību analītika (angļu val. – *learning analytics*) attiecas uz plaša datu klāsta interpretāciju, kur datus rada studenti mācību procesa laikā un dati tiek izmantoti, lai novērtētu akadēmisko sniegumu, prognozētu turpmākos rezultātus un sniegtu atbalstu studentiem (Niet u. c., 2016).

Mācību analītika ir ar izglītojamajiem saistītu datu mērījumi, kolekcijas, analīze un pārskati, lai izprastu un optimizētu mācīšanās procesu un vidi, kurā notiek apmācība (LAK, 2011). Mācību analītikas mērķi ir šādi: (1) nodrošināt izpratni par mācīšanās procesu; (2) optimizēt mācīšanās procesu; (3) nodrošināt izpratni par mācīšanās vidi; (4) optimizēt mācīšanās vidi. Mācību analītikā ir iesaistītas trīs galvenās lietotāju grupas: izglītojamie, pedagogi/instruktori, iestādes (Miteva un Stefanova, 2020; Ortiz-Rojas u. c., 2019; Tsai u. c. 2017). Katrai grupai ir savi specifiskie mērķi:

- Izglītojamais: mudināt izglītojamos uzņemt atbildību par savām studijām; sniegt uz datiem balstītu informāciju vai norādījumus studentiem.
- Pedagoģis/Instruktors: identificēt mācīšanās problēmas, uzlabot mācīšanas procesu.
- Iestāde: pārvaldīt resursus un uzlabot institucionālo sniegumu.

Mācību analītikas iespēju radīšanā un izmantošanā ir iesaistīti arī pētnieki un sistēmu projektētāji (*Chatti u. c., 2014*).

Mācību analītikas rīkus var iedalīt vairākos veidos:

1) aprakstošie; 2) prognozējošie 3) diagnosticējošie 4) recepšu – ieteikumu (*Lenar u. c., 2019*). Mācību analītikas rīku funkcijas ietver monitoringu, analīzi, prognozēšanu, apmācību / mentoringu, novērtēšanu, atgriezeniskās saites sniegšanu, personalizēšanu, ieteikumus, informēšanu (*Chatti u. c., 2014; Costa u. c., 2019*). Trīs galvenie jēdzieni, ko ietver mācību analītikas definīcija, un kuri norāda uz darbībām, ko ietver mācību analītika, ir dati, analīze un atbilstoša rīcība (*Siemens, 2013*).

Prognozējošā mācību analītika ir vēsturisko un pašreizējo datu, kas iegūti no izglītojamajiem un mācību procesa, analīze, lai izveidotu modeļus, kas ļauj prognozēt, kas uzlabo mācību procesu un vidi, kurā tas notiek (*ECAR-Analytics Working Group, 2015*). Izmantojot mācību analītiku, izglītības datizraces un mašīnmācīšanās tehnoloģijas, var veidot prognozējošus modeļus no studentu datiem, lai saprastu studentu mācīšanās riskus (*Herodotou u. c., 2019; Herrmannova un Hlosta, 2014*).

Mācību analītika integrē kognitīvās, sociālās, pedagoģiskās, tehnoloģiskās, organizatoriskās komponentes, lai iegūtu sistemātisku skatījumu par studentiem un to mācīšanās procesu.

Mācību analītika ir starpdisciplināra joma, kas, galvenokārt, kombinē trīs nozares: datorzinātņi, izglītību un statistiku (*Romero un Ventura, 2020*). Mācību analītikā prognozēšanas modeļu izveidē izmanto statistikas, datizraces un mašīnmācīšanās metodes un tehnoloģijas (*Lenar u. c., 2019*). Gan statistikas, gan datizraces, gan mašīnmācīšanās metodes un tehnoloģijas tiek izmantotas, lai risinātu izvērztu problēmu, meklējot atbildi ar esošo datu palīdzību un izdarot secinājumus no tiem.

Ar **datizraci** tiek saprasta datu bāzes datu analīze, kas paredzēta aplēptu sakarību meklēšanai kādā datu grupā, piemēram, atrast lietotājus ar kopīgām interesēm (Latvijas Nacionālais terminoloģijas portāls, 2021). Datizraces mērķis ir atklāt iepriekš nezināmas attiecības starp datiem, dodot noderīgu informāciju problēmas risināšanai. Datizrace kombinē datorzinātnes, mašīnmācīšanās, statistikas pieejas un metodes, lai atklātu datu bāzēs sakarības starp datiem. Datizracē tiek izmantota klasteranalīze, regresijas un klasificēšanas pieejas. **Izglītības datizracē** tiek izmantoti ar apmācības procesu saistīti dati.

Ar **statistiku** tiek saprasti apkopoti, aprēķināti, publicēti dati, kas atspoguļo kādas nozares attīstības faktus (Latvijas Nacionālais terminoloģijas portāls, 2021). Statistiku iedala: aprakstošā, kas rāda pagājušo periodu faktus, sasniegtos rezultātus, un prognozējošā statistikā, kas pēc iepriekšējās attīstības tendencēm paredz norises nākotnē. Statistikas ekspertu mērķis bieži ir novērtēt vai raksturot ģenerālkopu, izmantojot analīzes rezultātus, kas iegūti par izlases kopu.

Pieaugošais, ar apmācības procesu saistīto, datu apjoms un to pieejamība dod iespēju studentu datu analīzē izmantot jaunas pieejas, kas jau līdz šim ir tikušas pielietotas tādās nozarēs kā mākslīgais intelekts un ar to saistītajā mašīnmācīšanās (angļu val. – *machine learning*) (*Machine Learning and Learning Analytics Workshop, 2014*). **Mašīnmācīšanās**

paredz mēģinājumu mācīt datorus (sistēmas) prognozēt nākotni vai kaut kādā veidā nezināmus notikumus, pielietojot statistikas un datizraces tehnikas. Mašīnmācīšanās procesa mērķis ir nodrošināt datorprogrammai apmācību, balstoties uz pagātnes pieredzi (Cios u. c., 2002).

Ja datizraci izmanto, lai atklātu jaunas, iepriekš nezināmas sakarības, tad statistikas metodes izmanto, lai apstiprinātu iepriekš izvirzīto pieņēmumu par sakarībām un, balstoties uz izlases datu analīzi, novērtētu ģenerālkopas īpašības un/vai uzvedību, bet mašīnmācīšanās pieejas galvenais uzdevums ir mācīties no apmācību datu kopas radītos algoritmus un prognozēt nākotnes notikumus ar produkcijas datiem, izmantojot iemācītos algoritmus.

2.2. Prognozējošu modeļu izveides metodes un tehnoloģijas

Prognozējošu modeļu izveidē ir iespējams izmantot statistiskā, datizracē un mašīnmācīšanās tehnoloģijā balstītas metodes un algoritmus. Jāatzīmē, ka neviena mašīnmācīšanās metode vai algoritms nav viennozīmīgi labāks par kādu citu, bet mašīnmācīšanās laikā ir jānovērtē izveidotais modelis iepriekš izvirzītiem kritērijiem.

Mašīnmācīšanās tiek izmantotas vairākas stratēģijas (Dasgupta u. c., 2011; Schuh u. c., 2020): neuzraudzītā apmācīšana; uzraudzītās apmācīšana; daļēji uzraudzītā apmācīšana; stimulētā apmācīšana. Neuzraudzīto apmācīšanas stratēģiju lieto, lai saprastu datu kopas struktūru un raksturīgos datu modeļus (struktūras). Neuzraudzītās apmācības piemērs ir klasterizācijas uzdevumi, kad no ieejas datiem jāatrod potenciāli svarīgas grupas. Neuzraudzītai apmācīšanai pretstats ir uzraudzītā apmācīšana, kur notiek mēģinājums apmācīt, kādas attiecības pastāv starp ieejas datiem un gaidāmajiem rezultātiem. Ar uzraudzītās apmācības stratēģiju tiek risināti klasifikācijas un regresijas uzdevumi.

Klasterizācijas uzdevumi. Klasterizācijas (angļu val. – *clustering*) uzdevums ir grupēt objektu kopu tā, lai vienas grupas objekti (klasteris) būtu vairāk līdzīgi viens otram nekā tiem, kas ietilpst citās grupās (klasteros). Klasterizācija ir statistiskās analīzes metode, kas tiek plaši izmantota datizraces un mašīnmācīšanās nolūkiem.

Klasteranalīzes algoritmus var iedalīt vairākās kategorijās, vadoties no algoritmu ieejas datu tipiem, klasteranalīzes kritērija, ar kuru definē datu punktu līdzības, teorijām un pamatjēdzieniem, uz kā balstās klasteranalīzes metodes (piemēram, *fuzzy* teorija, statistika) (Halkidi u. c., 2001). Atkarībā no izvēlētās metodes klasteranalīzes algoritmus var iedalīt šādās grupās: nodalīšanas (angļu val. – *partitional*), hierarhiskā, uz blīvumu balstītā, uz režģiem balstītā. Katrai grupai ir piemēroti savi algoritmi.

Lai gan klasterēšanas primārais uzdevums ir grupēt objektu kopas klasteros, tomēr literatūrā ir pieejami pētījumi, kur klasteranalīzes lietojuma mērķis ir prognozēšana (Sorour u. c., 2014). Piemēram, klasteranalīzi veic datu kopai un rezultātā katrs iegūtais klasteris tiek raksturots ar noteiktām atribūtu vērtībām, veidojot katram klasterim atbilstošas datu struktūras. Prognozēšanas posmā nezināmai datu struktūrai tiek piemeklēts visatbilstošākais klasteris (Oyelade u. c., 2010).

Viens no algoritmiem, kas ir izmantots klasteranalīzē prognozēšanas mērķiem ir *kMeans* algoritms. *kMeans* algoritms ir nodalīšanas metodes klasteranalīzes algoritms. *kMeans* algoritmam iepriekš jānosaka klasteru skaits un jāminimizē attālums līdz klasteru centriem (Halkidi u. c., 2001).

kMeans algoritms ir izmantots prognožu veikšanai dažādos problēmapgabalos. Transporta

un satiksmes nozarē ir prognozēta ceļu noslodze (Nath, u. c., 2010). Medicīnā, balstoties uz pacientu datiem, ir prognozētas diagnozes (Deepa un Devi, 2011). *kMeans* algoritms lietots izglītības nozarē, lai prognozētu studentu mācību rezultātus (Oyelade u. c., 2010; Tamada u. c., 2019). Piemēram, lai paredzētu studentu atzīmes kursa noslēgumā - katrai no 5 noslēguma atzīmei ir izveidots savs dominējošais klasteris un tiek meklēts studenta pašnovērtējuma datiem tuvākais attālums līdz klasteru centriem, un tādējādi noteikts, kuram klasterim pieder students. Šim prognozēšanas modelim ir iegūts akurātumu no 59,3 % līdz 71,0 % (Sorour u. c., 2014).

Klasifikācijas uzdevumi. Mašīnmācīšanās klasifikācijas uzdevums ir, balstoties uz apmācības datu kopu, kurā katram objektam ir norādīta klase, kam tas pieder, iemācīties pēc atribūtiem noteikt klasi, kurai pieder agrāk neredzēts objekts. Klasifikācijas uzdevumiem atkarīgā atribūta vērtība ir kategoriju (nominālā) skalā. Klasifikācijas algoritmus var iedalīt pēc veida, kā tie prognozē: (1) prognozē klasi, kurai objekts pieder; (2) prognozē varbūtību, kas parāda, cik lielā mērā objekts pieder klasei.

Cits klasifikācijas algoritmu iedalījumu veids ir, kā tie veido klasifikācijas modeli un klasificē ar testa datiem (Galván u. c., 2011). Pirmais veids tiek saukts par slinko jeb atlikto mācīšanos, jo klasifikācijas modelis gaida, kad parādīsies dati, kas jāklasificē un tikai tad izmanto apmācības datu kopu, lai noteiktu, kā klasificēt konkrēto piemēru. Slinkās mācīšanās pieejā klasifikācijas modelim mazāk laiks ir nepieciešams apmācības posmam, bet salīdzinoši vairāk laiks tiek patērēts prognozēšanas posmam. Slinkās mācīšanās algoritmi ir neparametriska metode. Otrs mācīšanās veids ir enerģiskā (angļu val. – *eager*) mācīšanās. Šajā gadījumā vispirms, balstoties uz apmācības datiem, tiek izveidots klasifikācijas algoritms, ar kuru pēc tam tiek klasificēti iepriekš neredzēti dati. Enerģiskā mācīšanās ietekmē to, ka salīdzinoši vairāk laiks ir jātērē, lai izveidotu klasifikācijas modeli ar apmācības datiem, bet mazāk laika nepieciešams, lai prognozētu. Vairums klasifikatoru ir enerģiskās mācīšanās algoritmi, piemēram, algoritmi, kas balstīti likumos, funkcijās, kokos, kā arī Beijesa metodes algoritmi.

Slinkās mācīšanās klasifikatora piemērs ir tuvāko kaimiņu algoritms – *kNN* (angļu val. – *k-nearest neighbor*). Algoritma trūkums ir, ka lielām apmācības datu kopām ir grūtības dotajam objektam ātri sameklēt tuvākos kaimiņus. *kNN* ir robusts algoritms, to neietekmē “trokšņi” datos. Citi slinkās mācīšanās algoritmi ir balstīti *Locally Weighted Learning* pieejā.

Beijesa metodes algoritmi ir balstīti Beijesa teorēmā. Naivais Beijesa (angļu val. – *Naive Bayes*) algoritms izmanto Beijesa teorēmas jēdzienu, kas paredz neatkarību starp pazīmēm (prediktoriem). Naivais Beijesa algoritms pieņem, ka vienas pazīmes klātbūtne neietekmē nevienas citas pazīmes klātbūtni. Beijesa teorēmu izmanto varbūtību aprēķināšanai. Naivais Beijesa algoritms ir parametriska metode. Naivo Beijesa algoritmu izmanto gadījumos, kad nav lieli apmācības datu apjomi. Tiek uzskatīts, ka Naivais Beijesa algoritms ir salīdzinoši ātrs, tam nav nepieciešams liels datu apjoms modeļa apmācībā, bet kā trūkums tiek atzīts, ka varbūtību aprēķini ir neprecīzi.

Funkcijās balstītu algoritmu piemēri ir loģistiskās regresijas algoritmi un algoritmi, kas balstīti lineāro diskriminantu izmantošanā klasificēšanas nolūkiem. Loģistiskā regresijas algoritms spēj ne tikai paredzēt vienu vai otru kategoriju, bet arī noteikt, cik liela ir paredzējuma nenoteiktība. Loģistiskā regresija ir parametriska metode, kas modeli spēj apmācīt ar neliela apjoma datu kopu. Lineāro diskriminantu analīze ir Fišera lineārā diskriminanta metodes vispārinājums, lai atrastu lineāru pazīmju kombināciju, kas raksturo

vai atdala divas vai vairākas objektu vai notikumu klases. Tā ir parametriska metode, kas spēj izveidot modeli ar neliela apjoma apmācības datu kopu. Atbalsta vektoru mašīnas (angļu val. – *Support Vector Machine – SVM*) algoritms ir lineāro diskriminantu metodes paveids, kura mērķis ir atrast vislabāko taisni vai hiperplakni, kas atdala divas klases. Kā trūkums šim algoritmam tiek uzskatīts, ka nenodrošina rezultātu varbūtību novērtējumu.

Likumos balstīti algoritmi nosaka, kurai klasei objekts piederēs atkarībā no “ja...tad” likumiem. Likumi parasti mēdz būt viegli interpretējami. Piemēram, *OneR* algoritms ir vienkāršs klasifikators, kurš vispirms ģenerē vienu likumu katram prediktoram, tad izvēlas likumu ar vismazāko kopīgo kļūdu. Citi likumos balstītu algoritmu piemēri: *JRip* un *Ridor*.

Lēmumu koki ir algoritms, ar kuru no apmācības datu kopas tiek uzbūvēts klasifikācijas vai regresijas modelis, kas ir konkrēts lēmumu koks konkrētam uzdevumam. Lēmumu koki ir neparametriska metode. Lēmumu koku kā klasifikācijas metodes priekšrocības (Podnieks, 2020): (1) Lēmumu koki spēj atklāt klases identificējošo informāciju, tas ir, kādā veidā tiek nonākts pie secinājuma, ka dotais objekts pieder savai klasei. Lēmumu koki ir interpretējami. (2) Lēmumu koki spēj izmantot gan skaitliskus, gan nominālās skalas datus.

Lēmumu koku algoritmu piemēri: *C4.5*, *J4.8*, *Classification And Regression Trees (CART)*, *SimpleCart*, *ADTree*, *REPTree*.

Gadījumu meži (angļu val. – *Random Forest*) ir klasifikācijas, regresijas un citu uzdevumu kopīga mācīšanās metode, kas darbojas, apmācības laikā konstruējot lēmumu kokus. Metodē raksturo tas, ka lēmumu koki izmanto dažādas apmācību datu kopas, pie tam tām tiek mainīti atribūti (pazīmes). Klasifikācijas uzdevumiem gadījumu meža algoritma rezultāts ir klase, kuru izvēlas lielākā daļa koku. Tiek uzskatīts, ka gadījumu mežu algoritms dod akurātāku rezultātu, nekā lēmumu koku algoritms. Gadījumu mežu algoritmu ir grūtāk interpretēt nekā lēmumu koku algoritmu. Tiek uzskatīts, ka gadījumu mežu algoritmu trūkums ir prognozēšanas lēnums, bet priekšrocība ir prognozes akurātums.

Regresijas uzdevumi. Mašīnmācīšanās regresijas uzdevums ir iemācīt modelim, kā prognozēt nākotnes notikumus ar skaitlisku vērtību (nevis nominālā skalā), izmantojot iepriekš zināmas piemēru vērtības un kā tās ietekmē atkarīgā atribūta vērtību. Loģistikā regresija kā regresijas veids apskatīta pie klasifikācijas uzdevumiem.

Lineārā regresija ir visplašāk izmantotā uzraudzītā prognozējošā modelēšana mašīnmācīšanās pieejā balstītām sistēmām (*Caraciolo*, 2011). Lineārās regresijas pamatprincips ir apkopot katras neatkarīgās pazīmes ietekmi, lai noteiktu paredzamo vērtību.

Tā kā lineārā regresija ir ierobežota, lai atbilstu lineārai (taisnei) funkcijai, tā nav tik adekvāta reālās pasaules datiem, kā citas tehnoloģijas, piemēram, kā neironu tīkli, ar kuriem var modelēt nelineārās funkcijas. Bet lineārai regresijai ir vairākas priekšrocības (*Caraciolo*, 2011): (1) Lineārā regresija ir labi saprotama metode. Pārbaudot regresijas koeficienta lielumu un zīmi, var secināt kā prediktora mainīgais ietekmē mērķa mainīgo, lineārās regresijas modelis ir interpretējams. Tas ir viens no vienkāršākajiem algoritmiem un pieejams daudzos rīkos; (2) Lineārās regresijas modeļa apmācība parasti ir ātrāka nekā tādām metodēm kā neironu tīkli; (3) Lineārās regresijas modeļi ir vienkārši un tiem vajadzīgs minimāls atmiņas daudzums, lai tos implementētu.

Mašīnmācīšanās, izmantojot lineārās regresijas modelēšanu, ir plaši lietota dažādās nozarēs, piemēram, fizikā (*Leonardi*, u. c., 2010) sprieguma stabilitātes novērtējumam. Lineāro regresiju izmanto izglītības nozarē (*Stimpson* un *Cummings*, 2014).

Secinājums par prognozējošu modeļu izveides metodēm e-iekļautības modeļa

izveidei. Prognozējošu modeļu izveidē ir iespējams izmantot klasifikācijas, regresijas un klasteranalīzes metodes. Metodes izvēli ietekmē izmantojamo apmācību datu veids un prognozējamā mainīgā veids (piemēram, skaitliska vai nomināla skala). Prognozēšanas modeļu izveidē izmantojamus algoritmus atšķir, kādas ir iespējas interpretēt izveidoto rezultātu, kā arī, vai izmantotā metode ir parametriska vai neparametriska.

2.3. Prognozējošu modeļu novērtēšanas metodes un veikspējas rādītāji

Prognozēšanas algoritma - modeļa, kas izveidots kādam speciālam uzdevumam, kvalitātes mērs ir tā robustums. Prognozēšanas algoritmam ir jāspēj ignorēt “troksni” apmācības datos un jāspēj nodrošināt, ka prognoze ar iepriekš apmācībā neizmantotiem datiem ir tikpat kvalitatīva, kā ar apmācībā izmantotajiem datiem.

Pastāv vairākas metodes, kuras var izmantot modeļa (algoritma) novērtēšanai. Galvenās no tām ir jaunu datu kolekcionēšana, lai pārbaudītu prognožu precizitāti, vai esošo datu sadalīšana vairākās kopās, lai iegūtu neatkarīgus modeļa precizitātes mērījumus (*Snee*, 1977). Situācijās, kad jaunu datu iegūšana modeļa novērtēšanai nav iespējama vai ir laikietilpīga, ir jāizmanto esošo datu kopa. Modeļi nedrīkst novērtēt ar apmācībā izmantotiem datiem, jo šādi var tikt sniegts pārlieku optimistisks novērtējums par datu atbilstību izveidotajam modelim, var parādīties modeļa pārlieku pielāgotības (angļu val. – *overfitting*) problēma (*Podnieks*, 2020). Ar novērtēšanas metodi tiek noskaidrots, vai nav modeļa pārlieku pielāgotības problēma. Esošo datu sadalīšanu vairākās apakškopās modeļa precizitātes novērtējumam var veikt vairākos veidos. Divas metodes, kas visbiežāk tiek izmantotas, lai novērtētu izveidoto modeļi, ir novilcināšanas (angļu val. – *holdout*) metode un šķērsvalidācijas (angļu val. – *cross-validation*) metode (*Arlot* un *Celisse*, 2010).

Šķērsvalidācijas metode. Situācijās, kad ir pieejams ierobežots datu apjoms, lai objektīvi novērtētu modeļi, tiek izmantota kāda no šķērsvalidācijas metodēm (*Yadav* un *Shukla*, 2016). Viena no šķērsvalidācijas metodēm ir k-kārtu (angļu val. – *k-fold*) metode. K-kārtu metode sadala datus k vienāda izmēra apakškopās. Viena no k apakškopām tiek izmantota kā validācijas dati, pārējās $k-1$ apakškopas veido apmācības datu kopu. Tad tiek k reizes veidoti modeļi, katru reizi vienu no k apakškopām izmantojot par validācijas datu kopu. Rezultātā ir viens modeļa novērtējums, kas ir iegūts no k novērtējumiem. Par teorētiski labāko tiek atzīta desmitkārtīgā šķērsvalidācijas metode (*Podnieks*, 2020).

Novilcināšanas metode. Novilcināšanas metode ir k-kārtu metodes vienkāršākais paveids (*Oxford* un *Daniel*, 2001). Šī metode parasti izmanto liela apjoma datu kopu, kas pēc nejaušības principa tiek sadalīta apakškopās:

1) Apmācības datu kopa, kuru izmanto, lai izveidotu prognozējošo modeļi.

2) Validācijas kopa, kuru izmanto, lai novērtētu modeļa darbību apmācības posmā, lai precizētu modeļa parametrus.

Šķērsvalidācijas metode ir izmantota studentu sasniegumu klasifikatoru modeļu novērtēšanā (*Buraimoh* u. c., 2021; *Ilic* u. c., 2016, *Pereira* u. c. 2019).

Secinājumi par modeļu novērtēšanas pieeju e-iekļaušanas prognozēšanas modeļa izveidē

Ņemot vērā, ka e-iekļaušanas prognozējošā modeļa izveidē ir pieejams ierobežots datu apjoms, tad ieteicams ir izmantot šķērsvalidācijas metodes.

Prognozējošu modeļu veikspējas rādītāji no datizraces vai mašīnmācīšanās aspekta

Modeļu novērtēšanas laikā mērķis ir pārliecināties par prognozējošā modeļa kvalitāti, raksturojot to ar modeļa veikspējas rādītājiem. Turpinājumā detalizētāk aprakstīti biežāk izmantotie prognozējošo modeļu veikspējas rādītāji.

Klasifikācijas algoritma (modeļa) veikspējas rādītāji

Lai noteiktu, klasifikācijas modeļa veikspēju un pieņemtu lēmumu par modeļa izmantošanu turpmāk, ir nepieciešams modeli novērtēt. Zinātniskajā literatūrā nav vienprātības par to, kuru veikspējas rādītāju labāk izmantot tā novērtēšanai (*Seliya* u. c., 2009). Atbilstīgāko veikspējas rādītāju atlase jāveic atkarībā no risināmās problēmas un pieejamās datu kopas īpašībām (*Novaković* u. c., 2017).

Ja klasifikācijas algoritms konkrētu datu kopas piemēru, salīdzinot ar reālo novērojumu, klasificē atšķirīgi, tad tā ir uzskatāma par klasifikācijas kļūdu. Ja risināmai problēmai ir vienlīdz svarīgas visas kļūdas, tad kopējais kļūdu skaits raksturo klasifikācijas modeļa veikto darbu. Šajā gadījumā modeļa akurātums (angļu val. – *accuracy*) ir modeļa kvalitātes rādītājs. Ar modeļa akurātumu tiek saprasta attiecība starp pareizi klasificētiem un visiem datu kopas piemēriem. Akurātumam kā modeļa veikspējas rādītājam ir vairāki trūkumi. Pirmkārt, modeļa akurātums neparāda atšķirības starp kļūdu veidiem (kurai no klasēm atbilst kļūda). Otrkārt, akurātums ir atkarīgs no klašu sadalījuma datu kopā. Piemēram, ja negatīvās klases gadījumu skaits ir vairākkārt lielāks par pozitīvās klases gadījumu skaitu, tad ir iespējams iegūt augstu vērtību akurātumam, ja piemēri tiek klasificēti kā piederoši lielākajai klasei. Bet šāda akurātuma vērtība neatspoguļo patiesi klasifikatora veikspēju.

Bieži, risinot problēmu, ir būtiski kāda veida kļūdu klasifikācijas modelis ir pieļāvis. Kā piemērs ir medicīnas joma, kur klasifikācijas modelis nosaka, vai pacientam ir kādas slimības risks. Ja klasifikācijas modelis pieļauj kļūdu, uzrādot, ka pacientam nav slimības riska, bet patiesībā pacients ir riska grupā, tad šāda veida kļūda ir svarīgāka par modeļa kļūdu, kad tas neatpazītu pacientu, kuram nav slimības riska. Kļūdaini neatpazīstot riska pacientu, nevar tam preventīvi novērst saslimšanas risku. Tā kā promocijas darbā jāprognozē indivīdi ar e-iekļaušanas risku, tad autore uzskata, ka ir būtiski atšķirt kļūdu veidus. Autore pieņem, ka svarīgāk ir samazināt tās kļūdas, kas attiecas uz indivīdiem, kuri ir digitāli izslēgti, bet klasifikācijas algoritms prognozē, ka indivīdi ir digitāli iekļauti.

Gadījumos, kad ir svarīgi atšķirt kļūdu veidus vai arī klasēs piemēru skaits nav līdzīgs, klasifikācijas modeļu veikspējas novērtēšanai tiek lietota pārpratuma matricas metodika (skat. 2.1. tab.).

2.1. tabula

Pārpratumu matrica binārā klasifikatorā

	Prognoze pozitīvā klase	Prognoze negatīvā klase
Reālā pozitīvā klase	pareiza atbilsme (<i>tp</i>)	viltus negatīvs – 2. veida kļūda (<i>fn</i>)
Reālā negatīvā klase	viltus pozitīvs – 1. veida kļūda (<i>fp</i>)	pareiza neatbilsme (<i>tn</i>)

Pārpratumu matricu veido 4 dažādas paredzēto un reālo vērtību kombinācijas: pareiza atbilsme (angļu val. – *true positive, tp*); pareiza neatbilsme (angļu val. – *true negative, tn*);

viltus pozitīvs (angļu val. – *false positive, fp*); viltus negatīvs (angļu val. – *false negative, fn*). Gadījumos, kad ir pareiza atbilde un pareiza neatbilde, klasifikācijas algoritms ir korekti paredzējis, kurai klasei piemērs atbilst. Gadījumos, kad ir viltus pozitīvs, klasifikācijas algoritmam ir 1. veida kļūda, bet kad ir vai viltus negatīvs, tad ir 2. veida kļūda.

Binārā klasifikācijas modelī tā veiktspēju novērtē, izmantojot precizitātes (angļu val. – *precision*) (2.1.), pārklājuma (angļu val. – *sensitivity, recall*) (2.2.), akurātuma (angļu val. – *accuracy*) (2.3.), līdzsvarota akurātuma (angļu val. – *balanced accuracy*) (2.4.), F1 mēra (2.5.) un F2 mēra (2.6.) rādītājus, kur:

$$\text{precizitāte} = \frac{tp}{tp+fp} \quad (2.1.)$$

$$\text{pārklājums} = \frac{tp}{tp+fn} \quad (2.2.)$$

$$\text{akurātums} = \frac{tp+tn}{tp+tn+fp+fn} \quad (2.3.)$$

$$\text{līdzsvarotais akurātums} = \left(\frac{tp}{tp+fn} + \frac{tn}{tn+fp} \right) / 2 \quad (2.4.)$$

$$F1 \text{ mērs} = \frac{2 \times \text{precizitāte} \times \text{pārklājums}}{\text{precizitāte} + \text{pārklājums}} \quad (2.5.)$$

$$F2 \text{ mērs} = \frac{4 \times \text{precizitāte} \times \text{pārklājums}}{5 \times \text{precizitāte} + \text{pārklājums}} \quad (2.6.)$$

Precizitāte norāda, cik procentu no tiem, kas prognozēti kā pozitīvā klase, ir pareizi prognozēti. Pārklājums rāda, cik daudz no pozitīvās klases gadījumiem ir atklāti. Akurātums tiek definēts kā abu klašu pareizi klasificētu gadījumu attiecība pret kopējo gadījumu skaitu. Līdzsvarotais akurātums ir īpaši noderīgs, ja katrā no klasēm ir atšķirīgs gadījumu skaits (Brodersen u. c., 2010) Līdzsvarots akurātums tiek definēts kā katras klases pareizi klasificēto gadījumu vidējā attiecība.

Papildināmība ir viena no svarīgākajām klasifikācijas modeļu novērtēšanas īpašībām (Novaković u. c., 2017). Izmantojot pāru mērus, var parādīt klasifikācijas modeļu korektumu no dažādām pozīcijām. F1 mērs ir harmoniskais vidējais starp precizitāti un pārklājumu. F2 mērs apvieno precizitāti un pārklājumu, dubulti uzsverot pārklājuma nozīmīgumu. Kā klasifikatoru veiktspējas rādītāji var tikt izmantots arī laukums zem *ROC-AUC* līknes (Cobos un Olmos, 2018).

Secinājumi par klasifikācijas modeļu veiktspējas rādītājiem e-iekļaušanu prognozējošā modeļa izveidē. Tā kā promocijas darba pētījuma kontekstā mērķis ir identificēt studentus, kuriem draud digitālā izslēgšana (nav e-iekļauts), tāpēc promocijas darbā tiek uzskatīts, ka pozitīvā klase ir *nav e-iekļauts*, bet savukārt *e-iekļauts* klase ir negatīvā klase. Pareiza atbilde (*tp*) ir “nav e-iekļauts” gadījumu daudzums, kas tiek prognozēts pareizi (kā “nav e-iekļauts”). Pareiza atbilde (*fp*) ir „nav e-iekļauts” gadījumu daudzums, kas tiek prognozēts pareizi (kā „nav e-iekļauts”). Pareiza neatbilde (*tn*) ir negatīvās „e-iekļauts” klases gadījumu daudzums, kas tiek prognozēts pareizi (kā „e-iekļauts”). Viltus pozitīvs (*fp*) ir „e-iekļauts” klases gadījumu daudzums, kas tiek prognozēti kā „nav e-iekļauts”. Viltus negatīvs (*fn*) ir „nav e-iekļauts” klases gadījumu daudzums, kas tiek prognozēts nepareizi (kā „e-iekļauts”).

Autore uzskata, ka svarīgs e-iekļaušanas prognozēšanas modeļa veikspējas rādītājs ir pārklājums. Pārklājums parāda pareizi klasificēto pozitīvās klases (“nav e-iekļauts”) gadījumu īpatsvaru. Jo lielāks pārklājums, jo vairāk riska studentu ir atpazīti. Augsta pārklājuma iegūšana kā svarīgs prognozēšanas modeļa mērķis ir norādīts zinātniskajā literatūrā par studentu sasniegumus prognozējošo modeļu izveidi (*Hung u. c., 2019*). Tomēr otrs svarīgs rādītājs modelim ir precizitāte, kas nosaka, cik no prognozētajiem pozitīvās klases (“nav e-iekļauts”) gadījumiem ir pareizi noteikti. Jo augstāka precizitāte modelim, jo mazāks ir to studentu skaits, kas nav riska studenti, bet tomēr nepareizi tiek prognozēti kā riska studenti. Tāpēc kā primārais modeļa veikspējas rādītājs promocijas darbā tiek izmantots F mērs. Individīda e-iekļautības prognozēšanas modelim ir nozīme, ja tā prognoze aptver pēc iespējas vairāk riska grupas studentu. Tāpēc promocijas darba pētījumā ir izmantots ne tikai F1 mērs, bet arī F2 mērs, lai uzsvērtu pārklājuma nozīmīgumu.

Regresiju modeļu veikspējas rādītāji

Izplatītākās metrikas regresijas problēmu novērtēšanai ir vidējā kvadrātiskā kļūda (angļu val. – *Root Mean Squared Error* vai *RMSE*), vidējā absolūtā kļūda (angļu val. – *Mean Absolute Error* vai *MAE*), determinācijas koeficients, koriģētais determinācijas koeficients. Vidējā absolūtā kļūda ir absolūto atšķirību summa starp prognozēm un faktiskajām vērtībām. Vidējā kvadrātiskā kļūda mēra vidējo kļūdas lielumu, no kvadrātsaknes vidējo kvadrātu starpībai starp prognozēšanu un faktisko novērojumu. Determinācijas koeficients raksturo, kādu daļu no kopējām atkarīgā mainīgā variācijām izskaidro novērtētais regresijas vienādojums. Koriģētais determinācijas koeficients dod iespēju salīdzināt modeļus ar dažādu neatkarīgo mainīgo skaitu. Determinācijas un koriģētā determinācijas koeficienta vērtība ir robežās no 0 līdz 1.

Secinājumi par regresiju modeļu veikspējas rādītājiem e-iekļaušanu prognozējošā modeļa izveidē. Veidojot lineārās regresijas modeļus, lai raksturotu, kādu daļu no kopējām e-iekļaušanas pakāpes variācijām izskaidro izveidotais regresijas vienādojums, ieteicams izmantot determinācijas koeficientu, kā arī ieteicams izmantot vidējo kvadrātisko kļūdu un vidējo absolūto kļūdu.

Klasteranalīzes modeļu veikspējas rādītāji

Promocijas darbā klasteranalīze tiks izmantota prognozēšanai, tāpēc iepriekš būs zināmas datu kopai atkarīgā mainīgā vērtības, tādējādi būs iespējams izmantot klasifikācijas uzdevumiem paredzētos veikspējas rādītājus.

Prognozējošo modeļu veikspējas uzlabošanas paņēmieni

Modeļu veikspējas rādītājus ir iespējams uzlabot, eksperimentējot ar apmācības datiem, prognozēšanas modeļus ģenerējošiem algoritmiem un to kombinācijām.

Prognozējošo modeļu kombinēšana, lai uzlabotu studentu sasniegumu paredzēšanas modeļa veikspējas rādītājus. Lai uzlabotu modeļa veikspējas rādītājus (akurātumu, precizitāti, pārklājumu u.c.), viena no iespējām ir fināla prognozi balstīt uz vairāku modeļu prognozēm, nosakot shēmu, kā kombinēt katra prognozējošā modeļa individuālo prognozi (*Hung u. c., 2019; Tamada u. c., 2019*). Piemēram, fināla prognozē identificēt studentu kā riska studentu, ja kaut viens no modeļiem ir tā prognozējis. Ar šādu shēmu tika prognozēti 75–85 % korekti riska studenti kursa sākumā un pat 97–100 % korekti kursa noslēguma daļās (*Lykourantzou u. c., 2009*).

Cita pieeja kā uzlabot studentu mācību sasniegumu prognozējošo modeļu veikspēju, ir

veidot klasifikatoru ansambļus (*Atallah un Al-Mousa, 2019; Kotsiantis u. c., 2010; Kumari u. c., 2018*). Klasifikatoru ansambļa metodē vairāki klasifikatori tiek apvienoti, lai veiktu galīgo prognozi. Ansambli var veidot vai nu homogēni, vai heterogēni klasifikatori. Homogēnie klasifikatori, rodas no viena un tā paša klasifikācijas algoritma dažādām izpildēm. Šādus klasifikācijas modeļus var izveidot, piemēram, manipulējot ar apmācības datu kopu vai ievades atribūtiem. Var izdalīt divas homogēnu klasifikatoru veidošanas metodes: (1) modeļi mācās paralēli, neatkarīgi viens no otra (angļu val. – *bagging*) vai (2) modeļi mācās secīgi, balstoties uz iepriekš izveidotā modeļa rezultātu (angļu val. – *boosting*). Piemēri ansambļa klasifikatoru algoritmiem, kur modeļi mācās paralēli, ir gadījumu koki. Kā trūkumi šai metodei tiek uzskatīts, ka ir grūti interpretēt rezultātu un nav zināms, kādi atribūti ir izmantoti prognozēšanai. Metodes priekšrocība ir, ka tajā var izmantot neliela apjoma apmācības datu kopas. Piemēri ansambļa klasifikatoru algoritmiem, kas balstīti secīgā apmācībā ir: *AdaBoost*, *Gradient Boosting Machine (GBM)*, *Extreme Gradient Boosting Machine (XGBM)*, *LightGBM*. Otra iespēja ir izmantot klasifikācijas modeļus, kur katrs modelis ir ģenerēts ar citu algoritmu, piemēram, lēmumu koku, *kNN* vai citu algoritmu, un visiem algoritmiem tiek izmantota viena un tā pati apmācības datu kopa. Šajā gadījumā par priekšrocību tiek uzskatīts, ka ne visi modeļi dos nepareizu prognozi, ja izmanto dažādus algoritmus klasifikācijas modeļu izveidē.

Ansambļa klasifikatora metodē katrs no ansambļa klasifikatoru modeļiem izveidos savu prognozi, un tā var būt modeļiem atšķirīga. Klasifikatoru ansambļī galīgo lēmumu parasti pieņem, balsojot pēc tam, kad ir apvienotas prognozes no vairākiem klasifikatoriem (*Quo un Boukir, 2017*). Viena no metodēm klasifikatoru ansambļa apvienošanai ir vairākuma balsošana (angļu val. – *majority voiting*), kur klase, kurai ir visvairāk balsu, ir tā, kuru kā prognozi izvēlas ansamblis.

Ansambļu klasifikatori ir izmantoti riska studentu prognozējošo modeļu izveidē, piemēram par bāzes klasifikatoriem izvēloties gadījumu koku, *kNN* un loģistiskās regresijas algoritmus. (*Mulyani u. c., 2019*).

Secinājumi par klasifikatoru ansambļu izmantošanu e-iekļaušanas prognozējošā modelim. Veidojot e-iekļaušanas prognozējošo modeli, kā vienu no modeļa veiktspējas uzlabošanas paņēmieniem ir iespējams izmantot kādu no klasifikatoru ansambli veidošanas metodēm.

Nelīdzsvarotu klašu problēmas novēršana klasifikācijā. Modeļa veiktspējas rādītāji un datu izvēles uzdevums ir saistīts ar modeļa izveidē izmantojamo datu kopas klašu līdzsvarošānu, ja piemēru skaits klasēs ir atšķirīgs. Tiek uzskatīts, ka datu kopas klases ir nelīdzsvarotas, ja kādā no klasēm ir daudz vairāk klašu gadījumu (piemēru) nekā citā klasē (*Ling un Sheng, 2011*). Attiecība starp mazākajām un lielākajām klasēm var būt 1 : 100, 1 : 1000 vai pat 1 : 10 000 atkarībā no lietojumiem. Šāds klašu sadalījums, kur vienā klasē izteikti lielāks gadījumu skaits, ir novērojams daudzās reālās dzīves situācijās, piemēram, slimību diagnozēs (*Agrawal u. c., 2017*), studentu mācību procesā (*Pereira u. c., 2019*). Promocijas darba kontekstā pastāv iespēja, ka klasēs “e-iekļauts” un “nav e-iekļauts” ir salīdzinoši atšķirīgs gadījumu skaits, kas norāda uz to, ka klases nav līdzsvarotas.

Nelīdzsvarotas klases apgrūtina klasificēšanu, jo klasifikācijas modeļi ir apmācīti rādīt augstāku prognozes precizitāti lielākajās klasēs, mazākas klases uzskatot par troksni, un tāpēc tās tiek ignorētas apmācīšanas procesa laikā. Tomēr tieši klases ar mazāko piemēru skaitu bieži ir pētījuma objekti, tāpēc nelīdzsvarotu klašu klasifikācija tiek uzskatīta par vienu

klasifikācijas problēmām. Mašīnmācīšanās tehnoloģija nav veiksmīgi lietojama, ja klases nav līdzsvarotas un viltus negatīvie gadījumi ir svarīgāki par viltus pozitīviem gadījumiem (Novaković u. c., 2017).

Promocijas darba kontekstā ir svarīgi samazināt viltus negatīvo gadījumu skaitu, tas ir, nav e-iekļauts klases gadījumu daudzumu, kas tiek prognozēti nepareizi kā “e-iekļauts” klases gadījumi.

Literatūrā ir aprakstītas vairākas metodes, kā risināt nelīdzsvarotu klašu problēmu. Metodes ir iedalītas divās grupās (Ganganwar, 2012; Haixiang u. c., 2017): (1) algoritmu līmenis, kur mērķis ir uzlabot klasificēšanas algoritmus; (2) datu līmenis, kur mērķis ir līdzsvarot datu apjomu klasēs.

Biežāk izmantotās metodes ietver datu līmeņa metodes. Līdzsvarošanas mērķis datu līmenī ir, vai nu palielināt piemēru skaitu mazākajā klasē, vai samazināt piemēru skaitu lielākajā klasē, lai abās klasēs būtu aptuveni vienāds piemēru skaits. Promocijas darba pētījumos tiek izmantotas salīdzinoši neliela apjoma datu kopas, tāpēc autore apskata metodes, kā palielināt piemēru skaitu mazākajā klasē. Piemēru skaitu mazākajā klasē var palielināt, pavairojot mazākās klases piemērus pēc nejaušības principa, bet trūkums šai metodei ir piemēru pārklāšanās, kas rodas, kad precīzi kopē mazākās klases piemērus. Lai izvairītos no piemēru pārklāšanās, tiek piedāvāta *SMOTE* (*Synthetic Minority Over-Sampling Technique*) metode (Chawla u. c., 2002; Han u. c., 2005). *SMOTE* metode no mazākās klases piemēriem sintezē jaunus piemērus. Tiek uzskatīts, ka *SMOTE* metode nav piemērota datu kopām ar lielu klašu skaitu.

SMOTE metode ir izmantota riska studentu prognozējošo modeļu izveidē (Buraimoh u. c., 2021; Meedeck u. c., 2019; Mulyani u. c., 2019).

Secinājumi par klašu līdzsvarošanu e-iekļaušanas prognozējošā modelim. Ja e-iekļaušanu prognozējošā modeļa izveidei izmantotās datu kopas klases ir nelīdzsvarotas, tad ieteicams veikt klašu līdzsvarošanu ar *SMOTE* metodi.

2.4. Studentu sasniegumu prognozēšanā izmantoto pazīmju raksturojums

Prognozēšanas modeļa izveidē nozīmīga loma ir ne tikai izmantotām prognozēšanas metodēm, bet arī pazīmēm (atribūtiem), kas tiek izmantotas modeļa izveidei un uz kurām balstoties tiek izdarītas prognozes. Iepazīstoties ar literatūrā pieejamajiem pētījumiem par mācību analītiķu un studentu sasniegumu prognozēšanu, jāsecina, ka analītikā izmantotās pazīmes ir daudzveidīgas, tās var iedalīt pēc to vērtību maiņas attiecībā uz pētāmā notikuma norises gaitu (Romero un Ventura, 2020):

1) laikā nemainīgas (maz mainīgas) pazīmes – demogrāfiskie un sociālekonomiskie dati (piemēram, dzimums, vecums, dzīves vietas reģions, ekonomiskais stāvoklis), administratīvie dati (informācija par izglītības iestādi un pedagogiem, instruktoriem) (Moncada, 2018; Niet u. c., 2016). Individu demogrāfiskie, sociālekonomiskie un dzīvesvietas reģiona dati var norādīt uz risku, ka indivīds ir digitāli atstumts (Hilbert, 2011; Hsieh, u. c., 2008; Kyung Hoon, u. c., 2010; Lin, u. c., 2012; Matzat un Sadowski, 2012; Oyedemi, 2012; Vicente un Lopez, 2010). Literatūrā ir norādīts, ka, lai arī demogrāfiskā informācija, akadēmiskie sasniegumi (piemēram, atzīmes) ir svarīgi, tomēr ir nepieciešams meklēt jaunus, dinamiskus studentu uzvedību raksturojošus datu veidus (Arnold, 2010);

2) laikā mainīgas pazīmes – studenta aktivitāte un mijiedarbība ar mācībspēku un mācību

vidi (navigācijas dati, testu, uzdevumu un vingrinājumu dati, forumu ziņojumi utt.), studentu psiholoģiskie un kognitīvo spēju rādītāji (piemēram, motivācija, emocionālie stāvokļi), studentu pašvērtējumi par mācību vidi un procesu saistītām aktivitātēm (*Cobos un Olmos, 2018; Maennel, 2020*). Piemēram, pētījumi rāda, ka prognozēšanas nolūkiem izmanto brīva stila komentārus, kurus studenti raksta pēc nodarbības, no šiem komentāriem kā atribūtus/pazīmes atrod studentu attieksmi, mācību priekšmeta izpratnes rādītājus (*Sorour u. c., 2014*). Riska studenti tiek prognozēti, balstoties uz to, cik reizes students pieslēdzies sistēmai, kāda ir studenta veikspēja, salīdzinot ar grupas veikumu, studenta veikspēja konkrētām aktivitātēm, vidējais vērtējums aktivitātēm (*Herrera u. c., 2019*). Bieži pazīmju izveidei tiek izmantoti dati par studentu veiktajām darbībām (angļu val. – *click stream*) mācību vidē (*Tamada u. c., 2019*). Literatūrā ir pieejami pētījumi par riska studentu noteikšanu augstākās izglītības apgūves laikā, kā atribūtus izmantojot, piemēram, iepriekšējā semestra atzīmes (*Niet u. c., 2016*). Prognozējošu modeļu izveidē, lai novērstu izniekoto mācīšanos (prasmes tiek apgūtas, bet netiek izmantotas profesionālām vajadzībām), kā galvenie faktori, kas ietekmē mācīšanās rezultātu tiek norādīti studenta attieksme un ieinteresētība apgūt jaunas prasmes, pārliecība par savām spējām izmantot iemācīto, atbalsta apjoms no darba vietas un kolēģiem, kā arī iespēja tūlīt darba vietā pielietot jaunapgūtās prasmes (*Phillips Associates, 2018*);

3) kombinācijas no laikā mainīgām un nemainīgām pazīmēm. Piemēram, studentu vecums, dzimums tiek izmantots kā nemainīgas pazīmes un studentu aktivitāte mācību laikā, pārbaudes darbu atzīmes, dažādi starpvērtējumi kā mainīgas pazīmes (*Mahboob u. c., 2016; Tamada u. c., 2019*).

Otrs būtisks aspekts prognozējošo modeļu izveidē ir veids, pēc kādiem kritērijiem izvēlēties prognozēšanai izmantojamās pazīmes. Pastāv vairākas pazīmju izveiles pieejas, kas tiek izmantotas prognozēšanas modeļiem:

1) pazīmju izvēle ir balstīta teorijā, kas pamato prognozes prediktoru un rezultatīvo datu saistību. Lai no mācību analītikas būtu ieguvums pedagoģiskajā procesā, izvēloties analizējamus datus, būtiski ir izprast, kā indivīdi mācās (*Ferguson u. c., 2016*). Piemēram, balstoties uz Djuī teoriju par indivīda iepriekšējās pieredzes lomu jaunu zināšanu apgūvē, kā pazīme, kas tiek izmantota indivīda digitālo prasmju līmeņa un IKT lietošanas prognozēšanā, ir izmantota indivīda iepriekšējā pieredze tehnoloģiju lietošanā (*Verhoeven u. c., 2020*). Līdzšinējie pētījumi viennozīmīgi nenorāda piemērotāko teorētisko ietvaru mācību analītikas pētījumiem (*Nistor, 2015*);

2) ar modelēšanas rīku palīdzību tehniski nosaka piemērotākās pazīmes. Pieejamie pētījumi par studentu sasniegumus prognozējošo modeļu izveidi parāda, ka datu izvēle reti tiek balstīta mācīšanās teorijās. Dati tiek izvēlēti, piemēram, izmantojot mašīnmācīšanās rīku iespējas, kas ļauj noteikt atribūtus, ar kuriem modelis uzrāda augstākos veikspējas rādītājus (*Márquez-Vera u. c., 2013*). Šādos gadījumos trūkums ir tas, ka par atribūtiem var tikt noteikti dati, kas tiek identificēti kā riska faktori, bet ko nav iespējams novērst.

Zinātniskajā literatūrā pieejamie apraksti rāda, ka, veidojot indivīdu sasniegumu prognozēšanas modeļus, lielākoties mērķi aprobežojas ar to, ka tiek prognozēts, vai students pabeigs kursu, vai studentam būs sekmīgas pārbaudes un mācību noslēguma darbu atzīmes, taču netiek noteikti riska faktori, ko iespējams ietekmēt, lai uzlabotu studentu sasniegumus (*Akhtar u. c., 2017; Cobos un Olmos, 2018; Dewan u. c., 2015; Mahboob, 2016; Mustafa, u. c., 2012; Oyelade, u. c., 2010; Ribeiro De Carvalho Martinho, u. c., 2013; Sorour u. c.,*

2014).

Secinājumi par pazīmju izvēli e-iekļaušanas prognozējošam modelim. Nepastāv vienots pazīmju komplekts, ko varētu pārņemt un izmantot e-iekļaušanu prognozējošā modelī. Daļā no pētījumos aprakstītajos analītikas rīkos netiek izmantoti faktori, kurus var mainīt, lai uzlabotu studenta mācību rezultātu, bet ir faktu konstatējums par studentu dzimumu, dzīves vietu, iepriekšējām izglītības iestādēm, mācību sasniegumiem. Jāsecina, ka šie faktori nav saistīti ar studenta mācīšanās procesu – zināšanu plūsmu. Tā kā promocijas darbā mērķis ir ne tikai noteikt e-iekļaušanas riska studentus, bet arī konstatēt tādu riska faktoros, kurus iespējams novērst, tad par riska faktoru nevar izmantot mācību laikā nemainīgas pazīmes, piemēram, studenta dzimumu, vecumu, tautību, ekonomisko un finanšu stāvokli, iepriekšējos mācību sasniegumus (atzīmes) utml. Lai gan daudzos pētījumos šādi atribūti tiek izmantoti studentu mācību sasniegumu prognozēšanai, tos nevar uzskatīt par riska faktoriem, kurus var novērst, bet par faktoriem, kuri var norādīt uz konkrētiem studentiem, kam varētu būt grūtības mācību procesā. Laikā nemainīgas pazīmes var izmantot kā papildus pazīmes, bet ne kā vienīgās pazīmes, uz kurām balstoties tiek prognozēta indivīda e-iekļautība. E-iekļaušanas modelēšanā nav iespējams izmantot tos atribūtus, ko lieto, modelējot studentu sasniegumus, kas apgūst augstāko izglītību, jo digitālo prasmju kursi ir nosacīti īslaicīgi, tie nav mērāmi vairāku semestru garumā. Izvēloties atribūtu noteikšanas pieeju, jāņem vērā zinātniskajā literatūrā norādītais, ka būtiski ir izprast, kā indivīdi mācās un balstīt atribūtu izvēli teorijā.

2.5. Studentu sasniegumus prognozējošo modeļu raksturojums

Šīs apakšnodaļas mērķis ir raksturot zinātniskajā literatūrā pieejamos studentu sasniegumus prognozējošus modeļus no šādiem aspektiem: modeļa mērķis; izmantotās prognozēšanas metodes un pazīmes, uz ko balstoties ir veikta prognoze; iegūtie modeļa veikspējas rādītāji. Ja pieejama informācija, tad raksturots tiek arī izmantoto datu kopu apjoms, mācīšanās veids, apgūstamās programmas līmenis un citi indivīdus un mācīšanās procesu aprakstoši rādītāji.

Digitālo prasmju un to jēgpilnas lietošanas prognozēšanas modeļi. Primāri autore apskatīja pētījumus, kas saistīti ar digitālo prasmju apguvi un to jēgpilnu izmantošanu, respektīvi, kur aprakstīti prognozējoši modeļi, kuru mērķis ir saistīts ar indivīda e-iekļautības paredzēšanu.

Faktoranalīze tiek izmantota pētījumā, kur tiek prognozētas 1280 studentu digitālās prasmes un to lietošana, secinot, ka pazīmes, kas ietekmē prognozi, ir indivīda iepriekš apgūto digitālo prasmju līmenis, IKT lietošanas pieredzes ilgums, kā arī studenta ieinteresētība pētniecībā vai vēlme uzzināt kaut ko jaunu (*Verhoeven* u. c., 2020). Iegūtais rezultāts uzrāda, ka ar IKT lietošanas pieredzes ilgumu iespējams izskaidrot 17,5 % no datora izmantošanas biežuma brīvā laika nodarbēm.

Lineārās regresijas metode izmantota vairākos pētījumos. Līdzīgs secinājums, ka iepriekšējo datorprasmju līmenis ietekmē indivīdu IKT risinājumu un pakalpojumu lietošanu, ir pētījumā, kur ar Spīrmēna rangu korelācijas analīzes metodi, regresiju analīzi, t-testu pētīti dati par 52 vecāka gadagājuma cilvēkiem (*Berkowsky* u. c., 2017). Šajā pētījumā kā faktoriālā pazīme, kas ietekmē tehnoloģiju lietošanu, ir norādīta pārliecība par savām spējām iemācīties lietot tehnoloģiju un tehnoloģijas ietekme uz dzīves kvalitāti. Pētījumā iegūtie lineārās regresijas vienādojumi (determinācijas koeficienti robežās no 0,254 līdz 0,764), ar kuriem var

prognozēt kādas tehnoloģijas lietojumu, ir atšķirīgi katrai tehnoloģijai, tas nozīmē, ka tie nav vispārināmi un nav atkārtoti izmantojami. Piemēram, lai prognozētu rezultātu mācībām par CAD programmatūru kombinētās mācīšanās kursā, izmanto lineārās regresijas modeli (Akhtar u. c., 2017). Apmeklējums, uzdevumam veltītais laiks, sociālā stabilitāte – darbs grupā, studenta izvēlēta sēdvietā klasē tiek izmantoti kā prediktori. Lineārās regresijas vienādojumi ir atšķirīgi katrā mācību gadā. 50 % tiek izmantots kā sliekšnis, vai ir risks vai nav. Lineāro regresijas modeli veido, lai meklētu saistību starp pedagogu digitālajām prasmēm un to ietekmējošiem faktoriem (Lucas u. c., 2021). Ar lineārās regresijas modeļiem nosaka pedagogu digitālo prasmju līmeni, kā prediktorus lieto demogrāfiskos faktorus (Guillén-Gámez u. c., 2020a).

Daļa prognozējošo modeļu tiek balstīti klasifikācijas un regresijas metodēs. Pētījumā, kur analizēti 17 000 iedzīvotāji un 75 % no tiem korekti prognozēts zems vai neesošs digitālo prasmju līmenis, tiek izmantota mašīnmācīšanās pieeja, klasifikatori un regresijas koki, bet kā pazīmes ir socioekonomiskie faktori (Hidalgo u. c., 2020). Attiecībā uz e-iekļaušanas prognozēšanu ir pieejami pētījumi, kas, vadoties no demogrāfiskiem, sociāliem un ekonomiskiem faktoriem, ar 148 klasifikācijas koku algoritmu paredz dažādus e-iekļaušanu raksturojošus notikumus vispārīgā (mājokļu), ne indivīdu līmenī (Coria u. c., 2013).

Prognozējošie modeļi tiek veidoti, izmantojot ar dažādiem klasifikatoru algoritmiem ģenerētus modeļus, kuriem tiek salīdzināti veiktspējas rādītāji un izvēlēti turpmākajai lietošanai modelis ar augstākajiem rādītājiem. Piemēram, izmantojot mašīnmācīšanas pieeju, ar vairākiem klasifikācijas un regresiju algoritmiem tiek prognozēti studenti, kam ir risks neapgūst programmēšanas kursu (Azcona u. c., 2019). Šajā pētījumā modeļa apmācībai kā atribūti lietoti 149 studentu demogrāfiskie dati un atzīmes kursa apguves laikā, kā arī studentu aktivitātes rādītājs. Lai izveidotu fināla prognozēšanas modeli, tiek apmācīti vairāki modeļi, izmantojot gadījumu mežu, *kNN*, lēmumu koku, loģistiskās regresijas, *SVM* algoritmus. Kā veiktspējas rādītāji tiek noteikta precizitāte, pārklājums un F1 mērs. Tie iegūts, ka riska studentu klasei F1 mērs ir robežās no 70 %–75 %, precizitāte ir 71 %–72 %, pārklājums ir 72 %–83 %.

Studentu sasniegumus prognozējošie modeļi. Lai iegūtu plašāku priekšstatu par prognozējošiem modeļiem, autore apskata modeļus, kuru mērķis ir paredzēt studentu sasniegumus, apgūstot dažāda veida prasmes un zināšanas, kas nav saistītas tikai ar informācijas un komunikācijas tehnoloģiju lietojumu. Tā kā promocijas darba kontekstā digitālās prasmes indivīdi apgūst kombinētās mācīšanāsursos, tad autore apskata pētījumus, kur mācības notiek gan klātienē nodarbībās, gan tiešsaistē e-vidēs, apgūstot e- materiālus.

Pieejamie pētījumi rāda, ka studentu sasniegumu prognozēšanai tiek izmantotas dažādas prognozēšanas metodes un algoritmi, kā arī atšķirīgas ir pazīmes, uz kurām balstoties tiek veiktas prognozes.

Pētījumos tiek izmantotas klasteranalīzes metodes, lai raksturotu studentu grupas, ar ko tās atšķiras un kas tām ir kopīgs (piemēram, mācību sasniegumu vērtējumu līmenis). Pētījumā, kur atklāti pieci studentu uzvedību raksturojoši klasteri e-vides platformā, kā arī iegūtie rezultāti rāda, ka dažādiem mācību kursiem ir atšķirīgs akurātums (no 38 % līdz 79 %) studentu noslēguma atzīmju prognozēšanai ar gadījumu mežu algoritmu (Luo u. c., 2020).

Daudzfaktoru lineārā regresija ir viena no metodēm studentu sasniegumu analīzē. Pētījumā, kur kā studentu ietekmējošie faktori ir iegūti no e-mācību vides atbilstoši studentu veiktajām darbībām, tiek izmantota daudzfaktoru lineārā regresija, lai noteiktu studentu

mācību rezultātus (Xu u. c., 2020). Iegūto lineāro regresiju modeļu determinācijas koeficienti ir 0,579 un 0,567.

Klasifikācijas metodes ir visplašāk izmantotas studentu sasniegumus prognozējošo modeļu izveidē. Piemēram, pētījumā, kur apskatīti 13 prognozējošie modeļi, secināts, ka biežāk izmantoti ir loģistiskās regresijas un *SVM* algoritmi, bet ir plašs loks citu algoritmu, kā piemēram, gadījumu meži, lēmumu koki, dziļā mācīšanās (Tamada u. c., 2019). Atkarībā no izmantotajām prognozēšanas metodēm, iegūtie modeļu veiktspējas rādītāji ir atšķirīgi. Citā literatūrā pieejamā pētījumā salīdzināti 179 klasifikatori, kas izmanto 121 datu kopu un iegūts, ka ar gadījumu mežu algoritmu ģenerētie klasifikācijas modeļi uzrāda augstāko akurātumu – 94,1 % (Fernández-Delgado u. c., 2014). Pētījumā, kurā apkopoti akurātuma rādītāji mašīnmācīšanās prognozēšanas metodēm, ir secināts, ka dažādām prognozēšanas metodēm (naivais Beijesa, lēmumu koki, *kNN*, *SVM*) akurātums ir robežās no 50 % līdz 97 %. (Ashraf u. c., 2018). Šajā pētījumā atribūti ir indivīdu demogrāfiskie rādītāji un iepriekšējie mācību sasniegumi. Izmantojot lēmumu koku algoritmu C4.5, lai prognozētu studentus, kam ir risks nepabeigt mācības, tiek iegūta precizitāte 82 %, pārklājums 76 % (Pereira u. c., 2019). Veidojot prognozējošo modeli ar naivo Beijesa algoritmu ar 76 studentu datu kopu, tiek iegūts, ka riska klasei modeļa precizitāte ir 88,1 %, pārklājums ir 90,2 % un F1 mērs ir 89,2 % (Suresh u. c., 2016).

Pētījumā, kur veidots studentu noslēguma atzīmes prognozējošs modelis, izmantojot datus par 273 studentiem, kas *Moodle* platformā apgūst kursu par IKT gan klātienēs nodarbībās, gan tiešsaistē pastāvīgi, un kur kā algoritmi izmantoti lēmumu koki, ir secināts, ka studenta noslēguma atzīmi var prognozēt ar akurātumu 67.27 % (Baksa-Haskó un Baranyai, 2018). Pētījumā, kur prognozējošo modeļu izveidei izmantoti lineāro diskriminantu analīzes, loģistiskās regresijas, *CART*, *kNN*, naivais Beijesa un *SVM* algoritmi, augstāko akurātumu 86 % uzrādīja loģistiskās regresijas un *CART* algoritmi (Buraimoh u. c., 2021).

Apjomīgs skaits pētījumu ir par riska studentu noteikšanu *MOOC* platformās (Chen u. c., 2016; Klüsener un Fortenbacher, 2015; Pereira u. c. 2019; Tamada u. c., 2019). Kā atribūti tiek izmantoti studenta profila dati un dati, kas iegūti forumā, kā mašīnmācīšanās metodes ir izmantoti vairāki algoritmi – stohastiskā gradienta palielināšana (angļu val. – *Stochastic Gradient Boosting*), lēmumu koki, gadījumu meži, lēmumu likumi, loģistiskā regresija, *kNN*. Tiek secināts, ka, nosakot studentus, kam ir risks nepabeigt *MOOC* kursus, augstāku precizitāti uzrāda šādi algoritmi: stohastiskā gradienta palielināšana, gadījumu meži, bet zemāko precizitāti uzrāda tuvāko kaimiņu metode *kNN*, loģistiskā regresija (Cobos un Olmos, 2018).

Bieži prognozēšanas modeļu izveide notiek, salīdzinot vairāku modeļu veiktspējas rādītājus. Prognozējošā modeļa izveides procesā raksturīgi ir vispirms veidot vairākus klasifikācijas modeļus ar atšķirīgiem klasifikatoriem, un tad izvēlēties modeli, kuram ir augstāki veiktspējas rādītāji (Meedech u. c., 2016). Piemēram, salīdzinot 8 klasifikācijas modeļus, kas veidoti ar *JRip*, *OneR*, *Ridor*, *J48*, *SimpleCart*, *ADTree*, gadījumu mežu un *REPTree* algoritmiem, tiek iegūts, ka augstākā akurātuma vērtība 83,4 % ir ar *ADTree* algoritmu ģenerētajam modelim. Salīdzinot ar gadījumu mežu, *Adaptive Boost*, *XGBoost* un *GradientBoost* algoritmiem veidotus klasifikācijas modeļus dažādiem mācību kursiem, iegūts, ka modeļu akurātums ir no 82 % līdz 94 %, *Gradient Boost* algoritms uzrāda augstāko akurātumu (Alamri u. c., 2019). Salīdzinot lineāro diskriminantu analīzes, loģistiskās regresijas, *CART*, *kNN*, naivā Beijesa un *SVM* algoritmus, augstāko akurātumu 86 % uzrādīja

loģistiskās regresijas un *CART* algoritmi, precizitāte, pārklājums un F1 mērs šiem algoritmiem bija robežās no 85 % līdz 86 % (*Buraimoh* u. c., 2021). Līdzīgi citā pētījumā, izmantojot datu kopu par 60 studentiem, tiek veidots modelis, kas prognozē studentu noslēguma atzīmes, ir salīdzināti veiktspējas rādītāji modeļiem, kas veidoti ar *J48*, naivo Beijesa un gadījumu meža algoritmiem. Kā atribūti šajā pētījumā ir izmantoti dati par studentu dzimumu, vecumu, apmeklējumu, testu atzīmes, uzdevumu vērtējumi, citi starpvērtējumi, kā arī studentu aktivitāte klātienē nodarbībās. Ar algoritmu *J48* ir iegūts akurātums 93.3 %, ar naivo Beijesa algoritmu akurātums ir 86.7 %, ar gadījumu mežu algoritmu pat 100 % akurātums (*Mahboob* u. c., 2016). Pētījumā, kur prognozējošais modelis veidots ar 670 studentu datiem, izmantojot 10 klasifikācijas algoritmus, kas balstīti lēmumu kokos vai likumos, iegūts, ka pārklājums riska studentiem ir no 76 % līdz 99 % atkarībā no izmantotā klasifikācijas algoritma (*Márquez-Vera* u. c., 2013). Šajā pētījumā augstākie veiktspējas rādītāji ir *ADTree* algoritmam – 99 % pārklājums un 97 % akurātums. Pētījumā, kur prognozēšanas modeļu izveidei datu kopās studentu skaits ir 495 un 516 ir iegūts modeļa akurātumu starp 75 % un 80 % ar lēmumu koku algoritmu *CART (SimpleCart)* un *C4.5 (J48)*, Beijesa klasifikatoru (*BayesNet*), loģistisko modeli, likumos balstītus klasifikācijas algoritmu (*JRip*) un gadījumu mežu, kā arī *OneR* klasifikatoru (*Dekker* u. c., 2009). Šajā pētījumā prognozēšanas modelis kā galvenos atribūtus izmanto studentu atzīmes dažādosursos. Pētījumā, kur izmantota studentu datu kopa, kas satur mazāk par 100 objektus, secina, ka ar mašīnmācīšanās metodēm un prognozējošo modeļu kombinēšanu iespējams sasniegt pat 97 %–100 % korekti prognozētus riska studentus (*Lykourantzou* u. c., 2009). Kā atribūti ir izmantoti demogrāfiskie rādītāji, studentu atzīmes, kā arī aktivitātes un attieksmes pret mācībām rādītāji. Izmantotas šādas metodes: neironu tīkli, *SVM*. Akurātums ir no 77 % līdz 97 %. Kā atribūti ir izmantotas studentu iepriekš iegūtās atzīmes.

Pieejami pētījumi par studentu sasniegumu prognozēšanu rāda, ka prognozēšanas modeļi prognozi par riska studentiem veido, balstoties ne tikai uz viena algoritma paredzējumu, bet vairākiem, izmantojot klasifikatoru ansambļa metodi. Piemēram, pētījumā, kur ar mašīnmācīšanās metodēm tiek prognozēts, vai students pabeigs, vai nepabeigs kursu, ir izmantota ansambļa pieeja, kas nozīmē, ka tiek kombinētas vairākas klasificēšanas metodes studentu datu analīzei: *kNN*, *Radial Basis Function Network Classifier*, *SVM* (*Dewan* u. c., 2015). Šajā pētījumā studentu dati, kas tiek izmantoti klasificēšanas algoritmam, sastāv no 28 atribūtiem, kā, piemēram, vērtējumi par uzdevumu izpildi, laika ilgums, ko students ir pavadījis forumos un citām studentu raksturojošām pazīmēm.

Secinājumi par studentu sasniegumus prognozējošajiem modeļiem.

Autore secina, ka nav iespējams tiešā veidā pārņemt literatūrā pieejamos modeļus, lai prognozētu indivīda e-iekļaušanas procesu, jo pieejamie pētījumi neuzrāda modeli, atribūtu kopumu, kas būtu viennozīmīgi pārņemams un atkārtoti izmantojams. Modeļu izveidi ietekmē gan modeļa mērķis, gan konteksts kādā veidā notiek mācības, kāds ir mācību saturs, vide, gan studentus raksturojošās pazīmes. Autores atziņa par to, ka nav iespējams pārņemt tieši iepriekš izveidotus modeļus saskan ar rezultātiem, kas iegūti pētījumā par mācību prognozējošu modeļu lietošanu 17ursos, un, kur ir secināts, ka nav iespējams esošos prognozējošos modeļus atkārtoti izmantot citos līdzīgosursos vai mācību gados (*Conijn* u. c., 2017). Mācīšanās analītikas viens no izaicinājumiem ir prognozējošo modeļu izveidē nodrošināt, ka tie ir ne tikai vienreizējai lietošanai vai vienam kursam, bet nepieciešams tos vispārināt plašākam kursu skaitam (*Hung* u. c., 2019; *Romero* un *Ventura*, 2019). Pētījumi

rāda, ka atkārtoti izmantojot prognozēšanas modeļus, tā veikspējas rādītāji ir vidēji, piemēram F1 mērs ir 60 % (*Gitinabard* u. c., 2019). Tā kā e-iekļaušanas procesā būtiski ir nodrošināt, ka studenti sekmīgi apgūst digitālās prasmes, no literatūrā pieejamajiem modeļiem ir iespējams izmantot pētījumu rezultātus par prognozējošo modeļu izveidi studentu sasniegumu paredzēšanā. Tas attiecas uz prognozēšanā izmantotajām metodēm, algoritmiem, pazīmēm un modeļu veikspējas rādītājiem, kas tiek aprakstīti turpmākajās apakšnodaļās atbilstoši prognozējoša modeļa izveides posmiem.

Autore secina, ka tikai nedaudz pētījumos ir pieejama informācija par prognozējošiem modeļiem, kas nosaka indivīda digitālo prasmju līmeni vai IKT lietošanas līmeni, tomēr, galvenokārt, šie modeļi ir balstīti uz demogrāfiskiem faktoriem vai indivīda personības iezīmēm un iepriekšējām digitālām prasmēm, tas ir faktoriem, kurus mācību procesa laikā nav iespējams mainīt, lai novērstu risku (*Guillén-Gámez* u. c., 2020a; *Lucas* u. c., 2021).

Prognozēšanas modeļi veidoti dažāda veidā apgūstamām mācību programmām – tiešsaistē, klātienē, vai jaukti. Autore uzskata, ka nav iespējams pilnībā pārņemt MOOC platformās pieejamās studentus raksturojošās pazīmes un izmantotos algoritmus e-iekļaušanas prognozēšanai. MOOC platformu prognozēšanas modeļi izmanto liela apjoma datus un atribūtus, kas ne vienmēr pieejami kombinētās mācīšanāsursos. Kā arī kombinētās mācīšanāsursos ir klātienē nodarbības instruktora vadībā, tāpēc būtiski izprast instruktora ietekmi uz studentu digitālo prasmju apguvi un to jēgpilnu turpmāko izmantošanu.

Prognozējošo modeļu izveidē ir izmantotas atšķirīga apjoma datu kopas, piemēram, modeļiem, kuru prognozes ir saistītas ar e-iekļautību, ir 52 dalībnieki vai 17 000 dalībnieki. Digitālās prasmes indivīdi bieži apgūst tālākizglītības, profesionālās pilnveides, neformālās izglītībasursos, kur dalībnieku skaits ir nosacīti neliels, dažu simtu, ne tūkstošu apmērā, tāpēc autore literatūras izpētē pievērta uzmanību pētījumiem, kur prognozēšanas tehnoloģijas ir izmantotas nelielām studentu grupām. Jāuzsver, ka pētījumos lielākā prognozējošo modeļu daļa attiecas uz lielo datu analīzi, kur dati ietver ļoti lielas studentu raksturojošas datu kopas ar apjomīgu atribūtu skaitu (*Ashraf* u. c., 2018). Literatūrā ir norādīts, ka salīdzinoši maz pētīti gadījumi, kur tiek prognozēti studentu sasniegumi, ja ir neliels studentu skaits un neliels prognozēšanā izmantoto atribūtu skaits (*Wakelam* u. c., 2020). Salīdzinot prognozēšanas modeļa rezultātu rādītājus ar tiem, kur ir izmantoti lieli datu apjomi, var uzskatīt, ka apskatītie pētījumi rāda, ka var iegūt prognozēšanas modeļu veikspēju rādītājus mazām datu kopām salīdzināmus ar tiem rādītājiem, kas iegūti liela apjoma datu kopām (kur studentu skaits pārsniedz pat 10 000 un atribūtu skaits tuvojas 100).

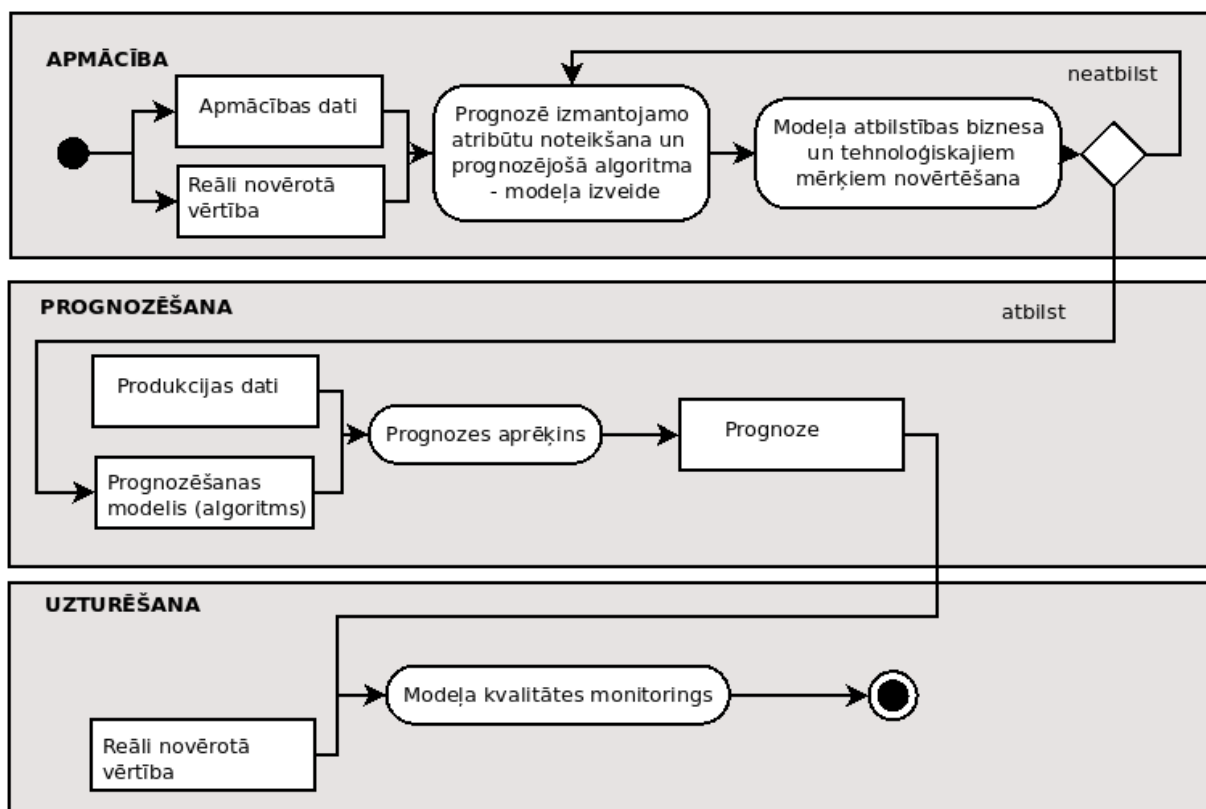
Prognozēšanas metodes literatūrā pieejamos pētījumos ir daudzveidīgas, izmantotas gan faktoranalīzes, lineārās regresijas, gan klasifikācijas metodes.

Pētījumos bieži kā veikspējas rādītājs ir norādīts prognozēšanas modeļa akurātums. Salīdzinot ar akurātumu, retāk kā modeļa veikspējas rādītāji zinātniskajā literatūrā ir norādīti prognozējamās klases precizitāte, pārklājums, F mērs, kas precīzāk raksturo prognozējošo modeļi, kad klasē, par kuru ir galvenā interese, ir mazāks gadījumu skaits, kā tas ir promocijas darba kontekstā, kad autore interesējas par studentiem, kam ir digitālās izslēgšanas risks. Kā veikspējas rādītāji atkarībā no izvēlētās metodes ir izmantoti arī determinācijas koeficienti. Veikspējas vērtības ir atšķirīgas izmantotajiem algoritmiem, piemēram klasifikācijas modeļu akurātums modeļiem, kas prognozē digitālo prasmju apguvi vai lietojumu ir 75 %, F1 mērs ir robežās no 70 %-75 %, precizitāte ir 71 %-72 %, pārklājums ir 72 %-83 %. Veikspējas rādītāji ar vienu un to pašu klasifikatoru algoritmu veidotajos klasifikācijas modeļos ar

atšķirīgām datu kopām, pazīmēm ir dažādi, kas norāda uz to, ka katram individuālam prognozēšanas gadījumam ir jāmeklē atbilstošs klasifikatora algoritms, ar kuru modelis uzrāda labākos veiktspējas rādītājus. Pētījumi atklāj, ka, lai uzlabotu veiktspējas rādītājus, veidojot klasifikācijas modeļus, tiek izmantoti vairāki klasifikatori, salīdzināti to veiktspējas rādītāji un tad turpmākai lietošanai izvēlēti tie klasifikatori, kam ir augstāki veiktspējas rādītāji vai veidoti klasifikatoru ansamblī.

2.6. Prognozējošu informācijas sistēmu darbības procesi mašīnmācīšanās tehnoloģiju kontekstā

2.1. attēlā ir parādītas prognozējošu informācijas sistēmu galvenie procesi mašīnmācīšanās tehnoloģiju kontekstā. Informācijas sistēmu, kuras izveidē ir izmantoti mašīnmācīšanās tehnoloģijās balstīti prognozējoši modeļi, raksturo divas galvenās funkcijas: modeļa apmācība un prognozēšana (*Berral u. c., 2010*).



2.1. att. Prognozējošu informācijas sistēmu galvenās funkcijas: modeļa apmācība, prognozēšana, uzturēšana.

Lai veiktu prognozes aprēķinu, izmantojot modeli, sistēma saņem datus par studentu, kam ir nepieciešama prognoze par mācību rezultātiem, un, ievietojot šos studentu raksturojošos datus modelī, veic aprēķinu (*Petkovic u. c., 2012*). Šajā posmā notiek sistēmai iemācīto zināšanu izmantošana, lai veiktu sistēmai paredzētos uzdevumus (*Ning, u. c., 2011; Wang Hua u. c., 2009*). Prognozēšanas posms ietver arī šādu darbību - iegūtās prognozes analīze un rezultātu interpretācija (*Halkidi, u. c., 2001*). Šajā posmā tiek noteikts, vai pastāv risks un kādi faktori nosaka risku, kā arī var tikt veikta padziļināta risku analīze. Noslēdzošais prognozēšanas posmā ir sistēmas rīcība atbilstoši iegūtajai prognozei (*Ribeiro De Carvalho*

Martinho u. c., 2013). Šis posms dažādām sistēmām ir atšķirīgs, atkarībā no izvirzītajiem uzdevumiem. Ja prognoze ir studentam labvēlīga, tad sistēma var analizēt nākošo studentu. Gadījumos, ja prognoze norāda uz riskiem, sistēma var informēt studentu, instruktoru, izglītības iestādes pārstāvi, un tas var uzsākt riska novēršanas pasākumus.

Informācijas sistēmām, kuru izveide ir balstīta mašīnmācīšanās tehnoloģiju lietojumā, būtiska ir arī prognozējošā modeļa kvalitātes uzturēšanas funkcija (*Studer* u. c., 2021).

Secinājumi par e-iekļaušanu prognozējošu informācijas sistēmu. Iepazīstoties ar literatūrā aprakstītajiem prognozēšanas modelī balstītu informācijas sistēmu procesiem, autore secina, ka, veidojot e-iekļaušanas prognozējošo tehnoloģisko modeli, jānodrošina, ka tas:

1) spēj mācīties, izmantojot studentus raksturojošos datus, atrod algoritmu, ar kura palīdzību var noteikt riska studentus;

2) spēj prognozēt e-iekļaušanas riskam pakļautos studentus.

Kā vēlama e-iekļaušanas prognozēšanas tehnoloģiskā modeļa funkcija ir izveidotā modeļa monitorings un uzturēšana, lai nodrošinātu prognozējošā modeļa kvalitāti (*Maskey* u. c., 2019).

2.7. Prognozējoša modeļa izveides process un tā lietojums e-iekļaušanu prognozējošā tehnoloģiskā modeļa izveidē

Mācību analītika ietver šādus galvenos procesus: iegūt un uzglabāt datus; analizēt datus; sniegt informāciju par analīzes rezultātu (2.2. tab.) (*Sclater*, 2017).

2.2. tabula

Prognozējoša modeļa izveides procesa posmi.

Mācību analītikas procesa posmi (<i>Sclater</i> , 2017)	Datizraces procesa posmi (<i>CRISP-DM</i>) (<i>Wirth</i> un <i>Hipp</i> , 2000)	Mašīnmācīšanās procesa posmi (<i>CRISP-ML</i>) (<i>Studer</i> u. c., 2021)
-	Izprast problēmsfēru	Izprast problēmsfēru
Iegūt un uzglabāt datus	Izprast datus	Izprast datus
	Sagatavot datus	Sagatavot datus
Analizēt datus	Izveidot modeli	Izveidot modeli
	Novērtēt modeli	Novērtēt modeli
Sniegt informāciju par analīzes rezultātu	Izvietot modeli	Izvietot modeli
-	-	Monitorēt un uzturēt modeļa kvalitāti

Mācību analītikas procesu var detalizēt sešos galvenos posmos atbilstoši *CRISP – DM* (*Cross-industry standard process for data mining*) standartam, ja prognozēšanas modeli veido ar datizraces metodēm (*Wirth* un *Hipp*, 2000; *Baksa-Haskó* un *Baranyai*, 2018). Galvenie posmi datizraces modeļa izveidē ir (1) izprast problēmsfēru (biznesu); (2) izprast datus; (3) sagatavot datus; (4) izveidot modeli; (5) novērtēt modeli; (6) izvietot (implementēt) modeli. Posmu secība nav strikti noteikta, ja nepieciešams, tad var atgriezties un atkārtoti veikt kādu no posmiem. Lai gan *CRISP-DM* ir datizraces standarts, tas tiek plaši izmantots ne tikai datizraces projektiem, bet arī mašīnmācīšanās balstītas programmatūras izstrādē (*Ekubo*, 2020; *Shearer*, 2000). Balstoties uz *CRISP-DM* standartu, ir izveidota *CRISP-ML (Q)* (*Cross-*

Industry Standard Process model for the development of Machine Learning applications with Quality assurance methodology) metode, kas paredzēta mašīnmācīšanās modeļu izveidei un to kvalitātes nodrošināšanai (Studer u. c., 2021). *CRISP-ML* metode datizraces procesa modeli paplašina, pielāgojot to mašīnmācīšanās uzdevumam. Mašīnmācīšanās gadījumā modelis tiek papildināts ar noslēdzošo posmu, kas pēc modeļa izvietojšanas produkcijas vidē, paredz monitorēt un uzturēt modeļa kvalitāti, pirmie divi posmi, kas ietver problēmsfēras un datu iepazīšanu, ir apvienoti, tādējādi kopējais posmu skaits saglabājas kā datizraces modelim.

Dažādi autori, aprakstot prognozējošo modeļu izstrādes posmus, tos ir apvienojuši vai gluži pretēji detalizējuši. Amerši (*Amershi*) ar kolēģiem (2019) piedāvā deviņus posmus mašīnmācīšanās balstītas programmatūras izstrādē: modeļa prasību stadija, datu vākšana, datu tīrīšana, datu marķēšana, pazīmju noteikšana, modeļa apmācība, modeļa novērtēšana, modeļa izvietošana, modeļa uzraudzība. Daži posmi attiecas uz datiem (piemēram, vākšana, tīrīšana un marķēšana), bet citi attiecas uz modeli (piemēram, modeļa prasības, pazīmju noteikšana, modeļa novērtēšana, izvietošana un uzraudzība). Salīdzinot ar *CRISP-DM* vai *CRISP-ML* metodēm, detalizēti ir ar datu sagatavošanu saistītie posmi, bet pēc būtības jauni posmi netiek paredzēti. Patersons (*Paterson*) ar kolēģiem visu mašīnmācīšanās modeļa izstrādi apvieno četros posmos: datu pārvaldība, modeļa apmācība, modeļa verifikācija, modeļa izvietošana, atsevišķi neizdalot prasību izstrādi un modeļa uzturēšanas posmus (*Paterson* u. c., 2021).

Datizracē un mašīnmācīšanās balstītu prognozēšanas sistēmu izveides procesa posmi un to pielietojums e-iekļaušanu prognozējošā tehnoloģiskā modeļa izveidē

Izvērtējot literatūrā aprakstītos prognozējošu modeļu izveides procesu, var redzēt, ka mašīnmācīšanās balstītu sistēmu galvenie darbības procesi ietver gan datizraces, gan mācību analītikas procesus. Autore detalizētāk apraksta prognozējoša mašīnmācīšanās modeļa izveides procesu un veic secinājumus attiecībā uz e-iekļaušanu prognozējošā modeļa izveidi.

Problēmsfēras izpratnes posms

2.3. tabula

Problēmsfēras izpratnes posma uzdevumi un rezultāti, adaptēti no (*Studer* u. c., 2021).

N.p.k.	Uzdevums	Rezultāts
1.	Noteikt biznesa mērķi: 1) identificēta problēma, kas jāatrisina, 2) noteikts, kādi mērķi jāsasniedz no biznesa aspekta 3) noteikti, kādi ir ierobežojumi mērķa sasniegšanā, piemēram, risinājumu veidi, kurus var izmantot, datu ierobežojums utml.	Skaidrojums par biznesa problēmu
		Definēti biznesa mērķi, piemēram, kas tiek plānots sasniegt ar projektu. Definēti biznesa mērķu izpildes kritēriji, norādot, kā tiks mērīti rezultāti.
2.	Noteikt datizraces vai mašīnmācīšanās procesa mērķi atbilstoši biznesa mērķim.	Definēts, kas būs rezultāts datizraces vai mašīnmācīšanās procesam, piemēram, prognozējošs modelis.
		Definēti datizraces vai mašīnmācīšanās procesa rezultātu kvalitātes kritēriji, norādot, kā tiks mērīti rezultāti, piemēram, kādi veikspējas rādītāji izveidotam modelim tiks mērīti un vai ir jāsasniedz noteikts skaitlisks rādītājs.

Problēmsfēras izpratnes posmā mērķis ir zināšanu iegūšana par doto jomu, tās problēmām,

uzlabošanas iespējām, mērķiem, ierobežojumiem. 2.3. tabulā ir doti problēmsfēras izpratnes posma uzdevumi un sasniedzamie rezultāti (*Studer u. c., 2021*). Problēmsfēras izpratnes posmā ir jāiedziļinās attiecīgajā biznesa nozarē un jānosaka programmatūras izstrādes mērķis. Problēmsfēras izpratne ietver biznesa mērķu un izmantojamo tehnoloģiju mērķu noteikšanu un rezultātu novērtēšanas rādītāju definēšanu.

Datu izpratnes posms

Datu izpratnes posma mērķis ir noskaidrot, vai ir pieejami dati, kas ir piemēroti biznesa problēmas risināšanai. 2.4. tabulā ir doti datu izpratnes posma uzdevumi un sasniedzamie rezultāti (*Studer u. c., 2021*).

2.4. tabula

Datu izpratnes posma uzdevumi un rezultāti, adaptēti no (*Studer u. c., 2021*).

N.p.k.	Uzdevums	Rezultāts
1.	Datu vākšana	Noskaidroti datu ieguves avoti un iegūtas datu kopas tālākai apstrādei.
2.	Datu aprakstīšana	Raksturoti datu ieguves avoti, datu formāti, apjomi utml.
3.	Datu izpēte	Datus aprakstošā statistika
4.	Datu kvalitātes pārbaude	Novērtējums, vai dati ir piemērotā apjomā, vai nav trūkstošu datu.

Datu ieguve var būt no vēsturiskiem statistiskiem datiem vai arī reālā laikā mainīgiem dinamiskiem datiem (*Arnold, 2010*). Neatkarīgi no tā, vai institūcija izmanto reāla laikā iegūtus datus vai vēsturiski uzkrātus, ja datus nav iespējams izgūt savlaicīgi un efektīvi, tad nav iespējams izmantot analītikas iespējas (*Arnold, 2010*). Bieži dati tiek iegūti no dažādām datu bāzēm, kas ir nesavietojamas bez papildus apstrādes. Sistēmai nodotās, no ārējās vides saņemtās informācijas kvalitāte ir kritisks faktors prognozējošās sistēmās (*Halkidi, u. c., 2001; Wang Hua u. c., 2009*). Statisku datu ieguve ir salīdzinoši vienkārša – vienreizēja ieguve un reti ir izmaiņas. Dinamisku datu pārvaldība un iekļaušana algoritmos ir viens no sistēmas izstrādes izaicinājumiem (*Arnold, 2010*). Dati tiek iegūti no dažādiem avotiem. Mācību vidēs tiek uzglabāti dati dažādos formātos un ar atšķirīgu detalizācijas līmeni, piemēram, taustiņsienu (klikšķu), pieslēgšanās sesijas, studenta, klases/kursa un izglītības iestādes līmenī.

Datu sagatavošanas posms

Kad ir iegūti prognozēšanai nepieciešamie izejas dati, šie dati ir jāsagatavo atbilstoši izvēlētajai prognozēšanas metodei un algoritmam. Datu sagatavošanas posma mērķis ir sagatavot datus nākamajam modelēšanas posmam (*Fu, u. c., 2012; Ning, u. c., 2011; Ribeiro De Carvalho Martinho, u. c., 2013; Wang Hua, u. c., 2009*). 2.5. tabulā ir doti datu sagatavošanas posma uzdevumi un sasniedzamie rezultāti (*Studer u. c., 2021*). Datu sagatavošanas posms ietver četrus uzdevumus: datu izvēle, datu tīrīšana, datu konstruēšana, datu standartizēšana.

Datu izvēle. Datu sagatavošanas posmā viens no svarīgākajiem uzdevumiem ir datu atlase, kas ietver pazīmju (atribūtu), uz kurām balstoties tiek izdarīta prognoze, noteikšanu. Mācību analītikas eksperti uzskata, ka pazīmju identificēšana ir viens no sarežģītākajiem un grūtāk atrisināmajiem mācību analītikas uzdevumiem. Šajā posmā mērķis ir izvēlēties tos

datu, kas raksturo problēmapgabalu vislabāk un kurus turpmāk, atbilstoši to vērtībām, ar izvēlēto algoritmu, izmantos prognozēšanai (*Halkidi* u. c., 2001).

2.5. tabula

Datu sagatavošanas posma uzdevumi un rezultāti, adaptēti no (*Studer* u. c., 2021).

N.p.k.	Uzdevums	Rezultāts
1.	Datu izvēle	Noteiktas pazīmes, kas atspoguļo risināmo problēmu un tiks izmantotas modeļa izveidē. Līdzsvarota datu kopa, ja nepieciešams.
2.	Datu tīrīšana	Izņemti “trokšņus” veidojošie dati, aizstātas trūkstošās vērtības.
3.	Datu konstruēšana	Jaunu pazīmju izveidošana no esošajiem datiem. Mainīgo un pazīmju vērtību transformēšana (piemēram, no skaitliskām vērtībām uz nominālām), mainīgo mērogošana.
4.	Datu failu standartizēšana	Modelēšanai nepieciešamo failu formātu izveide (piemēram, <i>csv</i> formāts).

Datu tīrīšanas, datu konstruēšanas un datu failu standartizēšanas uzdevumu veikšana ir tehniska un saistīta ar izvēlētajiem rīkiem modeļa izveidei, tāpēc autore detalizētāk neapskata šos uzdevumus. Atkarībā no izvēlēta algoritma dati var būt skaitliskā skalā vai nominālā skalā, ir algoritmi, kur nepieciešams datu binārs kodējums. Šajā posmā notiek, piemēram, nejaušu kļūdu – “trokšņu” izņemšana no datiem, studentu raksturojošu datu apvienošana no dažādiem datu avotiem, vajadzīgo pazīmju konstruēšana u.c. datu apstrādes operācijas.

Datu sagatavošanas rezultātā ir izveidota piemēru datu bāze, kurā ir gan apmācībai, gan modeļa testēšanai paredzētie dati (*Ribeiro De Carvalho Martinho*, u. c., 2013). Jānorāda, ka pirms datu sagatavošanas posma, ir nepieciešams zināt, kādas metodes un prognozēšanas algoritmus sistēma izmantos.

Prognozējošā modeļa izveides posms

Modelēšanas posma mērķis ir noteikt piemērotākās modelēšanas metodes. Veidojot prognozējošus modeļus, prognozēšanas metodes izvēle ir saistīta ar datu (atribūtu) izvēli un attiecīgi iegūtajiem veiktspējas rādītājiem.

2.6. tabulā ir doti modeļa izveidošanas posma uzdevumi un sasniedzamie rezultāti (*Studer* u. c., 2021).

Modelēšanas metodes izvēle. Kā rezultāts šim uzdevumam ir iespējamo modelēšanas tehniku (piemēram, klasificēšana, lineārā regresija utml.) izvēle atbilstoši tam, kādas iespējas no datu viedokļa un vajadzības no mērķu viedokļa.

Modeļa pārbaudes pieejas izvēle. Kā rezultāts šim uzdevumam ir noteikts, kā tiks veikta modeļa pārbaude (piemēram, datu dalīšana validācijas un apmācības datu kopās, šķērsvalidācijas izmantošana utml.).

Modeļa veidošana. Kad dati ir sagatavoti, tad daļa no datiem, tā saucamie apmācības (angļu val. – *training*) dati tiek nodoti apmācības algoritmam un tiek noteiktas, kādas sakarības pastāv starp datiem. Šinī posmā tiek izveidots prognozējošais modelis. Literatūrā šis posms tiek dēvēts arī par zināšanu krātuves izveidi (*Wang Hua* u. c., 2009). Zināšanu krātuve satur vispārīgus principus, kas tiek izmantoti, lai veiktu sistēmas uzdevumus līdz brīdim, kad no ārējās vides tiek saņemta jauna informācija un notiek atkārtota sistēmas apmācība un jaunu

Modeļa izveidošanas posma uzdevumi un rezultāti, adaptēti no (Studer u. c., 2021).

N.p.k.	Uzdevums	Rezultāts
1.	Modelēšanas metodes izvēle	Iespējamo modelēšanas tehniku (piemēram, klasificēšana, lineārā regresija utml.) izvēle atbilstoši tam, kādas iespējas no datu viedokļa un vajadzības no mērķu viedokļa.
2.	Modeļa pārbaudes pieejas izvēle	Definēts, kā tiks veikta modeļa pārbaude (piemēram, datu dalīšana validācijas un apmācības datu kopās, šķērsvalidācijas izmantošana utml.).
3.	Modeļa veidošana	<p>Modeļa hiperparametru iestatījumi.</p> <p>Modeļa apraksts, kur norādīts modeļa veids (piemēram, lineārā regresija), izmantotie mainīgie un modeļa interpretācija.</p> <p>Modelis</p>
4.	Modeļa novērtēšana (ar validācijas datiem)	Modeļa novērtējums un/vai salīdzinājums ar iepriekšējiem modeļiem tā piemērotībai problēmas risinājumam, kā arī parametru iestatījumu maiņa, lai veiktu atkārtotu modeļa izveidi.

Kā rezultāts šim uzdevumam ir:

- 1) Modeļa hiperparametru iestatījumi;
- 2) Modeļa apraksts, kur norādīts modeļa veids (piemēram, lineārā regresija), izmantotie mainīgie un modeļa interpretācija;
- 3) Modelis.

Modeļa novērtēšana (ar validācijas datiem). Modeļa novērtēšanas posma mērķis ir pārliecināties, ka iepriekšējā posmā izveidotais prognozējošais modelis nākotnē spēs prognozēt tikpat precīzi, kā ar apmācības datu kopu (Ning, u. c., 2011; Halkidi, u. c., 2001). Šajā posmā izmanto modeļa validācijas metodes, piemēram, šķērsvalidācijas metodi vai novilcināšanas metodi. Ne visos mašīnmācīšanās balstīto sistēmu procesu atspoguļojumā atsevišķi ir uzsvērts modeļa novērtēšanas posms (Fu u. c., 2012; Ribeiro De Carvalho Martinho, u. c., 2013; Wang Hua u. c., 2009). Modeļa novērtēšanai var tikt izmantota šķērsvalidācijas metode. Ja modelis atbilst izvirzītajiem precizitātes kritērijiem, tad tiek uzsākts nākamais posms – prognozēšanas process. Ja modelis neatbilst izvirzītajiem precizitātes kritērijiem, tad sistēmas apmācīšanas process tiek uzsākts no jauna. Kā rezultāts šim uzdevumam ir modeļa novērtējums un/vai salīdzinājums ar iepriekšējiem modeļiem tā piemērotībai problēmas risinājumam, kā arī parametru iestatījumu maiņa, lai veiktu atkārtotu modeļa izveidi.

Modeļa novērtēšanas (ar testa datiem) posms

Viens no prognozējošā modeļa izstrādes posmiem, pirms modeli izmanto darbībā, ir modeļa novērtēšana. Modeļa novērtēšanas mērķis ir noskaidrot, cik precīzi izveidotais modelis prognozē ar iepriekš neredzētiem datiem (datiem, kas nav izmantoti apmācībā). Novērtēšanas posma mērķis ir noteikt, kurš modelis vislabāk atbilst biznesa mērķiem. 2.7. tabulā ir doti modeļa novērtēšanas posma uzdevumi un sasniedzamie rezultāti (Studer

u. c., 2021). Novērtēšanas posms ietver šādus uzdevumus: novērtēt modeļa rezultātus ar testa datiem un atkarībā no iegūtajiem rezultātiem izlemt, vai modelis atbilst sākotnēji izvirzītiem biznesa mērķiem. Modeļa novērtēšanas posmā ieteicams pārbaudīt modeli praktiskā lietojumā, izveidojot prototipu, lai noteiktu, vai tas reālajā vidē darbojas tikpat labi kā izstrādes procesā (Studer u. c., 2021).

2.7. tabula

Modeļa novērtēšanas posma uzdevumi un rezultāti, adaptēti no (Studer u. c., 2021).

N.p.k.	Uzdevums	Rezultāts
1.	Modeļa rezultātu novērtēšana	Noskaidrots, vai ir sasniegti sākotnēji izvirzītie biznesa mērķi un tiem atbilstošie kritēriji. Apstiprināti modeļi: tie ietver visus modeļus, kas atbilst iepriekš noteiktajiem biznesa kritērijiem.
2.	Nākamo darbību noteikšana	Ieteikumi nākamajam solim – izvietot modeli produkcijas vidē vai atkārtoti veidot jaunu modeli, uzlabojot to.

Modeļa izvietojšanas posms

Izvietojšanas posmā mērķis ir nodrošināt, ka ieinteresētās personas - lietotāji piekļūst modelim un tā rezultātiem. Mācību analītikas rīks, kas ietver prognozējošo modeli var tikt izmantots mācību pārvaldības sistēmās kā tās sastāvdaļa vai veidots kā neatkarīgs rīks (Lenar u. c., 2019). Mācību analītikas rīku lietošanas pieredzes izpēte ir tās sākumposmā, tomēr esošie pētījumi rāda, ka pedagogi uzskata mācību analītikas rīkus par noderīgiem, bet tajā pašā laikā par grūti lietojamiem, nepieciešami to uzlabojumi, it īpaši vizualizācijas, neatkarība no mācību pārvaldības sistēmas versijas, datu formātiem (Lenar u. c., 2019). 2.8. tabulā ir doti modeļa izvietojšanas posma uzdevumi un sasniedzamie rezultāti (Studer u. c., 2021).

2.8. tabula

Modeļa izvietojšanas posma uzdevumi un rezultāti, adaptēti no (Studer u. c., 2021).

N.p.k.	Uzdevums	Rezultāts
1.	Izvietojšanas plānošana	Izvietojšanas plāns, kas satur secīgus soļus, kas jāsteno
2.	Modeļa izvietojšana	Modeļa integrācija produkcijas vidē
3.	Modeļa izvietojšanas novērtēšana	Modeļa novērtējums produkcijas vidē

Modeļa pārraudzības un uzturēšanas posms

Modeļa pārraudzības un uzturēšanas posma mērķis ir nodrošināt modeļa kvalitāti ilgtermiņā. Zinātniskajā literatūrā nav vienotas izpratnes par to, kuri ir labākie galvenie rādītāji mašīnmācīšanās modeļu kvalitātes mērīšanai (Sculley u. c., 2015). Mašīnmācīšanās balstītu lietojumprogrammu pārvaldības sarežģītību nosaka tas, ka to veikspēja ir atkarīga ne tikai no apmācības procesā izmantotiem datiem, bet arī no tā, ka produkcijas posmā izmantotie dati var mainīties (piemēram, to sadalījums) (Lu u. c., 2018; Nelson u. c., 2015; Zaharia u. c., 2018).

2.9. tabulā ir doti modeļa pārraudzības un uzturēšanas posma uzdevumi un sasniedzamie rezultāti (Studer u. c., 2021). Galvenie uzdevumi iekļauj šādus darbus: modeļa pārraudzības

un uzturēšanas plānošanu, modeļa pārraudzību un atjaunināšanu. Modeļa pārraudzība ietver datu integritātes, datu sadalījuma, modeļa veikspējas rādītāju novērojumus, lai pieņemtu lēmumus par modeļa atjaunināšanas nepieciešamību. Izmantojot mašīnmācīšanās metodes analītikas rīkos, svarīgi ir paredzēt resursus rīka darbības kvalitātes monitoringam (*Nakajima, 2018*). Ja modeļa kvalitāte vairs neatbilst izvirzītajām prasībām, tad viens no veidiem, kā to uzlabot ir modeļa pārāpmācība. Modeļa atkārtotas apmācības biežumu ietekmē atšķirību apjoms apmācības datos un produkcijas datos (*Lu u. c., 2018, Nelson, 2015*). Modeļu pielāgošanai jauniem datiem ir dažādas pieejas, tostarp atkārtota modeļa apmācība, modeļa nepārtraukta vai tiešsaistes mācīšanās (*Chen un Liu, 2018*).

2.9. tabula

Modeļa pārraudzības un uzturēšanas posma uzdevumi un rezultāti, adaptēti no (*Studer u. c., 2021*).

N.p.k.	Uzdevums	Rezultāts
1.	Pārraudzības un uzturēšana plānošana	Plāns pārraudzībai un uzturēšanai
2.	Modeļa pārraudzība	Informācijas iegūšana par modeļa veikspējas rādītājiem un lēmums par modeļa atjaunināšanas nepieciešamību
3.	Modeļa atjaunināšana	Atjaunināts modelis (atkārtoti apmācīts ar datiem, kas iepriekš nav izmantoti, novērtēts, kā arī citi iespējamie uzlabojumi)

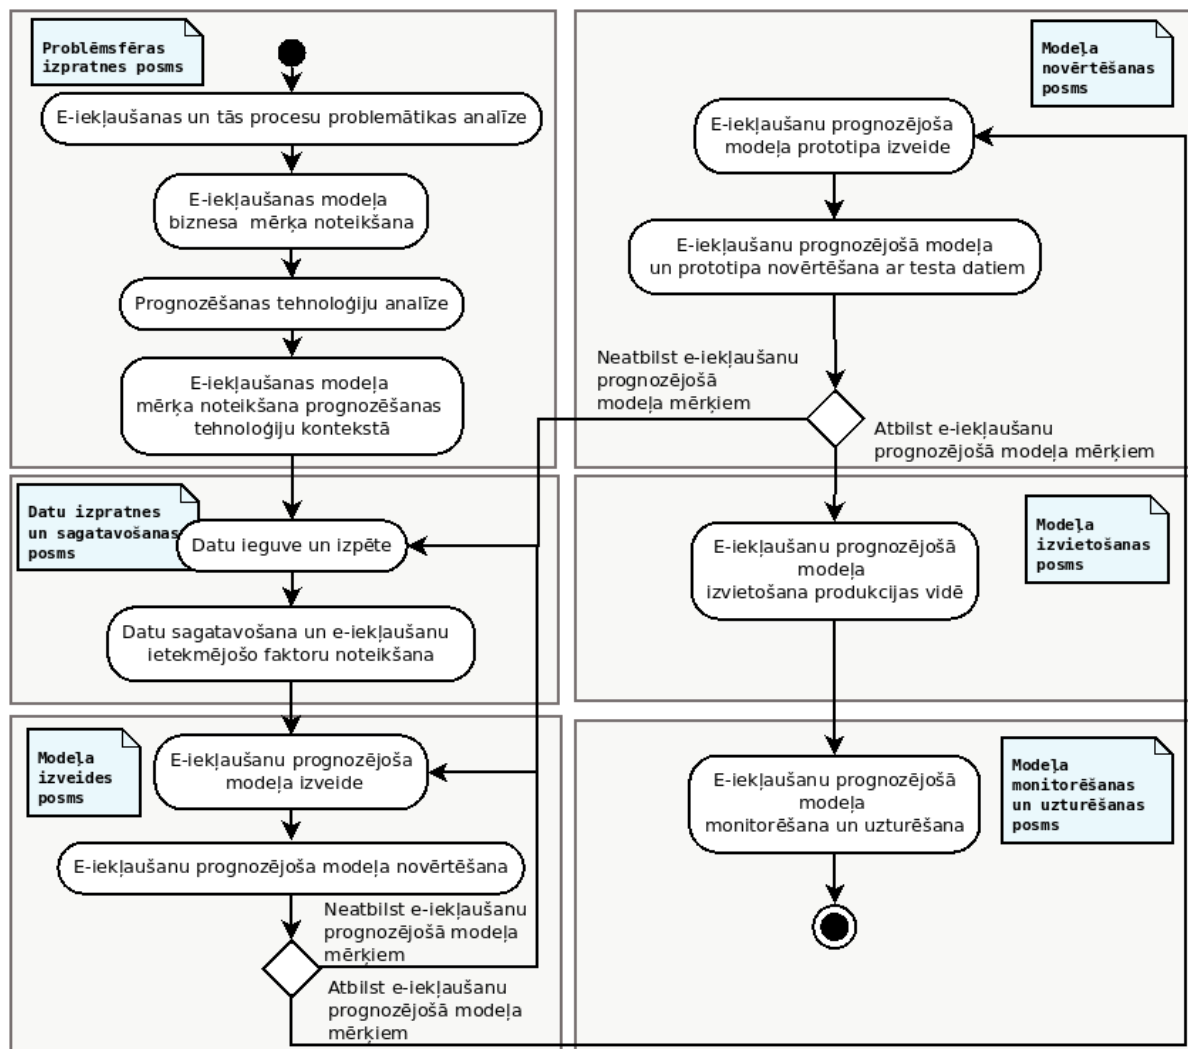
2.8. E-iekļaušanu prognozējošā modeļa izveides posmi

Balstoties uz 2.7. nodaļas prognozējošo modeļa izveides procesa posmiem, e-iekļaušanu prognozējošā modeļa izveides posmi ir doti 2.2. attēlā.

Ņemot vērā, ka nepieciešams analizēt e-iekļaušanas problēmsfēru, lai noteiktu e-iekļaušanas prognozējošā modeļa mērķus, autore indivīda e-iekļaušanu prognozējošas mašīnmācīšanās balstītas sistēmas izveidei par pirmo posmu nosaka biznesa izpratnes posmu. Veidojot indivīda e-iekļaušanu prognozējošo tehnoloģisko modeli, biznesa izpratnes posmā ir nepieciešams analizēt e-iekļaušanas procesu, lai identificētu e-iekļaušanas procesu problēmas un noteiktu, kāds ir mērķis, kas jāsasniedz tās risināšanā. Šī posma laikā jānosaka arī vispārīgs mērķis e-iekļaušanu prognozējošai sistēmai no prognozēšanas tehnoloģiju aspekta. Promocijas darba 1. nodaļa ietver e-iekļaušanas procesu analīzi un e-iekļaušanu prognozējošā modeļa biznesa mērķus.

Ņemot vērā to, ka nav pieejams visaptverošs e-iekļaušanas prognozēšanas tehnoloģiju apraksts, par otro posmu prognozējošā modeļa izveidei autore nosaka prognozējošo tehnoloģiju izpēti, lai īstenotu e-iekļaušanas prognozēšanas modelim izvirzītos biznesa mērķus. Prognozējot indivīda e-iekļautības pakāpi, kā rezultāts ir jāiegūst informācija ne tikai par to, vai students sekmīgi pabeigs digitālo prasmju apguves kursu, bet būtisks ir jau nākamais solis, vai students lietos jēgpilni jaunās prasmes, piemēram, profesionālajām vajadzībām. E-iekļautības prognozējošajam modelim būtisks ir gan indivīda mācīšanās process, gan prasmju pielietojums pēc kursa apguves, jo tikai digitālo jaunapgūto prasmju lietošana padara indivīdu par e-iekļautu. Kā arī e-iekļaušanu prognozējošajam modelim ir jāspēj atklāt riska faktori, ko novēršot būtu iespējams ietekmēt studenta sasniegumus. Lai

noteiktu, kādi mērķi e-iekļaušanas prognozēšanas modelim ir jāasniedz datizraces un mašīnmācīšanās kontekstā, ir nepieciešams analizēt pieejamo prognozēšanas tehnoloģiju lietojumu indivīdu mācību sasniegumu noteikšanai. Promocijas darba 2. nodaļā ir noteikti datizraces un mašīnmācīšanās tehnoloģiju un to lietojuma mērķi atbilstoši e-iekļaušanas procesa biznesa mērķiem.



2.2. att. E-iekļaušanu prognozējošā modeļa izveides process.

Ņemot vērā to, ka prognozējošā modeļa izveide ir iteratīvs process un cieši saistīts ar datu iegūvi, datu izpēti, pazīmju noteikšanu un modeļa apmācību ar dažādiem algoritmiem, autore apvieno datu izpratnes un sagatavošanas un modeļa izveides posmu vienā posmā. Tādējādi par trešo posmu prognozējošā modeļa izveidē autore nosaka e-iekļaušanu ietekmējošo faktoru noteikšanu un e-iekļaušanu prognozējošā modeļa izveidi. Prognozējošā modeļa izveide ietver arī modeļa novērtēšanu, izmantojot šķērsvalidācijas metodes, un modeļa veiktspējas rādītāju (attiecībā uz “nav e-iekļauts” klasi) – pārklājuma, precizitātes un F mēra vērtību salīdzinājumu. Promocijas darba 3. nodaļa ietver datu izpratnes, sagatavošanas un modeļa izveides posmus e-iekļaušanu prognozējošam tehnoloģiskam modelim.

Ceturtajā posmā prognozējošā modeļa izveidē autore veic modeļa novērtēšanu, kas ietver prototipa izstrādi, tā darbināšanu ar testa datiem un novērtēšanu. Promocijas darba 4. nodaļa satur e-iekļaušanu prognozējošā modeļa novērtēšanas posmu. Šis posms ietver e-iekļaušanu prognozējošā modeļa prototipa izveidi, tā novērtējumu ar testa datiem.

Piektais un sestais posms, kas promocijas darba gaitā netiek apskatīts, ir modeļa pilnvērtīga izvietošana un darbināšana produkcijas vidē un modeļa pārraudzība un uzturēšana.

2.9. Kopsavilkums un secinājumi par tehnoloģiju un metožu lietojumu studentu sasniegumus prognozējošā modeļa izveidē

Autore secina, ka nav iespējams tiešā veidā pārņemt literatūrā pieejamos modeļus, lai prognozētu indivīda e-iekļaušanas procesu. Tā kā e-iekļaušanas procesā būtiski ir nodrošināt, ka studenti sekmīgi apgūst digitālās prasmes, no literatūrā pieejamajiem modeļiem ir iespējams izmantot pētījumu rezultātus par prognozējošo modeļu izveidi studentu sasniegumu paredzēšanā. Tas attiecas gan uz prognozēšanā izmantotajām metodēm, algoritmiem, pazīmēm un modeļu veikspējas rādītājiem.

1) Lai no mācību analītikas būtu ieguvums pedagoģiskajā procesā, izvēloties analizējamus datus, būtiski ir izprast, kā indivīdi mācās un datu (atribūtu) izvēli veikt saistībā ar indivīdu mācīšanās procesu.

2) Līdzšinējie pētījumi viennozīmīgi nenorāda piemērotāko teorētisko ietvaru analizējamo datu izvēlē. Modeļu izveidē izmantotie atribūti ir daudzveidīgi, tie ietver gan demogrāfisko informāciju, gan studentu iepriekš iegūtos vērtējumus par mācību uzdevumiem, gan studentu aktivitāšu datus. Izvēloties prognozējošā modeļa atribūtus, būtiski ir par atribūtiem izvēlēties tādas studentus raksturojošas pazīmes, kas atspoguļo novēršamus riska faktorus, raksturo studentu mācīšanās procesu un ir balstīti zināšanu pārvaldības teorijā.

3) E-iekļaušanu prognozējošā modeļa izveidē izmantot mašīnmācīšanās balstītu pieeju, vispirms apmācīt modeli un tad ar to prognozēt digitālās izslēgšanas riskam pakļautos studentus. Būtiski ir nodrošināt modeļa vispārīgumu – ka tas spēj prognozēt ne tikai viena kursa ietvaros, bet plašākam kursu apjomam.

4) Literatūrā nav viennozīmīgi noteiktas piemērotākās prognozēšanas metodes riska studentu noteikšanai. Viena no iespējamā indivīda e-iekļaušanas prognozēšanā ir izmantot kvantitatīvas prognozēšanas metodes, atklājot cēloņu-secu sakarības. Klasifikācijas uzdevumi var tikt risināti ar klasifikatoriem, kas klasificēšanu balsta atšķirīgās klasifikācijas metodēs un klasifikatoru ģenerēšanas algoritmos. Klasifikatoru algoritmu izvēle ir atkarīga arī no pieejamās datu kopas un risināmās problēmas. Literatūrā pieejamie pētījumi atklāj, ka veidojot klasifikācijas modeļus tiek izmantoti vairāki klasifikācijas algoritmi, salīdzināti to veikspējas rādītāji un tad turpmākai lietošanai izvēlēti tie klasifikācijas algoritmi, kam ir augtāki veikspējas rādītāji. Studentu sasniegumu prognozējošo modeļu izveidei tiek izmantotas lineārās regresijas metodes, kā arī studentu dalījums klasteros. Veidojot e-iekļaušanas prognozēšanas modeli, ir nepieciešams izmantot dažādas datizraces metodes, un izveidot vairākus modeļus, lai salīdzinot to veikspējas rādītājus, varētu izvēlēties modeļus ar augstākiem veikspējas rādītājiem. Modeļu izveidi ietekmē pieejamo datu veids, ja rezultatīvā pazīme ir kategoriju mainīgais, tad iespējams izmantot klasifikācijas metodes, ja rezultatīvā pazīme ir nepārtraukts, skaitliskais mainīgais, tad - lineārās regresijas metodi.

5) Literatūrā ir secināts, ka prognozējošo modeļu kombinēšana ļauj sasniegt augstākus veikspējas rādītājus. Tāpēc e-iekļaušanas prognozējošā modeļa izveides procesā jāsālidzina veikspējas rādītāji individuāliem prognozēšanas modeļiem ar šo modeļu kombinācijām, lai noteiktu, kuros gadījumos ir augstāki veikspējas rādītāji.

6) Literatūrā ir rekomendēts nodrošināt klašu līdzsvaru, kā vienu no klašu līdzsvarošanas

metodēm var izmantot *SMOTE* metodi, lai sasniegtu augstākus veikspējas rādītājus.

7) Par prognozējošo modeļu veikspējas primārajiem rādītājiem binārās klasifikācijas gadījumā izmantot F mēru, precizitāti un pārklājumu.

8) Literatūrā ir secināts, ka studentu sasniegumu prognozējošo modeļu veikspējas rādītāji ir diapazonā no 50 % līdz pat 100 %, atkarībā no izmantotajiem studentus raksturojošajiem atribūtiem un prognozēšanā izmantotajiem algoritmiem.

9) E-iekļaušanas prognozēšanas modeļa novērtēšanā izmantot šķērsvalidācijas metodi, kas ir piemērota neliela apjoma datu kopām.

10) E-iekļaušanas tehnoloģiskā modeļa izveides procesā ievērot *CRISP-DM* un *CRISP-ML* metožu ieteikumus un paredzēt, šādus posmus prognozējošā modeļa izveidē: (1) izprast e-iekļaušanas problēmsfēru un izmantojamās tehnoloģijas prognozēšanas modeļa izveidē, izvirzot mērķus un sasniedzamos rezultātus; (2) izprast un sagatavot prognozēšanas modeļa izveidei pieejamos indivīdus raksturojošos datus, kā arī izmantojot šos datus izveidot e-iekļaušanu prognozējošo modeli, apmācot un novērtējot tā veikspējas rādītājus; (3) novērtēt prognozējošā modeļa veikspējas rādītājus ar testa datiem un izvietojot prognozējošo modeli prototipā.

3. INDIVĪDA E-IEKĻĀUŠANU IETEKMĒJOŠO FAKTORU UN PROGNOZĒJOŠO MODEĻU PĒTĪJUMS ZINĀŠANU RADĪŠANAS UN PĀRNESES PROCESA KONTEKSTĀ

Atbilstoši *CRISP-DM* un *CRISP-ML (Q)* metodēm šajā nodaļā ir atspoguļots e-iekļaušanu prognozējošo datu ieguves, sagatavošanas un modeļa izveides posms, īpaši veicot e-iekļaušanu ietekmējošo faktoru izpēti.

Nodaļas mērķis ir izveidot e-iekļaušanu prognozējošo modeli, veicot šādus uzdevumus:

1) izmantojot zināšanu pārvaldības teorijas atziņas, noteikt iespējamus e-iekļaušanas faktorus;

2) indivīda e-iekļautību prognozējošā modeļa izveidei nepieciešamo datu ieguve saskaņā ar noteiktajiem faktoriem;

3) izmantojot iespējamus faktorus, izveidot modeli, ar ko ir iespējams prognozēt studentus, kam ir e-iekļautības risks, un noteikt, kuri faktori jāizmanto prognozējošajā modelī;

4) noteikt piemērotāko modeli studenta e-iekļaušanas prognozēšanai, salīdzinot modeļu veikspējas rādītājus.

Īstenojot augstāk minētos uzdevumus, vērā ir ņemtas e-iekļaušanu prognozējošajam tehnoloģiskajam modelim izvirzītās prasības - noteikt, vai studentam, kurš apgūst digitālās prasmes, ir risks, ka pēc prasmju apguves tas neizmantos jaunapgūtās prasmes profesionālām vai privātām vajadzībām.

Balstoties uz iepriekšējās nodaļas no zinātniskās literatūras iegūtajiem secinājumiem, e-iekļaušanu prognozējošā modeļa (algoritma) izveides pētījumi veikti saskaņā ar šādu metodiku:

1) secīgi izmantotas trīs dažādas datizraces metodes (lineārās regresija, klasteranalīze, klasificēšana) un ar katru no tām, veidots prognozes modelis, novērtēti prognozes modeļa veikspējas rādītāji, kā arī novērtēts, vai modeli var vispārināt digitālo prasmju apguves kursiem;

2) veidotas prognozes modeļu kombinācijas, novērtēts kādām modeļu kombinācijām uzlabojas veikspējas rādītāji, kā arī novērtēts, vai modeli var vispārināt digitālo prasmju apguves kursiem.

Katrā no e-iekļaušanu prognozējošā modeļa (algoritma) izveides pētījumiem ir precizētas izmantotās metodes datu analīzei, modeļa novērtēšanai, kā arī aprakstīts, kādi dati veido piemēru datu bāzi, kas izmantota modeļa apmācībā.

Nodaļa sastāv no septiņām apakšnodaļām. Pirmajā apakšnodaļā ir noteikti un raksturoti indivīda e-iekļaušanu ietekmējošie faktori, balstoties uz zināšanu pārvaldības teoriju. Otrajā apakšnodaļā ir aprakstīta datu ieguve un sagatavošana modeļu izveidei. Nākamajās apakšnodaļās ir atspoguļoti pētījumi, kuros iesaistīti profesionālo izglītības iestāžu pedagogi, kas instruktora vadībā pilnveidoja savas digitālās prasmes klātienēs nodarbībās un internetā e-studiju platformā *Moodle*. Trešajā apakšnodaļā ir meklētas korelācijas starp iespējamajiem faktoriem un indivīda e-iekļautību, kā arī veidoti lineārās regresijas modeļi indivīda e-iekļautības prognozēšanai. Ceturtajā apakšnodaļā ir izmantota klasteranalīzes pieeja, lai analizētu faktoru saistību ar indivīda e-iekļautību. Piektajā apakšnodaļā ir pētīts, vai ar klasifikācijas algoritmiem ir iespējams prognozēt indivīda e-iekļautību. Sestajā nodaļā ir

izveidots un novērtēts e-iekļaušanas prognozēšanas modelis, izmantojot iepriekšējās nodaļā analizētās metodes – klasificēšanu, klasteranalīzi, lineāro regresiju. Septītajā nodaļā ir kopsavilkums un secinājumi par indivīda e-iekļaušanu ietekmējošiem faktoriem un piemērotāko e-iekļaušanu prognozējošo modeli.

3.1. Zināšanu pārvaldības teorijā balstīti e-iekļaušanu ietekmējoši faktori

Šīs apakšnodaļas uzdevums ir noteikt iespējamus faktorus, kas ietekmē indivīda e-iekļautību jeb indivīda spēju jēgpilni izmantot digitālās prasmes. Indivīda e-iekļautību ietekmējošo faktoru noteikšanai ir izmantotas zināšanu pārvaldības teorijas atziņas.

Plaisa starp zināšanām un zināšanu praktisko lietojumu

Plaisa starp zināšanām un zināšanu praktisko lietojumu ir viens no iemesliem, kāpēc organizācijās darbinieki, atgriezoties no apmācībām, zināšanas pilnvērtīgi neizmanto organizācijas mērķu sasniegšanai (*Pfeffer un Sutton, 1999*). Ar jēdzienu “zināt” tiek saprasts, ka indivīdam ir spējas pielietot zināšanas noteiktā darbībā. Šī pētījuma kontekstā tas nozīmē, ka indivīdam ir digitālās prasmes vai spējas pielietot zināšanas, lai veiktu ar IKT saistītus uzdevumus. Termins “darīt” attiecas uz aktivitāti. Šī pētījuma ietvaros tiek uzskatīts, ka “darīt” attiecas uz jēgpilnu digitālo prasmju pielietošanu profesionālām vai privātām vajadzībām.

Par plaisu starp zināšanām un zināšanu praktisku lietojumu digitālo prasmju kontekstā tiek uzskatītas atšķirības starp digitālo prasmju esamību un to praktisko lietošanu. Pieņemts, ka ideālais stāvoklis ir tāds, ja kādas tehnoloģijas aktuālo izmantotāju skaits konverģē ar potenciālo lietotāju skaitu (*Becker u. c., 2008*).

Lai gan veikti pētījumi, kā mazināt plaisu starp zināšanām un zināšanu praktisku pielietojumu, piemēram, industriālajā pārvaldībā (*Wortman, 2005*), klīniskā medicīnā (*Cochrane u. c., 2007*), bioloģijā (*Knight u. c., 2008*), ķīmijas inženierzinātnē (*Steenefeldt u. c., 2006*), tomēr nav pieejami pētījumi par šādas plaisas novēršanu e-iekļaušanas kontekstā.

Zināšanu plūsmas e-iekļaušanas kontekstā

Atbilstoši Nisena (*Nissen*) (2006) teorijai plaisa starp zināšanām un zināšanu praktisku lietojumu var rasties, ja ir problēmas zināšanu plūsmā.

Zināšanu plūsmām ir trīs svarīgi atribūti: virziens (sūtītājs un saņēmējs); nesējs (medijs); saturs (koplietojams) (*Zhuge, 2004*). E-iekļaušanas procesa kontekstā zināšanu sūtītājs ir instruktors vai digitālo prasmju eksperts, saņēmējs ir students, kuram ir nepieciešams uzlabot vai iegūt jaunas digitālās prasmes.

IKT attīstība ir veicinājusi tehnoloģiju nozīmi mācību procesā. Mūsdienās tradicionālās mācīšanās formas bieži ir pilnībā vai daļēji aizstātas ar e-studijām, lai sasniegtu labākus mācību rezultātus (*Mason un Rennie, 2008*). Promocijas darbā kā nesējs (medijs) apskatīta e-studiju vide un internets. E-vides loma zināšanu pārnēsē ne tikai palīdz studentiem izprast mācību saturu, bet arī nodrošina studentu un instruktoru komunikāciju (*Oye, u. c., 2011*).

Nisens savos pētījumos ir norādījis, ka, lai zināšanas plūstu uz indivīdu, instruktoram vai ekspertam ir jāgrib un jābūt spējīgam dalīties ar zināšanām; studentam jāgrib un jābūt spējīgam mācīties; organizācijai jāgrib un jābūt spējīgai palīdzēt studentam saņemt zināšanas, bet instruktoram vai ekspertam dalīties ar zināšanām (*Nissen, 2006, p.11*).

Indivīda e-iekļautību raksturo tas, ka tam piemīt digitālās prasmes un tās tiek jēgpilni

izmantotas. E-iekļautības kontekstā atbilstoši Nisena pieejai, lai zināšanas par digitālajām prasmēm nonāktu pie indivīda, instruktoram ir jāgrib un jāspēj dalīties ar zināšanām par digitālām prasmēm, indivīdam jāgrib un jābūt spējīgam mācīties un apgūt digitālās prasmes; organizācijai ir jāgrib un jābūt spējīgai palīdzēt studentam (piemēram, nodrošinot tehnoloģiju pieejamību) un instruktoram zināšanu nodošanā un saņemšanā.

Iespējamie e-iekļaušanu ietekmējošie faktori atbilstoši zināšanu pārvaldības teorijai

Autore piedāvā e-iekļaušanas kontekstā izmantot pieeju, kur iespējamība, ka jaunapgūtās digitālās prasmes tiks jēgpilni lietotas (indivīds būs e-iekļauts), tiek noteikta, balstoties uz trīs faktoriem:

1. faktors: pakāpe, kādā instruktors ir ieinteresēts un spējīgs dalīties ar zināšanām;
2. faktors: pakāpe, kādā students ir ieinteresēts un spējīgs mācīties;
3. faktors: pakāpe, kādā organizācija ir ieinteresēta un spējīga atbalstīt mācīšanas un mācīšanās procesu.

1. faktors. Instruktoru ieinteresētība un spēja dalīties ar zināšanām. Instruktoru ieinteresētību dalīties ar zināšanām autore saprot kā atbalstu, kas tiek sniegts studentiem. Ja studenti lieto e-mācību vidi, tad instruktora loma mainās. Zināšanu pieejamība ir atkarīga no vides satura pieejamības, piemēram, mācību materiāli, e-vides lietošanas ērtuma satura ieguvei un komunikācijai. Piedāvātajā modelī uz instruktora spēju dalīties ar zināšanām autore skatās e-vides kontekstā un definē, to kā kursa satura un e-vides kvalitāti.

Par to, ka instruktors ietekmē to, kā studenti lieto un cik labi spēj apgūt IKT, liecina vairāki pētījumi (*Quintana un Zambrano, 2014; Sánchez, 2010; Sundqvist u. c., 2020; Soobramoney, & Heukelman, 2019*). Mācību vides ietekme uz studentu sasniegumiem ir norādīta par pētījumā par prognozējošo modeļu izveidi (*Maennel, 2020*).

2. faktors. Studentu ieinteresētība un spēja mācīties. Pētījumos studentu interese tiek identificēta kā svarīgs motivējošs elements, kas ietekmē mācību sasniegumus. (*Abrantes u. c., 2007, Subramaniam, 2009*). Pētījumos studentu motivācija ir norādīta kā priekšnoteikums digitālo prasmju ieguvei (*Hatlevik u. c., 2015; Senkbeil un Ihme, 2017*). Saskaņā ar Djuī (*John Dewey*) teoriju (1913) mācīšanās rezultāti ir atkarīgi no studenta interesēm. Autore modelī studenta interesi mācīties iedala šādos četros interešu veidos: sociālās, intelektuālās, profesionālās un personīgās.

Studenta spēju mācīties autore apraksta ar studenta iepriekšējo pieredzi, kas atspoguļojas zināšanu līmenī. Studenta iepriekšējai pieredzei modelī ir svarīga loma. Saskaņā ar konstruktīvisma teoriju, katrs students konstruē jaunas zināšanas balstoties savā esošajā pieredzē (*Powell u. c., 2009; Vedins, 2011*). Mācīšanās procesa laikā studentu zināšanu līmenis var pieaugt. Lai noteiktu studenta spēju mācīties, autore lieto procentuālo zināšanu līmeņa pieaugumu.

ES ir noteikusi sešas pamata datoru un interneta prasmes (*European Commission, 2011, p. 11*). Šīs prasmes ietver pamata datorzināšanas, kas sastāv no prasmēm kopēt vai pārvietot datnes mapē, rīku pārzināšanu, lai kopētu, pārvietotu un ielīmētu informāciju dokumentā, izmantotu pamata aritmētiskās formulas izklājlappās, arhivētu datnes, uzstādītu jaunas ierīces (piemēram, drukas iekārta) un rakstītu datorprogrammas kādā programmēšanas valodā (*European Commission, 2012*). Autore piedāvā novērtēt šo kritērijus e-iekļaušanas modelī, lai noteiktu studenta vispārīgo digitālo prasmju līmeni.

3. faktors. Organizācijas atbalsts un mācīšanās procesa veicināšana. Šajā darbā

autore pieņem, ka organizācijai ir vienāda attieksme pret visiem studentiem, ikvienam studentam ir iespēja apgūt e-kursu digitālo prasmju pilnveidei. Organizācija atbalsta visus studentus. Digitālo prasmju apguves kontekstā organizācijai ir svarīga loma tehnoloģiju nodrošināšanā, lai tās darbinieki varētu pielietot jaunapgūtās digitālās prasmes.

Jānorāda, ka izvēlētie indivīda e-iekļautību raksturojošie faktori atbilst tiem, kas saistīti ar izniekoto (angļu val. – *scrap*) mācīšanos, ko pētījumos minējis Pike (2018) un ko lieto darbinieku apmācības kontekstā, lai norādītu uz apgūtā mācību satura apjomu, ko izglītojamais nelietos darbā. Būtībā *izniekotā mācīšanās* nozīmē izniekotu apmācības laiku un finanses. Savukārt organizācijas atbalsts darbinieku digitālo prasmju apgūvē veicina digitālas uzņēmējdarbības attīstību (*Huđek* u. c., 2019).

3.2. Datu ieguve un sagatavošana pētījumiem par prognozējošo modeļu izveidi un iespējamo e-iekļaušanu ietekmējošo faktoru pārbaudi

Apakšnodaļas mērķis ir iegūt un sagatavot datu kopas atbilstoši iepriekšējā nodaļā noteiktajiem indivīda e-iekļaušanu ietekmējošajiem faktoriem. Datu kopu sagatavošana ir nepieciešama, lai veiktu pētījumus ar datu analīzē, statistikā, datizracē un mašīnmācīšanās balstītām metodēm, veidojot prognozējošus modeļus un pārbaudot, vai iepriekšējā apakšnodaļā noteiktie faktori ietekmē indivīda e-iekļautību. Apakšnodaļas ietvaros ir raksturoti pētījumu dalībnieki, aprakstītas datu ieguves metodes, kā arī dotas pazīmes un mainīgie, kas atbilst iepriekš noteiktajiem faktoriem un kas tiks izmantoti prognozējošo modeļu izveidē.


Pētījumu dalībnieki: Ģenerālās kopas raksturojums un pētījuma dalībnieku (izlases) formālais raksturojums

Pētījuma ģenerālā kopa ir Latvijas profesionālo izglītības iestāžu pedagogi. Atbilstoši Izglītības un zinātnes ministrijas datiem kopējais profesionālo izglītības iestāžu pedagogu skaits 2011./2012. mācību gadā, kad autore veica pētījumu, ir 4168 (IZM, 2014). Kā liecina Centrālās statistikas pārvaldes dati, Latvijā 2011./2012. mācību gadā, ir 3102 pedagoģiskie darbinieki pamatdarbā 65 profesionālās izglītības iestādēs (CSP, 2014). Šajās iestādēs mācās 34 638 audzēkņi, kas pedagogu vadībā apgūst vispārējo izglītību, humanitārās zinātnes un mākslu, sociālās zinātnes un komercdarbību, dabas zinātnes un informācijas tehnoloģijas, inženierzinātnes, lauksaimniecību, ražošanu un būvniecību, veselības aprūpi un sociālo labklājību. Profesionālās izglītības iestādes atrodas visos Latvijas reģionos – Vidzemē, Latgalē, Kurzemē, Zemgalē un Rīgas reģionā.

Autore pētījuma vajadzībām veido varbūtisko izlasi no profesionālo izglītības iestāžu pedagogiem, kas Eiropas Sociālā fonda projekta "Profesionālo mācību priekšmetu pedagogu un prakses vadītāju teorētisko zināšanu un praktisko kompetenču paaugstināšana" ietvaros apguva moduli „Informācijas tehnoloģiju prasmju kompetenču paaugstināšana”.


Tā kā autore pētījumu veic ģenerālajā kopā, kas pārsniedz 4000, bet ir mazāka par 5000, tad pie 95 % ticamības (5 % izlases kļūda) atbilstīgās izlases apjomam ir jābūt 370 (Mārtinsone, 2011). Šajā promocijas darbā pētījumā iesaistīti 767 profesionālo izglītības iestāžu pedagogi no 2400 projekta dalībniekiem, kas apguva moduli „Informācijas tehnoloģiju prasmju kompetenču paaugstināšana” laika posmā no 2011. gada novembra līdz 2012. gada maijam. Šis respondentu skaits ir pietiekams pieļaujamās izlases kļūdas robežās (Mārtinsone, 2011).

Pētījumā piedalījās 492 sievietes un 275 vīrieši (3.1. att.). 64 % no kopējā respondentu skaita bija sievietes, 36 % – vīrieši. No Izglītības un zinātnes ministrijas datiem izriet, ka 2011./2012. mācību gadā 70 % no pedagogiem bija sievietes, 30 % vīrieši (IZM, 2014). Līdz ar to, var secināt, ka izlasē ir līdzīgs dzimumus sadalījums kā ģenerālkopā.



3.1. att. Respondentu skaits atbilstoši dzimumam.

Kā redzams 3.2. attēlā, visvairāk pētījuma dalībnieku – 418 bija vecuma grupā no 46 līdz 65 gadiem, tie veido 54 % no kopējā dalībnieku skaita. Tad seko vecuma grupa no 26 līdz 45 gadiem ar 297 dalībniekiem, kas sastāda 39 % no kopējā skaita. Vecuma grupa no 17 līdz 25 gadiem piedalījās 30 pārstāvji, kas ir 4 % no kopējā skaita, bet vecāki par 66 gadiem bija 22 dalībnieki – 3 % no kopējā skata. Izglītības un zinātnes ministrijas publicētie dati līdzīgās vecuma grupās raksturo tikai pamatdarbā esošo pedagogu sadalījumu 2011./2012. mācību gadā un tas ir procentuāli līdzīgs kā izlasei (IZM, 2014). Visvairāk pedagogu ir vecuma grupā no 45 līdz 64 gadiem – 56 %, tad seko vecuma grupa no 25 līdz 44 gadiem – 34%. Līdzīgi kā izlasē jaunākajā un vecākajā vecuma grupā ir mazāk dalībnieku, attiecīgi – 2% pedagogu ir vecuma grupā no 17 līdz 24 gadiem, bet vecāki par 65 gadiem ir 8 %. Tādējādi var secināt, ka izlasē ir līdzīgs vecumu sadalījums kā ģenerālkopā.



3.2. att. Respondentu skaits atbilstoši vecumu diapazonam.

Izlasē iekļautie pedagogi pārstāv dažādus Latvijas reģionus un pasniedz dažādus mācību

priekšmetus.

Ņemot vērā izlases izvēles metodi, dalībnieku skaitu un raksturojumu, var uzskatīt, ka izlase ir reprezentatīva.

Jāatzīmē, ka atsevišķiem promocijas darba pētījumiem izlases dati tika papildināti ar datiem, kas iegūti no 160 profesionālo izglītības iestāžu pedagogiem, kas laika posmā no 2014. gada līdz 2016. gadam apguva mācību programmas "Mūsdienu interešu izglītība" trīs kursus: mobilās tehnoloģijas; robotika; video tehnoloģijas un dizains.

Digitālo prasmju apguves moduļu, kursu un tēmu raksturojums

Profesionālo izglītības iestāžu pedagogi digitālās prasmes apguva instruktora vadībā klātienē nodarbībās un attālināti no mācību materiāliem, kas bija ievietoti Moodle platformā. Digitālo prasmju pilnveidei pedagogi apguva moduli „Informācijas tehnoloģiju prasmju kompetenču paaugstināšana”, kura saturs atbilst ES ieteikumiem par būtiskākām digitālajām prasmēm (*Ferrari, 2013*). Promocijas darbā ir analizētas desmit moduļa tēmas: perifērijas iekārtu uzstādīšana; attēlu skenēšana; tīmekļa lapas izveide; *PDF* failu izveide un lietošana; drošība; datu bāzu vadības sistēmas *MS Access* pamati; video apstrāde; e-studijas pasaulē; sociālie tīkli; e-pasta lietošana. Katra tēma ietvēra teorētisko materiālu video un teksta formātā, kā arī zināšanu novērtēšanas testus. Papildus katrā tēmā bija ievietoti praktiski uzdevumi, lai nostiprinātu iegūtās zināšanas. Pirms un pēc katras tēmas, kā arī kursa sākumā un beigās bija ievietotas studentu pašvērtējumu aptaujas anketas.

Kā arī dati tika iegūti no mācību programmas "Mūsdienu interešu izglītība" trīs kursiem: mobilās tehnoloģijas; robotika; video tehnoloģijas un dizains.

Datu ieguves metodes

Pētījumiem dati tika iegūti divās kārtās par diviem dažādiem digitālo prasmju apguves moduļiem. Vispirms tika iegūti dati par moduli „Informācijas tehnoloģiju prasmju kompetenču paaugstināšana”, pēc tam tika iegūti dati par mācību programmu "Mūsdienu interešu izglītība".

Datu ieguve par moduli „Informācijas tehnoloģiju prasmju kompetenču paaugstināšana”

Autore kā datu ieguves metodi izmantoja 25 aptaujas, kas ir piemērots atgriezeniskās saites veids, lai uzlabotu studentu mācību sasniegumus (*Prokofyeva u. c., 2019*). 24 aptaujas anketas tika ievietotas Moodle sistēmā mācību kursā, kuru apguva profesionālo skolu pedagogi. Dati tika iegūti no 2011. gada novembra līdz 2012. gada maijam. Savukārt telefonaptauja par digitālo prasmju lietošanu profesionālām vai privātām vajadzībām pēc kursa apguves tika veikta no 2012. gada marta līdz maijam.

Respondentiem dažādu aptaujas anketu aizpilde, kas bija nepieciešama pētījumam, nebija obligāta. Līdz ar to respondentu skaits dažādām aptaujas anketām ir atšķirīgs. Aptaujas anketu nosaukumi, anketas apraksts un respondentu skaits ir dots 3.1. tabulā.

Respondentu skaits aptaujas anketām.

N.p.k.	Anketas nosaukums	Anketas apraksts	Respondentu skaits
1.	Aptauja pirms moduļa apguves	Novērtējums pirms moduļa apguves	647
2.	Aptauja pirms tēmas apguves: Perifērijas iekārtu pieslēgšana	Prasmju pašvērtējums pirms tēmas apguves	533
3.	Aptauja pēc tēmas apguves: Perifērijas iekārtu pieslēgšana	Prasmju pašvērtējums pēc tēmas apguves. Tēmas materiālu novērtējums.	376
4.	Aptauja pirms tēmas apguves: Darbs ar skeneri	Prasmju pašvērtējums pirms tēmas apguves	409
5.	Aptauja pēc tēmas apguves: Darbs ar skeneri	Prasmju pašvērtējums pēc tēmas apguves. Tēmas materiālu novērtējums.	330
6.	Aptauja pirms tēmas apguves: E-pasts	Prasmju pašvērtējums pirms tēmas apguves	383
7.	Aptauja pēc tēmas apguves: E-pasts	Prasmju pašvērtējums pēc tēmas apguves. Tēmas materiālu novērtējums.	316
8.	Aptauja pirms tēmas apguves: Mājas lapas izveides pamati un publicēšana	Prasmju pašvērtējums pirms tēmas apguves	320
9.	Aptauja pēc tēmas apguves: Mājas lapas izveides pamati un publicēšana	Prasmju pašvērtējums pēc tēmas apguves. Tēmas materiālu novērtējums.	244
10.	Aptauja pirms tēmas apguves: PDF formāta faili	Prasmju pašvērtējums pirms tēmas apguves	311
11.	Aptauja pēc tēmas apguves: <i>PDF</i> formāta faili	Prasmju pašvērtējums pēc tēmas apguves. Tēmas materiālu novērtējums.	274
12.	Aptauja pirms tēmas apguves: Drošs darbs ar datoru	Prasmju pašvērtējums pirms tēmas apguves	313
13.	Aptauja pēc tēmas apguves: Drošs darbs ar datoru	Prasmju pašvērtējums pēc tēmas apguves. Tēmas materiālu novērtējums.	259
14.	Aptauja pirms tēmas apguves: Iemaņas darbā ar <i>DBVS Access</i> datu bāzi	Prasmju pašvērtējums pirms tēmas apguves	261
15.	Aptauja pēc tēmas apguves: Iemaņas darbā ar <i>DBVS Access</i> datu bāzi	Prasmju pašvērtējums pēc tēmas apguves. Tēmas materiālu novērtējums.	228
16.	Aptauja pirms tēmas apguves: Video apstrāde	Prasmju pašvērtējums pirms tēmas apguves	281

N.p.k.	Anketas nosaukums	Anketas apraksts	Respondentu skaits
17.	Aptauja pēc tēmas apguves: Video apstrāde	Prasmju pašvērtējums pēc tēmas apguves. Tēmas materiālu novērtējums.	247
18.	Aptauja pirms tēmas apguves: E-studiju kursi internetā pasaulē	Prasmju pašvērtējums pirms tēmas apguves	278
19.	Aptauja pēc tēmas apguves: E-studiju kursi internetā pasaulē	Prasmju pašvērtējums pēc tēmas apguves. Tēmas materiālu novērtējums.	236
20.	Aptauja pirms tēmas apguves: <i>Excel</i>	Prasmju pašvērtējums pirms tēmas apguves	295
21.	Aptauja pēc tēmas apguves: <i>Excel</i>	Prasmju pašvērtējums pēc tēmas apguves. Tēmas materiālu novērtējums.	253
22.	Aptauja pirms tēmas apguves: Sociālie tīkli	Prasmju pašvērtējums pirms tēmas apguves	298
23.	Aptauja pēc tēmas apguves: Sociālie tīkli	Prasmju pašvērtējums pēc tēmas apguves. Tēmas materiālu novērtējums.	272
24.	Aptauja pēc moduļa apguves	Kursa novērtējums	498
25.	Aptauja par jauniegūto digitālo prasmju lietošanu	Jauniegūto digitālo prasmju lietošanas novērtējums pēc kursa apguves	150

Pētījumā izmantoto aptauju raksturojums (Mārtinsone, 2011):

1) forma:

- 1 mutiskā telefonaptauja;
- 24 rakstiskās ievietotas e-mācību vidē *Moodle*.

2) distance starp pētnieku un pētāmo: neklātiene.

3) procedūra: grupveida aptaujas.

Anketu izmēģināšanu autore veica 2010. gada novembrī ar 12 profesionālo skolu pedagogiem.

3.2. tabulā ir atspoguļoti pētījumā izmantotie pieci aptaujas anketu veidi un norādīts aptaujas veikšanas laiks kursā. Katram aptaujas anketas veidam ir dots skaits, kādi dati tiek iegūti aptaujā, kādi jautājuma veidi izmantoti un atbilstošā datu mērījumu skala (aptaujas anketu paraugi pievienoti 6. pielikumā).

Aptaujas anketu veidi, norises laiks, skaits, iegūtie dati un atbilstošā mērījumu skala.

Aptaujas veids un norises laiks pētījumā	Aptauju skaits	Iegūtie dati	Jautājumu veids	Skala
I. Aptauja pirms moduļa apguves	1	Demogrāfiskā informācija: vecums, dzimums, atbilstība kādai no e-iekļaušanas riska grupām, nodarbošanās veids	Slēgtie jautājumi	Nominālā skala
		Studenta pašvērtējums vēlmei apgūt kursu	Slēgtie jautājumi	Likerta skala, iespējamās atbildes ir no 1- pilnībā nepiekrītu līdz 5 – pilnībā piekrītu)
		Studenta pašvērtējums savām datorprasmēm	Slēgtie jautājumi	Likerta skala, iespējamās atbildes ir no 1- pilnībā nepiekrītu līdz 5 – pilnībā piekrītu)
		Studenta pašvērtējums savām interneta prasmēm	Slēgtie jautājumi	Likerta skala, iespējamās atbildes ir no 1- pilnībā nepiekrītu līdz 5 – pilnībā piekrītu)
II. Aptauja pirms katras tēmas apguves	11	Studenta pašvērtējums savām zināšanām atbilstošai tēmai pirms tēmas apguves	Slēgtie jautājumi	Likerta skala, iespējamās atbildes ir no 1- pilnībā nepiekrītu līdz 5 – pilnībā piekrītu)
		Informācija, ko students vēlētos apgūt šajā tēmā	Neobligāts, atvērts jautājums	
III. Aptauja pēc katras tēmas apguves	11	Studenta pašvērtējums savām zināšanām atbilstošai tēmai pēc tēmas apguves	Slēgtie jautājumi	Likerta skala, iespējamās atbildes ir no 1- pilnībā nepiekrītu līdz 5 – pilnībā piekrītu)
		Tēmas materiālu novērtējums		Likerta skala, iespējamās atbildes ir no 1- pilnībā nepiekrītu līdz 5 – pilnībā piekrītu), daļai jautājumu iespējamās atbildes ir 1-mazāk, 2-nemainīt, 3-vairāk
		Informācija, kādas jaunas zināšanas students ir ieguvis šajā tēmā	Neobligāts, atvērts jautājums	
IV. Aptauja pēc moduļa apguves	1	Vērtējums pasniedzēja ieinteresētībai dalīties ar zināšanām	Slēgtie jautājumi	Likerta skala, iespējamās atbildes ir no 1- pilnībā nepiekrītu līdz 5 – pilnībā piekrītu)
		Kursa norises novērtējums	Slēgtie jautājumi	Likerta skala, iespējamās atbildes ir no 1- pilnībā

				nepiekrītu līdz 5 – pilnībā piekrītu)
		E-vides novērtējums	Slēgtie jautājumi	Likerta skala, iespējamās atbildes ir no 1- pilnībā nepiekrītu līdz 5 – pilnībā piekrītu)
		Studenta prognoze, kuru kursa tēmu zināšanas un prasmes students plāno turpmāk izmantot personiskām vai profesionālām vajadzībām	Slēgtie jautājumi	Likerta skala, iespējamās atbildes ir no 1- pilnībā nepiekrītu līdz 5 – pilnībā piekrītu)
		Ieteikumi trūkstošām tēmām	Neobligāts, atvērts jautājums	
		Ieteikumi kursa pilnveidei	Neobligāts, atvērts jautājums	
V. Aptauja par jauniegūto digitālo prasmju lietošanu 4 līdz 8 nedēļas vai 6 mēnešus pēc kursa pabeigšanas	1	Jauniegūto digitālo prasmju lietošanas novērtējums	Slēgtie jautājumi	Nominālā skala

Jāatzīmē, ka ne visi aptaujās iegūtie dati tika izmantoti promocijas darbā aprakstītajiem pētījumiem. Daļa datu izmantoti, pētījumiem, kas nav iekļauti promocijas darbā.

Kā arī jānorāda, ka, dati, kas raksturo kādu studenta īpašību, ir iegūti aptaujās uzdodot vairākus jautājumus, nevis vienu. Piemēram, lai noskaidrotu studenta pašvērtējumu savām zināšanām pirms tēmas apguves, aptaujas anketās ir uzdoti astoņi jautājumi. Tas nozīmē, ka viena mainīgā vērtību veido dati, kas iegūti, apvienojot datus no vairākiem Likerta skalas jautājumiem.

Lai iegūtos datus izmantotu mainīgo vidējo vērtību, standartnovirzes un Pīrsona korelāciju aprēķiniem, datiem ir jābūt intervāla skalā un jāatbilst normālsadalījumam (*Creswell*, 2013, 199 lpp; *Mārtinsons*, 2011, 209 lpp.).

Pētījumos ir norādīts, ka ar Likerta skalas jautājumiem iegūtās vērtības var uzskatīt kā piederošas intervāla skalai, ja tiek pieņemts, ka distance starp atbilžu vērtībām ir vienāda un ir spēkā normālsadalījums mainīgo raksturojošajai datu kopai (*Creswell*, 2013, 176 lpp.). *Normans (Norman)* ir apkopojis pētījumus par to, ka ar Likerta skalas jautājumiem iegūtie dati ir izmantojami parametriskiem testiem, tai skaitā Pīrsona korelāciju aprēķiniem (*Norman*, 2010). Likerta skalas dati un to lietošana Pīrsona korelāciju aprēķiniem ir pieeja, kas tiek izmantota studentus raksturojošos pētījumos, piemēram, studentu attieksmes, mācību pieejas un studenta apmierinātības līmeņa saistības noteikšanai izglītības procesā (*Dominguez* u.c., 2019; *Xue* un *Lu*, 2021).

Promocijas darba pētījumos tiek pieņemts, ka distance starp Likerta skalas jautājumu

atbilžu vērtībām ir vienāda. 3.3. apakšnodaļā autore pārbauda mainīgo atbilstību normālsadalījumam, lai pamatotu, ka mainīgo raksturošanai ir iespējams izmantot to vidējās vērtības, standartnovirzi, bet saistību raksturošanai starp diviem mainīgajiem iespējams izmantot Pīrsona korelāciju aprēķinus.

Datu ieguve par mācību programmu “Mūsdienu interešu izglītība”

Dati mācību programmas “Mūsdienu interešu izglītība” kursiem tika iegūti laikā no 2014. gada līdz 2016. gadam. Līdzīgi kā modulim “Informācijas tehnoloģiju prasmju kompetenču paaugstināšana” datu ieguvei tika izmantotas Moodle platformāursos izvietotas aptaujas. Aptauju jautājumi tika veidoti līdzīgi kā modulim “Informācijas tehnoloģiju prasmju kompetenču paaugstināšana”. Aptaujas tika izvietotas pirms un pēc kursu tēmu apguves, kopā sešas aptaujas. Pēc kursa apguves studentiem tika nosūtīts e-pasts ar aptauju (veidota ar *Google* rīkiem) par digitālo prasmju lietošanu profesionālām vai privātām vajadzībām. Aptauju aizpilde nebija obligāta.

Pētījumos izmantoto mainīgo un atribūtu raksturojums

Neatkarīgie mainīgie. Vadoties no 3.1. nodaļā apskatītās teorijas, autore e-iekļaušanas procesa raksturošanai izmanto divus faktoros un tiem atbilstošus neatkarīgos mainīgos, kas doti 3.3. tabulā.

3.3. tabula

E-iekļaušanas procesu raksturojošie faktori un tiem atbilstošie neatkarīgie mainīgie.

Faktors	Neatkarīgais mainīgais, tā saīsinājums	Datu ieguve atbilstoši 3.2. tabulai
I. Instruktora vēlme un spēja dalīties ar zināšanām	<u>Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām, IWS.</u> Mainīgā vērtība tiek iegūta no studenta atbildes uz jautājumu par instruktora ieinteresētību, atsaucību mācību procesa laikā. Mainīgā vērtība: no 1 (ļoti zema) līdz 5 (ļoti augsta).	IV. Aptauja pēc kursa apguves
	<u>Studenta vērtējums apmierinātībai ar e-materiāliem, ELM.</u> Mainīgā vērtība tiek iegūta no studenta atbildēm uz jautājumiem par apmierinātību ar konkrētās tēmas video materiālu, teksta materiālu, pastāvīgā darba uzdevumiem un vingrinājumiem, testu un ceļvedi kā apgūt tēmas materiālus. Mainīgā vērtība: no 1 (pilnībā neapmierināts) līdz 5 (pilnībā apmierināts).	III. Aptauja pēc katras tēmas apguves
	<u>Studenta vērtējums apmierinātībai ar e-vidi, ELE.</u> Mainīgā vērtība tiek iegūta no studenta atbildēm par apmierinātību ar e-vides navigāciju, iespēju sameklēt vajadzīgos materiālus. Mainīgā vērtība: no 1 (pilnībā neapmierināts) līdz 5 (pilnībā apmierināts).	III. Aptauja pēc katras tēmas apguves
II. Studenta vēlme un spējas mācīties	<u>Studenta vērtējums savai vēlmei mācīties, SWL.</u> Mainīgā vērtība tiek iegūta summējot studenta vērtējumus tā motivācijai (profesionāla, personīga, intelektuāla, sociāla) apgūt kursa tēmas. Mainīgā vērtība: no 1 (pilnībā nav vēlmes) līdz 5 (izteikta vēlme).	I. Aptauja pirms kursa apguves
	<u>Studenta spējas mācīties, SAL.</u> Mainīgā vērtība tiek interpretēta kā studenta procentuālais zināšanu līmeņa pieaugums. Vērtības ieguvei izmanto datus par studenta zināšanu līmeni pirms un pēc tēmas apguves, kā arī maksimāli iespējamo zināšanu līmeņa pieaugumu. Mainīgā vērtība: no 0 % (nav spēju) līdz 100 % (izcilas spējas).	II. Aptauja pirms tēmas apguves III. Aptauja pēc katras tēmas apguves

Papildus iepriekš minētajiem neatkarīgajiem mainīgajiem autore pētījumā izmanto vēl šādu mainīgo: studenta vispārīgās digitālās prasmes, DS.

Šī mainīgā vērtība tiek iegūta no studenta pašvērtējuma savām digitālām un interneta prasmēm. Jautājumi par studenta digitālo un interneta prasmju līmeni ir sagatavoti atbilstoši Digitālās programmas indikatoriem (*European Commission, 2014*). Individā vispārējās digitālās prasmes kā prediktors digitālo rīku lietojumam tiek norādīts literatūrā pieejamos pētījumos (*Verhoeven u. c., 2020*). Dati šim mainīgajam tiek iegūti ar aptauja pirms kursa apguves (skat. 3.2. tabulu). Mainīgā vērtība: no 0 (nav prasmju) līdz 1 (izcilas prasmes). Mainīgā vērtība tika mērogota no 1 līdz 5.

3.4. tabula

Atkarīgo mainīgo raksturojums.

Atkarīgais mainīgais, tā saīsinājums	Datu ieguves veids atbilstoši 3.2. tabulai
<u>Studenta prognoze</u> par to, vai pēc kursa pabeigšanas apgūtās prasmes students izmantos profesionālām vai privātām vajadzībām, <i>PU</i> Šī mainīgā vērtība tiek iegūta no studenta pašvērtējuma par katrā kursa tēma jauniegūto prasmju lietošanu pēc kursa apguves beigām. Mainīgā vērtība: no 1 (pilnībā nepiekrītu) līdz 5 (pilnībā piekrītu).	IV. Aptauja pēc kursa apguves
<u>Novērotā prasmju lietošana, OU</u> . Šī mainīgā vērtība tiek iegūta, ņemot vērā studenta pašvērtējumu par jauniegūto prasmju lietošanu pēc kursa pabeigšanas. Mainīgajam ir trīs iespējamās vērtības: 0 – Nē, neesmu vispār izmantojis/usi ar šo tēmu saistītas prasmes. 1 – Nē, bet izmantoju prasmes tādā pašā līmenī kā pirms kursa apguves. 2 – Jā, izmantoju jaunapgūtās prasmes. Mainīgā vērtība saskaņā ar pētījumos lietotās datu analīzes metodes prasībām tiek mērogota atbilstoši jaunapgūto prasmju intensitātei, tādējādi iegūstot skaitliska tipa mainīgo.	V. Aptauja par jauniegūto digitālo prasmju lietošanu atkarībā no kursa veida 4 līdz 8 nedēļas pēc kursa pabeigšanas vai līdz 6 mēnešiem pēc kursa beigšanas.
<u>Iespējamā prasmju lietošana, PU&OU</u> . Šī mainīgā vērtība tiek iegūta, kombinējot mainīgo “Studenta prognoze” un “Novērotā prasmju lietošana” vērtības. Mainīgā vērtība: no 1 (nepastāv iespējamība) līdz 7 (pastāv droša iespējamība). Mainīgā vērtība daļai pētījumu tika mērogota no 1 līdz 5.	IV. Aptauja pēc kursa apguves V. Aptauja par jauniegūto digitālo prasmju lietošanu atkarībā no kursa veida 4 līdz 8 nedēļas pēc kursa pabeigšanas vai līdz 6 mēnešiem pēc kursa pabeigšanas.

Atkarīgie mainīgie. Lai noteiktu individā e-iekļautības pakāpi e-iekļaušanas procesā, autore izmanto vairākus raksturlielumus, kas raksturo individā e-iekļautību: studenta prognozi par jaunapgūto prasmju lietošanu, novēroto prasmju lietošanu, iespējamo prasmju lietošanu. Informāciju par studentu prognozi jaunapgūto prasmju lietošanā par būtisku uzskata dažādu tiešsaistes kursu organizētāji (*Future Learn, 2020*), prognoze par digitālo tehnoloģiju lietojumu tiek izmantota pētījumos, lai noteiktu individuā digitālās prasmes (*Kreijns u. c., 2014*). Mainīgie, kas raksturo individā e-iekļautības pakāpi, apkopoti 3.4. tabulā.

Sagatavotās datu kopas pētījumiem

1. pētījums (3.3. apakšnodaļa). Lineārās regresijas pieejā balstīta e-iekļaušanu prognozējošā modeļa izveide un prognozi ietekmējošo faktoru izvērtējums. Pētījumā

katrai moduļa „Informācijas tehnoloģiju prasmju kompetenču paaugstināšana” tēmai veidota sava datu kopa, kopumā izveidotas desmit datu kopas (3.5. tab.).

3.5. tabula

Datu kopas atbilstoši tēmai korelāciju meklēšanai un lineārās regresijas modeļu veidošanai.

Datu kopas Nr.	Tēma	Ierakstu skaits
1.	Perifērijas iekārtu pieslēgšana	86
2.	Darbs ar skeneri	74
3.	E-pasts	73
4.	Video apstrāde	73
5.	PDF formāta faili	71
6.	Sociālie tīkli	71
7.	E-studiju kursi internetā pasaulē	70
8.	Drošs darbs ar datoru	66
9.	Iemaņas darbā ar <i>DBVS Access</i> datu bāzi	65
10.	Mājas lapas izveides pamati un publicēšana	62

Datu kopas mainīgie un to iespējamās vērtības dotas 3.6. tabulā.

3.6. tabula

Korelāciju un lineārās regresijas pētījumu datu kopas mainīgie un to iespējamo vērtību raksturojums.

Mainīgais	Mainīgā vērtības
Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām, <i>IWS</i>	Skaitlis no 1 līdz 5
Studenta vērtējums apmierinātībai ar e-materiāliem, <i>ELM</i>	Skaitlis no 1 līdz 5
Studenta vērtējums apmierinātībai ar e-vidi, <i>ELE</i>	Skaitlis no 1 līdz 5
Studenta vērtējums savai vēlmei mācīties, <i>SWL</i>	Skaitlis no 1 līdz 5
Studenta spējas mācīties, <i>SAL</i>	Skaitlis no 1 līdz 5
Studenta prognoze par to, vai pēc kursa pabeigšanas apgūtās prasmes students izmantos profesionālām vai privātām vajadzībām, <i>PU</i>	Skaitlis no 1 līdz 5
Novērotā prasmju lietošana, <i>OU</i>	Mainīgā vērtība saskaņā ar pētījumos lietotās datu analīzes metodes prasībām tiek mērogota atbilstoši jaunapgūto prasmju intensitātei, tādējādi iegūstot skaitliska tipa mainīgo ar skaitliskām vērtībām no 0 līdz 2 vai 1 līdz 5 atkarībā no konkrētā pētījuma nosacījumiem.
Iespējamā prasmju lietošana, <i>PU&OU</i>	Skaitlis no 1 līdz 7 vai mērogots skaitlis no 1 līdz 5

2. pētījums (3.4. apakšnodaļa). Individā e-iekļautību raksturojošu klasteru izveide un e-iekļautību ietekmējošo faktoru atšķirību izvērtējums klasteros. Klasteranalīzei izmantota datu kopa, kas veidota, apvienojot ierakstus no moduļa „Informācijas tehnoloģiju prasmju kompetenču paaugstināšana” 11 tēmām. 1. pētījuma tēmas papildinātas ar tēmu par MS Excel programmatūru. Klasteranalīzes datu kopa satur 916 ierakstus. Datu kopas mainīgie un to iespējamās vērtības ir vienādas ar korelāciju un lineārās regresijas pētījumā izmantotajām (3.6. tabula). Bet ir šādas atšķirības:

1) papildus tiek izmantots mainīgais – “Studenta vispārīgās digitālās prasmes”, *DS*, tā vērtība ir skaitlis no 0 līdz 1;

2) netiek izmantots mainīgais – “Iespējamā prasmju lietošana”, *PU&OU*.

3. pētījums (3.5. apakšnodaļa). Individā e-iekļautības modelēšana ar klasifikācijas algoritmiem un e-iekļautības faktoriem. Autore sagatavoja divpadsmit atšķirīgas datu kopas e-iekļautības prognozēšanai (3.7. tab.).

3.7. tabula

Klasifikācijas algoritmiem izmantotās datu kopas.

Datu kopas Nr.	Studentu raksturojums datu kopā	Līdzsvarotas vai nelīdzsvarotas datu kopas klases	Kurss	Ierakstu skaits
1.	Visi	Nelīdzsvarotas	Mobilās tehnoloģijas	58
2.	Visi	Nelīdzsvarotas	Robotika	84
3.	Visi	Nelīdzsvarotas	Video tehnoloģijas un dizains	82
4.	Visi	Līdzsvarotas	Mobilās tehnoloģijas	71
5.	Visi	Līdzsvarotas	Robotika	115
6.	Visi	Līdzsvarotas	Video tehnoloģijas un dizains	121
7.	Tikai tie, kam pieejamas tehnoloģijas	Nelīdzsvarotas	Mobilās tehnoloģijas	51
8.	Tikai tie, kam pieejamas tehnoloģijas	Nelīdzsvarotas	Robotika	39
9.	Tikai tie, kam pieejamas tehnoloģijas	Nelīdzsvarotas	Video tehnoloģijas un dizains	76
10.	Tikai tie, kam pieejamas tehnoloģijas	Līdzsvarotas	Mobilās tehnoloģijas	71
11.	Tikai tie, kam pieejamas tehnoloģijas	Līdzsvarotas	Robotika	57
12.	Tikai tie, kam pieejamas tehnoloģijas	Līdzsvarotas	Video tehnoloģijas un dizains	118

Datu kopas raksturo tas, par kādiem studentiem ir iekļauti dati kopā. Pirmā veida datu kopā bija iekļauti visi studenti, kas bija aizpildījuši visas tiem paredzētās aptaujas. Katram

kursam tika sagatavotas datu kopas ar šādu izglītojamo skaitu: video tehnoloģijas un dizaina kurss – 82 izglītojamo ieraksti; mobilo tehnoloģiju kurss – 58 izglītojamo ieraksti; robotikas kurss – 84 izglītojamo ieraksti. Šajā datu kopā ir visi studenti, tas nozīmē, ka tur ir iekļauti arī studenti, kuriem nav pieejamas tehnoloģijas tālākai jaunapgūto prasmju lietošanai (digitāli izslēgti indivīdi). Piemēram, ja izglītojamajam nav videokameras, lai pēc video tehnoloģiju un dizaina kursa pabeigšanas izmantotu jauniegūtās prasmes, tad izglītojamam ir objektīvs šķērslis būt e-iekļautam. Autore izveidoja vēl vienu datu kopas veidu, kas satur ierakstus tikai par tiem studentiem, kuriem bija pieejams tehniskais aprīkojums, lai izmantotu jauniegūtās prasmes. Studentiem vismazāk aprīkojums bija pieejams robotikas kursā iegūto prasmju izmantošanai, tikai 46,43 % studentu bija pieejami roboti (*Arduino* vai *LEGO MINDSTORMS*). Visvairāk studentiem bija pieejams aprīkojums, kas nepieciešams video tehnoloģiju kursā iegūto prasmju pielietojumam – 92,68 % studentu. 87,93 % studentu bija pieejams aprīkojums, kas nepieciešams mobilo tehnoloģiju kursā iegūto prasmju lietošanai.

Katra izglītojamā ieraksts datu kopā tika apzīmēts kā “e-iekļauts” vai “nav e-iekļauts”. Jāatzīmē, ka klasifikācijas algoritms kļūst mazāk efektīvs, ja datu sadalījums klasēs nav līdzsvarots. Autore salīdzināja pētījumā izmantoto datu ierakstu skaitu klasēs “e-iekļauts” (ja students izmanto jaunapgūtās digitālās prasmes pēc kursu pabeigšanas) un “nav e-iekļauts” (ja students izmanto jaunapgūtās digitālās prasmes pēc kursu pabeigšanas). Tika secināts, ka visosursos datu kopas bija nelīdzsvarotas, kas nozīmē, ka kādā no klasēm ir daudz vairāk klašu gadījumu (piemēru) nekā citā klasē (*Ling un Sheng, 2011*) (3.8. tab.).

Lai līdzsvarotu klases, pētījumā ar *SMOTE* (*Synthetic Minority Over-Sampling Technique*) tehniku tika ģenerēti minoritātes klases piemēri, izmantojot *WEKA* platformu (*Frank u. c., 2009*). Rezultātā tika iegūtas sešas līdzsvarotas datu kopas trim kursiem (video tehnoloģijas un dizains; mobilās tehnoloģijas; robotika) visiem studentiem un studentiem ar piekļuvi tehnoloģijām.

3.8. tabula

Izglītojamo sadalījums klasēs “e-iekļauts” un “nav e-iekļauts”.

Klase/ Kurss	Visi studenti			Studenti, kam ir pieejamas tehnoloģijas		
	Video tehnoloģijas un dizains	Mobilās tehnoloģijas	Robotika	Video tehnoloģijas un dizains	Mobilās tehnoloģijas	Robotika
“e-iekļauts”	71,95 %	65,52 %	33,33 %	77,63 %	74,51 %	71,79 %
“nav e-iekļauts”	28,05 %	34,48 %	66,67 %	22,37 %	25,49 %	28,21 %

Datu kopas atribūti (mainīgie) un to iespējamās vērtības ir dotas 3.6. tabulā, tomēr jāatzīmē, ka ir nelielas atšķirības:

1) Papildus tiek izmantots atribūts – “Studenta vispārīgās digitālās prasmes”, *DS*, tā vērtība ir skaitlis no 1 līdz 5;

2) Netiek izmantots atribūts – “Iespējamā prasmju lietošana”, *PU&OU*.

3) Atribūtam – “Novērotā prasmju lietošana”, *OU* ir divas iespējamās vērtības: 0 jeb “nav e-iekļauts”, ja studenta atbilde ir: “Nē, neesmu vispār izmantojis/usi ar šo tēmu saistītas prasmes”; 2 jeb “e-iekļauts”, ja studenta atbilde ir “Jā, izmantoju jaunapgūtās prasmes”.

4. pētījums (3.6. apakšnodaļa). Lineārās regresijas, klasteranalīzes un klasifikācijas pieeju apvienošana indivīda e-iekļaušanu prognozējošā modeļa izveidē. Viens no šī pētījuma uzdevumiem bija modeļa vispārināšana, lai to varētu piemērot dažādiem kursiem. Tāpēc atšķirībā no iepriekšējiem pētījumiem tika izveidota viena datu kopa no dažādiem kursiem un to tēmām. Iepriekš veiktajos pētījumos autore novēroja, ka indivīda e-iekļautības prognozes algoritmiem ir zemāki veikspējas rādītāji, ja datu kopā ir studenti, kam digitālo prasmju izmantošana nav iespējama, jo nav piekļuves vajadzīgajai tehnoloģijai. Tāpēc šajā pētījumā no datu kopas tika izslēgti tie studenti, kam nebija piekļuves tehnoloģijām. Rezultātā autore sagatavoja vienu datu kopu, kas satur 928 ierakstus gan no moduļa „Informācijas tehnoloģiju prasmju kompetenču paaugstināšana” tēmām, gan no mācību programmas “Mūsdienu interešu izglītība” kursiem.

Lineārās regresijas modelēšanai tiek izmantoti atribūti (mainīgie) un to iespējamās vērtības, kas ir dotas 3.6. tabulā, bet ir šādas atšķirības:

- netiek izmantots mainīgais – “Novērotā prasmju lietošana”, *OU*;
- netiek izmantots mainīgais – “Studenta prognoze” – vai pēc kursa pabeigšanas apgūtās prasmes students izmantos profesionālām vai privātām vajadzībām, *PU*.

Klasteranalīzei un klasifikācijas algoritmiem tiek izmantoti atribūti un to iespējamās vērtības, kas dotas 3.6. tabulā, bet ir šādas atšķirības:

1) Papildus tiek izmantots atribūts – “Studenta vispārīgās digitālās prasmes”, *DS*, tā vērtība ir skaitlis no 1 līdz 5.

2) Netiek izmantots atribūts – “Iespējamā prasmju lietošana”, *PU&OU*.

3) Atribūtam – “Novērotā prasmju lietošana”, *OU*, – ir divas iespējamās vērtības: 0 jeb “nav e-iekļauts”, ja studenta atbilde ir “Nē, neesmu vispār izmantojis/usi ar šo tēmu saistītas prasmes”; 2 jeb “e-iekļauts”, ja studenta atbilde ir “Jā, izmantoju jaunapgūtās prasmes”.

Datu kopā ir 435 izglītojamie, kuri atbilst klasei “nav e-iekļauts” un 493, kas atbilst klasei “e-iekļauts”. Tā kā katrā no klasēm dalībnieku skaits ir līdzīgs, pētījumā tiek uzskatīts, ka nav nepieciešams izmantot *SMOTE* tehnoloģiju, lai datu kopas līdzsvarotu.

3.3. Lineārās regresijas pieejā balstīta e-iekļaušanu prognozējošā modeļa izveide un prognozi ietekmējošo faktoru izvērtējums

Apakšnodaļas mērķis ir aprakstīt pētījumu, kurā ir pārbaudīts, cik lielā mērā iepriekš noteiktie e-iekļaušanu ietekmējošie faktori, izmantojot lineārās regresijas metodi, spēj paredzēt indivīda e-iekļautību.

Pētījuma mērķis un pētnieciskie jautājumi

Pētījuma mērķis ir pārbaudīt, cik lielā mērā ar lineārās regresijas modeli, izmantojot iepriekš noteiktos iespējamus e-iekļaušanas faktorus, kas raksturo zināšanu plūsmu starp instruktoru un indivīdu, var prognozēt e-iekļautības pakāpi profesionālo izglītības iestāžu pedagogiem, kuri apgūst digitālās prasmes instruktora vadībā e-vidē.

Pētījuma jautājumi:

1) cik lielā mērā pastāv saistība starp studenta vērtējumu instruktora vēlmei dalīties ar zināšanām un studenta e-iekļautības pakāpi;

2) cik lielā mērā pastāv saistība starp studenta apmierinātības līmeni ar e-mācību materiāliem un e-iekļautības pakāpi;

3) cik lielā mērā pastāv saistība starp studenta apmierinātības līmeni ar e-vidi un studenta e-iekļautības pakāpi;

4) cik lielā mērā pastāv saistība starp studenta vēlmi mācīties un studenta e-iekļautības pakāpi;

5) cik lielā mērā pastāv saistība starp studenta spējām mācīties un studenta e-iekļautības pakāpi;

6) cik lielā mērā ir iespējams prognozēt studenta e-iekļautības pakāpi, vadoties no studenta ieinteresētības līmeņa un spējām mācīties, studenta apmierinātības līmeņa ar e-mācību materiāliem un e-vidi un instruktora vēlmi dalīties ar zināšanām.

Pētījuma dalībnieki, izmantotie dati un datu analīzes metodes

Pētījuma dalībnieki ir profesionālo izglītības iestāžu pedagogi, kuri apgūst moduļa „Informācijas tehnoloģiju prasmju kompetenču paaugstināšana” desmit tēmas instruktora vadībā klātienē un attālinātās nodarbībās, izmantojot *Moodle* platformā izvietotus mācību materiālus.

Pētījumā izmantotais e-iekļaušanas faktors – instruktora vēlme un spēja dalīties ar zināšanām e-mācību kursa laikā – tiek mērīts ar trīs mainīgiem (iespējamās vērtības ir no 1 līdz 5):

1. “Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām”, *IWS*;
2. “Studenta vērtējums apmierinātībai ar e-materiāliem”, *ELM*;
3. “Studenta vērtējums apmierinātībai ar e-vidi”, *ELE*.

Pētījumā izmantotais e-iekļaušanas faktors – studenta vēlme un spējas apgūt digitālās prasmes e-mācību kursa laikā – tiek mērīts ar diviem mainīgiem (iespējamās vērtības ir no 1 līdz 5):

1. “Studenta vērtējums savai vēlmei mācīties”, *SWL*;
2. “Studenta spējas mācīties”, *SAL*.

Mainīgie, ar kuriem izteikti e-iekļaušanas faktori, šī pētījuma kontekstā tiek saukti par prediktoriem jeb faktoriālām pazīmēm.

E-iekļautības pakāpi autore nosaka, izmantojot trīs mainīgos:

1. “Studenta prognoze” - vai pēc kursa pabeigšanas apgūtās prasmes students izmantos profesionālām vai privātām vajadzībām, *PU*;
2. “Novērotā prasmju lietošana”, *OU*;
3. “Iespējamā prasmju lietošana”, *PU&OU*.

Mainīgie, ar kuriem izteikta e-iekļaušanas pakāpe, šī pētījuma kontekstā tiek saukti par rezultatīvo pazīmi.

Pētījuma dalībnieki, datu ieguves metodes un izmantotās datu kopas detalizētāk ir aprakstītas 3.1. un 3.2. apakšnodaļās.

Pirms sakarību noteikšanas starp e-iekļautības pakāpi un faktoriālajām pazīmēm, faktoriālās pazīmes tiek raksturotas ar pazīmju aritmētisko vidējo jeb vidējām vērtībām (*Means*) un to standartnovirzēm (*Standard Deviation*). Lai e-iekļautības pakāpi un faktoriālās pazīmes varētu raksturot ar to vidējo aritmētisko vērtību, to sadalījumam jāatbilst

normālsadalījumam, Puasona sadalījumam (liela mērījumu skaita gadījumā) vai binomiālajam, sadalījumam (piemēram, gamma sadalījumam pie atbilstošiem nosacījumiem) vai citam sadalījumam, kurš pieļauj parametra interpretāciju ar vidējo aritmētisko vērtību.

Lai noskaidrotu sakarības starp e-iekļautības faktoriem un e-iekļautības pakāpi, autore izmanto Pīrsona korelācijas koeficientu noteikšanu (*Creswell*, 2013). Lai veidotu e-iekļautību prognozējošo modeli un noskaidrotu e-iekļautības faktoru ietekmi uz e-iekļautības pakāpi, autore izmanto daudzfaktoru lineārās regresijas analīzi. Kā pamatojums Pīrsona korelācijas koeficientu noteikšanas iespējamībai ir mainīgo vērtību atbilstība normālajam sadalījumam. Datu analīze tika veikta, izmantojot *SPSS for Windows* (versija 19.0) programmatūru.

Sākotnēji izvirzīta hipotēze $H(0)$, ka e-iekļautības faktorus un e-iekļautības pakāpi raksturojošie mainīgie ar pietiekošu ticamību atbilst normālsadalījumam. Lai pārlicinātos, veikti neparametriskie normālsadalījuma statistiskie testi. To veikšanai tika izmantota statistisko datu apstrādes datorprogramma *SPSS*. Kvantitatīvam hipotēzes $H(0)$ apstiprinājumam veikts Kolmogorova-Smirnova tests. Normālsadalījuma apstiprinājumam šajos testos nepieciešams, lai nozīmīguma vērtība $Sig \geq 0,05$. Šis nosacījums izpildās mainīgajiem *SWL* (“Studenta vērtējums savai vēlmei mācīties”) un *SAL* (“Studenta spējas mācīties”), pārējiem mainīgajiem neizpildās, tādēļ hipotēze normālsadalījumam šiem e-iekļautības faktoriem un e-iekļautības pakāpei neapstiprinās.

Izvirzīta hipotēze $H(0)$ e-iekļautības faktoriem (*IWS* – “Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām”; *ELE* – “Studenta vērtējums apmierinātībai ar e-vidi”; *ELM* – “Studenta vērtējums apmierinātībai ar e-materiāliem”) un e-iekļautības pakāpei (*OU* – “Novērotā prasmju lietošana”; *PU* – “Prognozētā prasmju lietošana”; *PU&OU* – “Iespējamā prasmju lietošana”) sadalījums atbilst normālsadalījumam vai kādam no sadalījumiem, kuri pieļauj parametra interpretāciju ar vidējo aritmētisko vērtību. Lai pārbaudītu hipotēzi, tika izmantots hī kvadrāta kritērija atbilstības tests statistisko datu apstrādes programmā *EasyFit Professional* (versija 5.5.). Normālsadalījuma vai kāda no sadalījumiem, kuri pieļauj parametra interpretāciju ar vidējo aritmētisko vērtību apstiprinājumam šajos testos nepieciešams, lai nozīmīguma vērtība $Sig \geq 0,05$. Tika secināts, ka mainīgie atbilst normālsadalījumam vai kādam no sadalījumiem, kuri pieļauj parametra interpretāciju ar vidējo aritmētisko vērtību. Piemēri e-iekļautības faktoru un e-iekļautības pakāpes atbilstībai Kolmogorova-Smirnova testam vai hī-kvadrāta kritērija atbilstības testiem doti 7. pielikumā.

Rezultāti: aritmētiskais vidējais un standartnovirze e-iekļaušanas faktoru un e-iekļautības pakāpes mainīgajiem

3.9. tabulā faktoriālās pazīmes tiek raksturotas ar pazīmju aritmētisko vidējo jeb vidējām vērtībām (*Means*) un to standartnovirzēm (*Standard Deviation*), Atbilstoši mācību tēmai katram no pieciem iespējamiem prediktoriem kolonā ar nosaukumu M ir norādīta vidējā vērtība, kolonā ar nosaukumu SD – standartnovirze no vidējās vērtības.

Aritmētiskais vidējais un standartnovirze prediktoriem (faktoriālai pazīmei).

Tēma	Respon- dentu skaits	<i>IWS</i>		<i>ELM</i>		<i>ELE</i>		<i>SWL</i>		<i>SAL</i>	
		M	SD	M	SD	M	SD	M	SD	M	SD
Perifērijas iekārtu pieslēgšana	86	4,58	0,89	3,99	0,92	3,66	0,90	3,75	0,79	49,42	36,30
Darbs ar skeneri	74	4,57	0,85	3,92	0,72	3,60	0,92	3,69	0,79	48,40	37,83
E-pasts	73	4,60	0,83	4,14	0,92	3,71	0,91	3,78	0,77	54,16	39,32
Video apstrāde	73	4,63	0,79	4,06	0,86	3,72	0,89	3,82	0,77	46,06	33,68
<i>PDF</i> formāta faili	71	4,59	0,79	4,08	0,87	3,67	0,94	3,68	0,76	52,17	33,97
Sociālie tīkli	71	4,58	0,91	4,02	0,94	3,65	0,95	3,76	0,79	71,16	29,05
E-studiju kursi internetā pasaulē	70	4,63	0,80	3,99	0,98	3,70	0,93	3,79	0,78	47,07	38,42
Drošs darbs ar datoru	66	4,58	0,92	3,75	0,70	3,72	0,89	3,71	0,79	49,29	31,71
Iemaņas darbā ar <i>DBVS Access</i> datu bāzi	65	4,60	0,84	3,85	0,97	3,60	0,93	3,75	0,81	44,56	31,55
Mājas lapas izveides pamati un publicēšana	62	4,66	0,79	3,87	0,95	3,68	0,95	3,67	0,79	48,03	31,84

IWS – Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām. *ELM* – Studenta vērtējums apmierinātībai ar e-materiāliem. *ELE* – Studenta vērtējums apmierinātībai ar e-vidi. *SWL* – Studenta vērtējums savai vēlmei mācīties. *SAL* – Studenta spējas mācīties. M – vidējā vērtība. SD – standartnovirze.

Instruktoru ieinteresētība dalīties ar zināšanām (*IWS*). Vidējās vērtības studentu vērtējumam par instruktora vēlmi dalīties ar zināšanām dažādām tēmām ir robežās no 4,57 līdz 4,66 piecu baļļu skalā. Kā redzams, vidējās vērtības ir salīdzinoši augstas un līdzīgas visām kursa tēmām. Studentu vidējais vērtējums liecina par to, ka studenti piekrīt tam, ka instruktors ir ieinteresēts dalīties ar zināšanām. Atšķirība starp augstāko un zemāko vidējo vērtību ir 0,09. Standartnovirze ir robežās no 0,79 līdz 0,92. Vienveidīgāki, blīvāki instruktora vērtējumi ir tēmām, kur standartnovirze ir mazāka, tas ir, tēmām: video apstrāde: *PDF* formāta faili; e-studiju kursi internetā pasaulē. Vērtējumu izkliede ir lielākā tēmām: drošs darbs ar datoru; sociālie tīkli; perifērijas iekārtu pieslēgšana.

E-mācību materiāli (*ELM*). Vidējās vērtības studentu apmierinātības rādītājam ar e-mācību materiāliem ir zemākas nekā studentu vērtējums instruktora vēlmei dalīties ar

zināšanās. Kā redzams tabulā, vidējās vērtības studentu vērtējumam par e-mācību materiāliem dažādām tēmām ir robežās no 3,75 līdz 4,14 piecu baļļu skalā. Kā rāda studentu vērtējumi, tad studentu apmierinātība visās mācību tēmās ar materiāliem ir laba. Starpība starp zemāko vidējo vērtējumu un augstāko vidējo vērtējumu, atšķiras par 0,39. Atšķirība ir nedaudz lielāka nekā iepriekš minētajam instruktora vērtējumam, tomēr var uzskatīt, ka studentu vidējais vērtējums e-mācību materiāliem dažādām tēmām ir līdzīgs, vienas balles robežās, tas ir, vērtējums ir 4. Standartnovirze ir robežās no 0,70 līdz 0,98. Kā rāda standartnovirze, tad vienveidīgāki un blīvāki e-mācību materiālu vērtējumi ir tēmām: drošs darbs ar datoru; darbs ar skeneri. Lielākā vērtējumu izkliede ir tēmām: e-studiju kursi internetā pasaulē; iemaņas darbā ar *DBVS Access* datu bāzi.

E-vide (ELE). Savukārt vidējās vērtības studentu apmierinātībai ar e-vidi ir vēl zemākas par vidējām vērtībām studentu apmierinātībai ar e-materiāliem. Vidējās vērtības studentu apmierinātībai ar e-vidi dažādām tēmām ir robežās no 3,60 līdz 3,72 piecu baļļu skalā. Lai arī apmierinātība ar e-vidi ir zemāka, tomēr var uzskatīt, ka studenti drīzāk (ne pilnībā) piekrīt, ka e-vide ir atbilstoša viņu vajadzībām. Starpība starp zemāko vidējo vērtējumu un augstāko ir 0,12. Tā ir mazāka nekā iepriekš minētajam parametram – studentu apmierinātībai ar e-mācību materiāliem un lielāka nekā instruktora vēlmei dalīties ar zināšanām. Tātad var uzskatīt, ka visām tēmām vidējā vērtība studentu apmierinātībai ar e-vidi ir maz atšķirīga. Standartnovirze ir no 0,89 līdz 0,95, tā ir minimāli atšķirīga dažādām tēmām.

Studenta vēlme mācīties (SWL). Vidējās vērtības studentu vēlmei mācīties dažādām tēmām ir robežās no 3,67 līdz 3,82 piecu baļļu skalā. Kā rāda vidējās vērtības studentu vēlmei mācīties, tad tā ir salīdzinoši augsta, studenti drīzāk piekrīt (bet ne pilnībā), ka ir ieinteresēti apgūt kursa tēmas. Šīs vērtības ir augstākas par vidējām vērtībām studentu apmierinātībai ar e-vidi, bet zemākas par pārējo parametru – instruktora vēlmes dalīties ar zināšanām, e-mācību materiālu novērtējuma vidējām vērtībām dažādām tēmām. Standartnovirze ir no 0,76 līdz 0,81. Tā ir minimāli atšķirīga dažādām tēmām.

Studenta spēja mācīties (SAL). Vidējās vērtības studentu spējai mācīties dažādām tēmām ir robežās no 44,56 % līdz 71,16 % no 100 %. Standartnovirze ir robežas no 29,05 līdz 39,32. Augstākā vidējā vērtība 71,16 % ir spējai mācīties sociālo tīklu tēmā. Šai tēmai standartnovirze ir vismazākā, salīdzinot ar citām tēmām, tā ir – 29,05. Tas nozīmē, ka šai tēmai ir blīvāki, vienveidīgāki vērtējumi, salīdzinot ar citām tēmām. Tēmai par iemaņām darbā ar *DBVS Access* datu bāzi vidējā vērtība spējai mācīties ir viszemākā, tā ir 44,56 %. Šai tēmai standartnovirze ir 31,55, kas ir viena no mazākām. Vislielākā standartnovirze ir e-pasta tēmai – 39,32. Tas liecina, ka e-pasta tēmā studenta spējai mācīties vidējai vērtībai (54,16 %) ir vislielākā izkliede, ja salīdzina ar citām tēmām.

Līdzīgi kā faktoriālās pazīmes, autore raksturo rezultatīvo pazīmi – e-iekļautības pakāpi ar aritmētisko vidējo jeb vidējām vērtībām (*Means*) un to standartnovirzēm (*Standard Deviation*) (3.10. tab.). Atbilstoši mācību tēmai katram no trim e-iekļautības pakāpi raksturojošajiem mainīgajam kolonā ar nosaukumu M ir norādīta vidējā vērtība, kolonā ar nosaukumu SD – standartnovirze no vidējās vērtības.

3.10. tabulā ir dotas vidējās vērtības un standartnovirzes sekojošiem mainīgajiem: “Novērotā prasmju lietošana”; “Studenta prognoze”; “Iespējamā prasmju lietošana”. Kā redzams, vidējās vērtības dažādām tēmām studentu prognozei par jaunapgūto digitālo prasmju lietošanu ir robežās no 3,27 līdz 4,38 piecu baļļu skalā. Starpība starp augstāko vērtējumu e-pasta tēmai un zemāko vērtējumu tēmai par mājas lapas izveides pamatiem un publicēšanu ir

1,11. Vēl zema vidējā vērtība ir tēmai par *DBVS Access* datu bāzi – 3,46. Pārējām tēmām studentu prognozes vidējā vērtība ir tuvāk 4 nekā 3, tas ir, ka studenti prognozē, ka drīzāk lietos jaunapgūtās prasmes. Vidējā vērtība 3 norāda, ka studenti šaubās, vai lietos jauniegūtās prasmes. Standartnovirze studentu prognozei dažādām tēmām ir no 0,99 līdz 1,37. Mazākā standartnovirze 0,99 ir e-pasta tēmai, kur bija augstākā vidējā vērtība. Šai tēmai studentu prognožu vērtējumi ir blīvāki, koncentrētāki. Savukārt tēmai par mājas lapas izveides pamatiem un publicēšanu, kam vidējā vērtība viszemākā, standartnovirze ir vislielākā 1,37, tas liecina par to, ka studentu prognozes ir izkliedētākas.

3.10. tabula

Aritmētiskais vidējais un standartnovirze rezultatīvai pazīmei.

Tēma	PU		OU		PU&OU	
	M	SD	M	SD	M	SD
Perifērijas iekārtu pieslēgšana	3,87	1,17	3,35	1,41	3,61	1,03
Darbs ar skeneri	4,04	1,13	3,38	1,39	3,71	0,97
E-pasts	4,38	0,99	3,41	0,81	3,90	0,67
Video apstrāde	3,73	1,25	2,32	1,74	3,02	1,11
PDF formāta faili	3,97	1,13	3,00	1,69	3,49	1,17
Sociālie tīkli	3,86	1,30	2,58	1,35	3,22	1,00
E-studiju kursi internetā pasaulē	3,89	1,15	3,34	1,63	3,61	1,09
Drošs darbs ar datoru	4,23	1,06	3,21	1,53	3,72	0,96
Iemaņas darbā ar <i>DBVS Access</i> datu bāzi	3,46	1,25	1,80	1,49	2,63	1,09
Mājas lapas izveides pamati un publicēšana	3,27	1,37	1,77	1,42	2,52	1,08

PU – Studenta prognoze, vai pēc kursa pabeigšanas apgūtās prasmes students izmantos profesionālām vai privātām vajadzībām. *OU* – Novērotā prasmju lietošana studentam. *PU&OU* – Iespējamā prasmju lietošana studentam. M – vidējā vērtība. SD – standartnovirze.

Vidējās vērtības novērotai studentu jaunapgūto digitālo prasmju lietošanai katrai tēmai ir zemākas par vidējām vērtībām studentu prognozētai jaunapgūto digitālo prasmju lietošanai. Novērotās lietošanas vidējās vērtības ir robežās no 1,77 līdz 3,44 piecu baļļu skalā. Iegūtās vidējās vērtības norāda uz to, ka studenti jaunapgūtās prasmes drīzāk nelieto. Zemākais vidējais vērtējums ir tai pašai tēmai, kur zemākā vidējā prognozētās lietošanas vērtība, un tā ir tēma: mājas lapas izveides pamati un publicēšana. Augstākā vidējā vērtība ir e-pasta tēmai, kam bija augstākā vidējā vērtība studentu prognozei par lietošanu. Standartnovirze ir robežās no 0,81 līdz 1,74. Vismazāk izkliedētie novērotās lietošanas vērtējumi ir e-pasta tēmai. Vislielākā izkliede novērotās lietošanas vērtējumiem ir tēmai par video apstrādi.

Vidējās vērtības iespējamai lietošanai ir zemākas par prognozētās lietošanas vidējām vērtībām, bet augstākas par novērotās lietošanas vidējām vērtībām. Vidējās vērtības iespējamai lietošanai dažādām tēmām ir robežās no 2,52 līdz 3,90 piecu baļļu skalā. Zemākā vidējā vērtība atkal ir tēmai par mājas lapas izveides pamatiem un publicēšanu, bet augstākā – e-pasta tēmai. Iegūtās vidējās vērtības, kas ir tuvāk 3, liecina par to, ka par šīm tēmām

studenti nav pārliecināti vai lietos jauniegūtās prasmes. Tādas tēmas ir: sociālie tīkli, video apstrāde, mājas lapas izveides pamati un publicēšana, iemaņas darbā ar *DBVS Access* datu bāzi. Bet vērtējums, kas tuvāk 4 – norāda, ka šajās tēmas iegūto prasmju lietošanas iespējamība ir augstāka, kas nozīmē, ka studenti drīzāk tās lietos (nevis nelietos). Šādas tēmas ir sekojošas: e-pasts, perifērijas iekārtu pieslēgšana, darbs ar skeneri, PDF formāta faili, e-studiju kursi internetā pasaulē, drošs darbs ar datoru. Iespējamās lietošanas vidējo vērtību standartnovirze dažādām tēmām ir robežās no 0,67 (e-pasta tēmai) līdz 1,17 (tēmai par *PDF* formāta failiem).

3.3. attēls uzskatāmi parāda, ka katrai tēmai vidējās vērtības visaugstākās ir prognozētai lietošanai, bet viszemākās ir novērotai lietošanai. Nevienai tēmai vidējās vērtības novērotai lietošanai nav augstākas par prognozēto lietošanu, bet vienmēr ir zemākas. Tas liecina par to, ka studentu prognozes par jauniegūto digitālo prasmju lietošanu nenozīmē, ka tās reāli tiks izmantotas profesionālām vai privātām vajadzībām.



3.3. att. Vidējās vērtības rezultatīvai pazīmei – e-iekļautības pakāpei.

No iegūtajiem aprēķiniem var secināt, ka studentu prognozes pārsniedz reālo prasmju lietošanu, ja tiek skatītas vidējās vērtības tām. Jāatzīmē, ka prognozes ir atšķirīgas tēmām – ir tēmas, kur studenti ir pārliecinātāki, ka lietos jauniegūtās prasmes, bet ir tēmas, kur šaubās, vai lietos mācībās iegūtās prasmes. Rezultāti parāda, ka iespējams, ka jauniegūto prasmju lietošana tēmām, kur studentu prognozēm vērtības ir augstākas, ir izteiktāka. Pētījums parādīja, ka tēmas, pēc kuru apguves studenti profesionālajā darbībā nelieto jaunapgūtās prasmes, ir sarežģītākas un ikdienā retāk nepieciešamas, piemēram, tēmas par *MS Access*, par mājas lapu izveidi vai arī tēma par sociālajiem tīkliem, kas tieši nav saistīti ar pedagoga profesionālo pienākumu izpildi.

Rezultāti: saistības starp e-iekļaušanas faktoru un e-iekļautības pakāpes mainīgajiem noteikšana

Vispirms pētījumā tika veikta Pīrsona korelāciju korelāciju analīze un izslēgti tie neatkarīgie mainīgie, kuriem bija nenozīmīgas korelācijas ar e-iekļautības pakāpi raksturojošiem mainīgajiem. Korelācijas analīzes mērķis ir arī noteikt, starp kuriem prediktora mainīgajiem un rezultatīvās pazīmes mainīgajam pastāv saistība.

Saistība starp e-iekļaušanas faktora mainīgajiem un e-iekļautības pakāpi tiek noteikta secīgi katram no trim e-iekļautības pakāpi raksturojošam mainīgajam – (1) studenta prognozētā jaunapgūto prasmju lietošana; (2) iespējamā jaunapgūto prasmju lietošana; (3) novērotā jaunapgūto prasmju lietošana. Attiecīgi 3.11., 3.12., 3.13. tabulā ir redzami korelācijas koeficienti visām tēmām visiem mainīgajiem.

Korelācijas studenta prognozētai jaunapgūto prasmju lietošanai

Korelācijas studenta prognozētai jaunapgūto prasmju lietošanai un e-iekļaušanas faktoru mainīgajiem ir dotas 3.11. tabulā.

3.11. tabula

Pīrsona korelāciju koeficienti studenta prasmju prognozētajai lietošanai un identificētajiem prediktoriem (e-iekļaušanas faktoriem).

Tēma Prediktors	1. prediktors			2. prediktors	
	<i>IWS</i>	<i>ELM</i>	<i>ELE</i>	<i>SWL</i>	<i>SAL</i>
Perifērijas ierīču pieslēgšana	0,38(**)	0,56(**)	0,64(**)	0,38(**)	0,25(*)
Video apstrāde	0,33(**)	0,38(**)	0,40(**)	0,34(**)	0,27(*)
Sociālie tīkli	0,09	0,54(**)	0,34(**)	0,38(**)	0,39(**)
PDF formāta faili	0,31(**)	0,47(**)	0,49(**)	0,33(**)	0,37(**)
Iemaņas darbā ar <i>DBVS Access</i> datu bāzi	0,28(*)	0,49(**)	0,54(**)	0,25(*)	0,35(**)
Drošs darbs ar datoru	0,18	0,48(**)	0,35(**)	0,29(*)	0,44(**)
Darbs ar skeneri	0,34(**)	0,37(**)	0,53(**)	0,23(*)	0,26(*)
Mājas lapas izveides pamati un publicēšana	0,24	0,44(**)	0,36(**)	0,34(**)	0,36(**)
E-studiju kursi internetā pasaulē	0,32(**)	0,59(**)	0,38(**)	0,34(**)	0,47(**)
E-pasts	0,41(**)	0,60(**)	0,63(**)	0,30(**)	0,11
** Korelācija ir nozīmīga 0,01 vērtībai (2-daļīga) * Korelācija ir nozīmīga 0,05 vērtībai (2-daļīga) <i>IWS</i> – Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām. <i>ELM</i> – Studenta vērtējums apmierinātībai ar e-materiāliem. <i>ELE</i> – Studenta vērtējums apmierinātībai ar e-vidi. <i>SWL</i> – Studenta vērtējums savai vēlmei mācīties. <i>SAL</i> – Studenta spējas mācīties.					

Studentu prognozētā jaunapgūto digitālo prasmju lietošana un instruktora ieinteresētība dalīties ar zināšanām. Korelāciju koeficienti studentu prognozētai jaunapgūto digitālo prasmju lietošanai un instruktora ieinteresētībai dalīties ar zināšanām ir nenozīmīgi trīs tēmām: sociālie tīkli; drošs darbs ar datoru; mājas lapas izveides pamati un publicēšana. Pārējām septiņām tēmām korelācijas ir nozīmīgas un ir robežās no 0,28 to 0,41. Tas nozīmē, ka šo tēmu ietvaros pastāv saistība starp studentu vērtējumu instruktora vēlmei dalīties ar zināšanām un studentu prognozi, vai lietos jaunapgūtās prasmes. Jo augstāk students vērtē pasniedzēja vēlmi dalīties ar zināšanām, jo augstāka ir prognoze, ka students lietos jaunapgūtās prasmes. Ciešākā saistība starp studenta prognozi prasmju lietošanai un

instruktora ieinteresētībai dalīties ar zināšanām ir e-pasta tēmai. Mainīgais “Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām” ir derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem šādām tēmām: perifērijas ierīču pieslēgšana; video apstrāde; *PDF* formāta faili; iemaņas darbā ar *DBVS Access* datu bāzi; darbs ar skeneri; e-studiju kursi internetā pasaulē; e-pasts.

Studentu prognozētā jaunapgūto digitālo prasmju lietošana un studenta apmierinātība ar e-materiāliem. Korelācijas ir nozīmīgas visām tēmām un ir robežās no 0,37 līdz 0,60. Tas nozīmē, ka pastāv saistība starp studentu apmierinātības līmeni ar e-mācību materiāliem un studentu prognozi, vai lietos jaunapgūtās prasmes. Jo vairāk students ir apmierināts ar e-mācību materiāliem, jo vairāk prognozē, ka lietos jaunapgūtās digitālās prasmes. Ciešākā saistība starp studenta prognozi prasmju lietošanai un apmierinātību ar e-mācību materiāliem ir e-pasta tēmai. Mainīgais “Studenta vērtējums apmierinātībai ar e-materiāliem” ir derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem visām tēmām.

Studentu prognozētā jaunapgūto digitālo prasmju lietošana un studenta apmierinātība ar e-mācību vidi. Korelācijas ir nozīmīgas visām tēmām un ir robežās no 0,34 līdz 0,64. Tas nozīmē, ka pastāv saistība starp studentu apmierinātības līmeni ar e-mācību vidi un studentu prognozi, vai lietos jaunapgūtās prasmes. Jo vairāk students ir apmierināts ar e-mācību vidi, jo vairāk prognozē, ka lietos jaunapgūtās digitālās prasmes. Ciešākā saistība starp studenta prognozi prasmju lietošanai un apmierinātību ar e-mācību vidi ir tēmai par perifērijas ierīču pieslēgšanu. Mainīgais “Studenta vērtējums apmierinātībai ar e-vidi” ir derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem visām tēmām.

Studentu prognozētā jaunapgūto digitālo prasmju lietošana un studenta vēlme mācīties. Korelācijas ir nozīmīgas visām tēmām un ir robežās no 0,23 līdz 0,38. Tas nozīmē, ka pastāv saistība starp studentu vēlmi mācīties un studentu prognozi, vai lietos jaunapgūtās prasmes. Jo vairāk studentam ir vēlme mācīties, jo vairāk prognozē, ka lietos jaunapgūtās digitālās prasmes. Ciešākā saistība starp studenta prognozi prasmju lietošanai un studenta vēlmi mācīties ir tēmām: perifērijas ierīču pieslēgšana; sociālie tīkli. Mainīgais “Studenta vērtējums savai vēlmei mācīties” ir derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem visām tēmām.

Studentu prognozētā jaunapgūto digitālo prasmju lietošana un studenta spējas mācīties. Korelācijas ir nozīmīgas visām tēmām, izņemot E-pasta tēmai, un ir robežās no 0,25 līdz 0,47. Tas nozīmē, ka pastāv saistība starp studentu spēju mācīties un studentu prognozi, vai lietos jaunapgūtās prasmes. Jo vairāk studentam ir spējas mācīties, jo vairāk students prognozē, ka lietos jaunapgūtās digitālās prasmes. Ciešākā saistība starp studenta prognozi prasmju lietošanai un studenta spējām mācīties ir tēmai par e-studiju kursiem internetā pasaulē. Mainīgais “Studenta spējas mācīties” ir derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem visām tēmām.

Korelācijas novērotai studentu jaunapgūto prasmju lietošanai

Korelācijas novērotai studentu jaunapgūto prasmju lietošanai un e-iekļaušanas faktoru mainīgajiem ir dotas 3.12. tabulā.

Novērotā studentu jaunapgūto digitālo prasmju lietošana un instruktora ieinteresētība dalīties ar zināšanām. Korelācijas nav nozīmīgas, izņemot vienu tēmu par drošu darbu ar datoru, kur koeficients ir 0,26. Tas nozīmē, ka vairums tēmu nepastāv saistība starp studentu vērtējumu instruktora vēlmei dalīties ar zināšanām un studentu jaunapgūto

digitālo prasmju lietošanu. Mainīgais “Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām” nav derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem, izņemot tēmu: drošs darbs ar datoru.

3.12. tabula

Pīrsona korelāciju koeficienti novērotai jaunapgūto digitālo prasmju lietošanai un prediktoriem (e-iekļaušanas faktoriem).

Tēma Prediktors	1. prediktors			2. prediktors	
	<i>IWS</i>	<i>ELM</i>	<i>ELE</i>	<i>SWL</i>	<i>SAL</i>
Perifērijas ierīču pieslēgšana	0,14	0,23	0,15	0,14	0,22(*)
Video apstrāde	0,15	0,02	0,17	0,07	0,07
Sociālie tīkli	0,15	0,30	0,15	0,15	0,29(*)
PDF formāta faili	0,09	0,17	0,20	0,05	0,28(*)
Iemaņas darbā ar <i>DBVS Access</i> datu bāzi	0,01	0,15	0,14	0,13	0,10
Drošs darbs ar datoru	0,26(*)	0,09(*)	0,02	0,32(**)	0,24
Darbs ar skeneri	-0,09	0,19	0,11	0,22	0,02
Mājas lapas izveides pamati un publicēšana	0,03	-0,16	-0,10	0,02	0,15
E-studiju kursi internetā pasaulē	0,14	0,30(*)	0,18	0,36(**)	0,20
E-pasts	0,04	0,13	0,07	0	-0,06

** . Korelācija ir nozīmīga 0,01 vērtībai (2-daļīga)
 * . Korelācija ir nozīmīga 0,05 vērtībai (2-daļīga)
IWS – Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām. *ELM* – Studenta vērtējums apmierinātībai ar e-materiāliem. *ELE* – Studenta vērtējums apmierinātībai ar e-vidi. *SWL* – Studenta vērtējums savai vēlmei mācīties. *SAL* – Studenta spējas mācīties.

Novērotā studentu jaunapgūto digitālo prasmju lietošana un studenta apmierinātība ar e-materiāliem. Korelācijas ir nenozīmīgas visām tēmām, izņemot divas tēmas: drošs darbs ar datoru (koeficients 0,09); e-studiju kursi internetā pasaulē (koeficients 0,30). Tas nozīmē, ka vairums tēmu nepastāv saistība starp studentu apmierinātības līmeni ar e-mācību materiāliem un novērojumiem par jaunapgūto digitālo prasmju lietošanu. Mainīgais “Studenta vērtējums apmierinātībai ar e-materiāliem” nav derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem, izņemot tēmām: drošs darbs ar datoru; e-studiju kursi internetā pasaulē.

Novērotā studentu jaunapgūto digitālo prasmju lietošana un studenta apmierinātība ar e-mācību vidi. Korelācijas ir nenozīmīgas visām tēmām. Tas nozīmē, ka nepastāv saistība starp studentu apmierinātības līmeni ar e-mācību vidi un novērojumiem par jaunapgūto digitālo prasmju lietošanu. Mainīgais “Studenta vērtējums apmierinātībai ar e-vidi” nav derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem visām tēmām.

Novērotā studentu jaunapgūto digitālo prasmju lietošana un studenta vēlme mācīties. Korelācijas ir nenozīmīgas, izņemot divas tēmas: e-studiju kursi internetā pasaulē; drošs darbs ar datoru. Tas nozīmē, ka vairums tēmu nepastāv saistība starp studentu vēlmi mācīties un novērojumiem par jaunapgūto digitālo prasmju lietošanu. Mainīgais “Studenta

vērtējums savai vēlmei mācīties” nav derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem visām tēmām.

Novērotā studentu jaunapgūto digitālo prasmju lietošana un studenta spējas mācīties. Korelācijas ir nenozīmīgas visām tēmām, izņemot tēmas: PDF formāta faili; sociālie tīkli; perifērijas ierīču pieslēgšana. Tas nozīmē, ka vairums tēmu nepastāv saistība starp studentu spēju mācīties un novērojumiem par jaunapgūto digitālo prasmju lietošanu. Mainīgais “Studenta spējas mācīties” vairums tēmu nav derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem visām tēmām.

Korelācijas studentu iespējamai jaunapgūto prasmju lietošanai

Korelācijas studentu iespējamai jaunapgūto prasmju lietošanai un e-iekļaušanas faktoriem ir dotas 3.13. tabulā.

3.13. tabula

Pīrsona korelāciju koeficienti iespējamai jaunapgūto digitālo prasmju lietošanai un prediktoriem (e-iekļaušanas faktoriem).

Tēma Prediktors	1. prediktors			2. prediktors	
	<i>IWS</i>	<i>ELM</i>	<i>ELE</i>	<i>SWL</i>	<i>SAL</i>
Perifērijas ierīču pieslēgšana	0,36(**)	0,54(**)	0,56(**)	0,36(**)	0,30(**)
Video apstrāde	0,18	0,32(**)	0,41(**)	0,31(**)	0,26(*)
Sociālie tīkli	0,13	0,58(**)	0,35(**)	0,34(**)	0,45(**)
PDF formāta faili	0,26(*)	0,41(**)	0,45(**)	0,29(*)	0,40(**)
Iemaņas darbā ar <i>DBVS Access</i> datu bāzi	0,22	0,45(**)	0,49(**)	0,26(*)	0,32(**)
Drošs darbs ar datoru	0,29(*)	0,43(**)	0,29(*)	0,41(**)	0,49(**)
Darbs ar skeneri	0,22	0,39(**)	0,48(**)	0,29(*)	0,21
Mājas lapas izveides pamati un publicēšana	0,21	0,29(*)	0,26(*)	0,29(*)	0,36(**)
E-studiju kursi internetā pasaulē	0,31(**)	0,60(**)	0,38(**)	0,44(**)	0,46(**)
E-pasts	0,38(**)	0,59(**)	0,60(**)	0,27(*)	0,08

** . Korelācija ir nozīmīga 0,01 vērtībai (2-daļīga)
 * . Korelācija ir nozīmīga 0,05 vērtībai (2-daļīga)
IWS – Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām. *ELM* – Studenta vērtējums apmierinātībai ar e-materiāliem. *ELE* – Studenta vērtējums apmierinātībai ar e-vidi.
SWL – Studenta vērtējums savai vēlmei mācīties. *SAL* – Studenta spējas mācīties.

Studentu iespējamā jaunapgūto digitālo prasmju lietošana un instruktora ieinteresētība dalīties ar zināšanām. Korelāciju koeficienti ir nenozīmīgi piecām tēmām: sociālie tīkli; video apstrāde; iemaņas darbā ar *DBVS Access* datu bāzi; darbs ar skeneri; mājas lapas izveides pamati un publicēšana. Pārējām piecām tēmām korelācijas ir nozīmīgas un ir robežās no 0,26 to 0,38. Tas nozīmē, ka šo tēmu ietvaros pastāv saistība starp studentu vērtējumu instruktora vēlmei dalīties ar zināšanām un iespējamo jaunapgūto prasmju lietošanu. Jo augstāk students vērtē pasniedzēja vēlmi dalīties ar zināšanām, jo augstāka ir iespēja, ka students lietos jaunapgūtās prasmes. Ciešākā saistība starp iespējamo prasmju lietošanu un instruktora ieinteresētību dalīties ar zināšanām ir e-pasta tēmai. Mainīgais

“Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām” ir derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem šādām tēmām: perifērijas ierīču pieslēgšana; PDF formāta faili; drošs darbs ar datoru; e-studiju kursi internetā pasaulē; e-pasts.

Studentu iespējamā jaunapgūto digitālo prasmju lietošana un studenta apmierinātība ar e-materiāliem. Korelācijas ir nozīmīgas visām tēmām un ir robežās no 0,29 līdz 0,60. Tas nozīmē, ka pastāv saistība starp studentu apmierinātības līmeni ar e-mācību materiāliem un iespēju, ka students lietos jaunapgūtās prasmes. Jo vairāk students ir apmierināts ar e-mācību materiāliem, jo lielāka iespēja, ka lietos jaunapgūtās digitālās prasmes. Ciešākā saistība starp iespējamību, ka students lietos jaunapgūtās prasmes un apmierinātību ar e-mācību materiāliem ir tēmai par e-studiju kursiem internetā pasaulē. Mainīgais “Studenta vērtējums apmierinātībai ar e-materiāliem” ir derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem visām tēmām.

Studentu iespējamā jaunapgūto digitālo prasmju lietošana un studenta apmierinātība ar e-mācību vidi. Korelācijas ir nozīmīgas visām tēmām un ir robežās no 0,29 līdz 0,60. Tas nozīmē, ka pastāv saistība starp studentu apmierinātības līmeni ar e-mācību vidi un iespēju, ka lietos jaunapgūtās prasmes. Jo vairāk students ir apmierināts ar e-mācību vidi, jo vairāk pastāv iespēja, ka lietos jaunapgūtās digitālās prasmes. Ciešākā saistība starp iespēju, ka students lietos jaunapgūtās prasmes un apmierinātību ar e-mācību vidi ir e-pasta tēmai. Mainīgais “Studenta vērtējums apmierinātībai ar e-vidi” ir derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem visām tēmām.

Studentu iespējamā jaunapgūto digitālo prasmju lietošana un studenta vēlme mācīties. Korelācijas ir nozīmīgas visām tēmām un ir robežās no 0,27 līdz 0,44. Tas nozīmē, ka pastāv saistība starp studentu vēlmi mācīties un iespēju, ka students lietos jaunapgūtās prasmes. Jo vairāk studentam ir vēlme mācīties, jo lielāka iespēja, ka lietos jaunapgūtās digitālās prasmes. Ciešākā saistība starp iespējamo prasmju lietošanai un studenta vēlmi mācīties ir tēmai par e-studiju kursiem internetā pasaulē. Mainīgais “Studenta vērtējums savai vēlmei mācīties” ir derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem visām tēmām.

Studentu iespējamā jaunapgūto digitālo prasmju lietošana un studenta spējas mācīties. Korelācijas ir nozīmīgas visām tēmām, izņemot tēmas: e-pasts; darbs ar skeneri. Korelācijas ir robežās no 0,26 līdz 0,49. Tas nozīmē, ka vairums tēmu pastāv saistība starp studentu spēju mācīties un iespējamību, ka students lietos jaunapgūtās prasmes. Jo vairāk studentam ir spējas mācīties, jo lielāka iespēja, ka students lietos jaunapgūtās digitālās prasmes. Ciešākā saistība starp iespējamību, ka students lietos jauniegūtās prasmes, un studenta spējām mācīties ir tēmai par drošu darbu ar datoru. Mainīgais “Studenta spējas mācīties” ir derīgs turpmākiem lineārās regresijas vienādojumu aprēķiniem, izņemot tēmas: e-pasts; darbs ar skeneri.

Kopsavilkums un secinājumi par e-iekļautības pakāpes un e-iekļaušanas faktoru saistību

Atbilstoši izvirzītajiem pētījumu jautājumiem ir veikti korelāciju pētījumi, un to rezultāti apstiprina, ka vismaz vienā kursa tēmā:

1) Pastāv saistība starp studenta vērtējumu instruktora vēlmei dalīties ar zināšanām un studenta e-iekļautības pakāpei gadījumā;

- ja e-iekļautības pakāpe tiek mērīta kā studenta prognoze, ka pēc kursa pabeigšanas

- students apgūtās prasmes izmantos profesionālām vai privātām vajadzībām;
- ja e-iekļautības pakāpe tiek mērīta kā prasmju iespējamā lietošana pēc kursa pabeigšanas.
- 2) Pastāv saistība starp studenta apmierinātības līmeni ar e-mācību materiāliem un e-iekļautības pakāpi gadījumā,
- ja e-iekļautības pakāpe tiek mērīta kā studenta prognoze, ka pēc kursa pabeigšanas students apgūtās prasmes izmantos profesionālām vai privātām vajadzībām;
 - ja e-iekļautības pakāpe tiek mērīta kā prasmju iespējamā lietošana pēc kursa pabeigšanas.
- 3) Pastāv saistība starp studenta apmierinātības līmeni ar e-vidi un studenta e-iekļautības pakāpi gadījumā,
- ja e-iekļautības pakāpe tiek mērīta kā studenta prognoze, ka pēc kursa pabeigšanas students apgūtās prasmes izmantos profesionālām vai privātām vajadzībām;
 - ja e-iekļautības pakāpe tiek mērīta kā prasmju iespējamā lietošana pēc kursa pabeigšanas.
- 4) Pastāv saistība starp studenta vēlmi mācīties un studenta e-iekļautības pakāpi gadījumā,
- ja e-iekļautības pakāpe tiek mērīta kā studenta prognoze, ka pēc kursa pabeigšanas students apgūtās prasmes izmantos profesionālām vai privātām vajadzībām;
 - ja e-iekļautības pakāpe tiek mērīta kā prasmju iespējamā lietošana pēc kursa pabeigšanas.
- 5) Pastāv saistība starp studenta spējām mācīties un studenta e-iekļautības pakāpi gadījumā,
- ja e-iekļautības pakāpe tiek mērīta kā studenta prognoze, ka pēc kursa pabeigšanas students apgūtās prasmes izmantos profesionālām vai privātām vajadzībām;
 - ja e-iekļautības pakāpe tiek mērīta kā prasmju iespējamā lietošana pēc kursa pabeigšanas.

Atbilstoši korelāciju rezultātiem var uzskatīt, ka nepastāv saistība starp novēroto studenta jaunapgūto prasmju lietošanu un e-iekļaušanas faktoriem. Tāpēc novērotā studenta jaunapgūto prasmju lietošana nevar tikt izmantota lineārās regresijas modeļos kā rezultatīvais mainīgais. Atbilstoši korelāciju pētījumiem kā rezultatīvie mainīgie lineārās regresijas modeļos var tikt izmantota (1) studenta prognoze, ka pēc kursa pabeigšanas students apgūtās prasmes izmantos profesionālām vai privātām vajadzībām; (2) prasmju iespējamā lietošana pēc kursa pabeigšanas. Korelāciju pētījumi parāda, ka saistība starp e-iekļaušanas faktoriem un e-iekļautības pakāpi dažādās kursa tēmas ir atšķirīga.

Rezultāti: lineārās regresijā balstīts e-iekļaušanu prognozējošs modelis

Lai izpētītu vairāku prediktoru mainīgo ietekmi uz rezultatīvo pazīmi, mainīgos apskatot vienkopus, bet izdalot katra ietekmi atsevišķi, autore izmanto lineārās regresijas vienādojumu modelēšanu.

Lineārās regresijas modelēša ir viena no metodēm, ko izmanto studentu sasniegumu prognozēšanai izglītības jomā (*Erguven, 2012; Huang un Fang, 2013*).

Lai izdalītu katra prediktora mainīgā patstāvīgo jeb tīro ietekmi, svarīgs analīzes priekšnoteikums ir, lai pašu mainīgo korelatīvās sakarības nebūtu ciešas. Ja šīs sakarības ir ciešas (multikolinearitāte), atsevišķu mainīgo patstāvīgo ietekmi nevar izdalīt (*Krastiņš, 1998*). Lai izslēgtu multikolinearitāti un iegūtu daudzfaktoru lineārās regresijas vienādojumus,

autore izmanto *SPSS* programmatūru un soļveida daudzfaktoru regresijas (angļu val. – *stepwise multiple regression*) metodi (Pearson Education, 2008).

3.14. un 3.15. tabulas parāda, ka modeļi ir nozīmīgi (kolonā Sig $p < 0.005$) visām tēmām. Determinācijas koeficienti R^2 parāda, cik daudz variācijas var identificēt, paredzot prognozi un iespējamību, ka studenti lietos jaunapgūtās digitālās prasmes pēc kursu apguves.

3.14. tabula

Determinācijas koeficienti R^2 un tā nozīmīgums studenta prognozētās lietošanas lineārās regresijas modelim.

Tēma	R^2	Sig
Perifērijas ierīču pieslēgšana	0,462	0,000
Video apstrāde	0,211	0,000
Sociālie tīkli	0,347	0,000
<i>PDF</i> formāta faili	0,299	0,000
Iemaņas darbā ar <i>DBVS Access</i> datu bāzi	0,343	0,000
Drošs darbs ar datoru	0,228	0,000
Darbs ar skeneri	0,284	0,000
Mājas lapas izveides pamati un publicēšana	0,190	0,000
E-studiju kursi internetā pasaulē	0,353	0,000
E-pasts	0,465	0,000

3.14. tabulā redzams, ka modeļi, ar kuriem var noteikt prognozēto lietošanu izskaidro no 19 % līdz 46,2 % no kopējā variāciju skaita. Augstākie variāciju procenti ir šādām tēmām: perifērijas ierīču pieslēgšana; e-pasts, e-studiju kursi internetā pasaulē. Zemākie procenti ir šādām tēmām: mājas lapas izveides pamati un publicēšana; video apstrāde.

3.15. tabulā redzams, ka determinācijas koeficienti modeļiem, kas nosaka iespējamo jaunapgūto digitālo prasmju lietošanu, ir robežās no 13,1 % līdz 43,2 % no kopējo variāciju skaita. Līdzīgi kā prognozētai lietošanai augstākie procenti ir tēmām: perifērijas ierīču pieslēgšana, e-pasts, e-studiju kursi internetā pasaulē. Zemākie determinācijas koeficienti ir tēmām: mājas lapas izveides pamati un publicēšana; video apstrāde.

Lineārās regresijas analīzē iegūtie rezultāti rāda, ka no visiem pieciem iespējamajiem mainīgajam modelī vienlaicīgi ir iekļauti tikai viens vai divi. Mainīgais “Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām” nav iekļauts nevienā modelī. Citi mainīgie ir iekļauti modelī, bet prediktoru un mainīgo skaits modeļos ir dažāds.

3.15. tabula

Determinācijas koeficienti R^2 un tā nozīmīgums iespējamās lietošanas lineārās regresijas modelim.

Tēma	R^2	Sig
Perifērijas ierīču pieslēgšana	0,382	0,000
Video apstrāde	0,167	0,000
Sociālie tīkli	0,397	0,000
PDF formāta faili	0,280	0,000
Iemaņas darbā ar <i>DBVS Access</i> datu bāzi	0,236	0,000
Drošs darbs ar datoru	0,309	0,000
Darbs ar skeneri	0,226	0,000
Mājas lapas izveides pamati un publicēšana	0,131	0,000
E-studiju kursi internetā pasaulē	0,432	0,000
E-pasts	0,427	0,000

3.16. un 3.17. tabulā ir attēloti regresijas modeļi studenta prognozētai digitālo prasmju lietošanai un iespējamai digitālo prasmju lietošanai.

3.16. tabula

Prediktori un lineārās regresijas vienādojumi studenta prognozētai digitālo prasmju lietošanai.

Prediktoru skaits	Iekļautie prediktori	Mainīgie	Tēma	Vienādojums	
1	1. prediktors	<i>ELM</i>	Mājas lapas izveides pamati un publicēšana	$PU= 0,837+0,629ELM$	
			E-studiju kursi internetā pasaulē	$PU= 1,676+0,656ELM$	
			Drošs darbs ar datoru	$PU= 1,496+0,729ELM$	
2		<i>ELE</i>	Darbs ar skeneri	$PU= 1,106+0,696ELE$	
			<i>ELM, ELE</i>	Perifērijas ierīču pieslēgšana	$PU=0,189+0,358ELM+0,617ELE$
				Iemaņas darbā ar <i>DBVS Access</i> datu bāzi	$PU=0,255+0,342ELM+0,527ELE$
	E-pasts	$PU=1,184+0,356ELM+0,466ELE$			
	1.prediktors, 2. prediktors	<i>ELE, SWL</i>	Video apstrāde	$PU=0,506+0,453ELE+0,400SWL$	
		<i>ELE, SAL</i>	PDF formāta faili	$PU=1,603+0,512ELE+ 0,009SAL$	
<i>ELM, SWL</i>		Sociālie tīkli	$PU=0,310+0,646ELM+0,418SWL$		

IWS – Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām. *ELM* – Studenta vērtējums apmierinātībai ar e-materiāliem. *ELE* – Studenta vērtējums apmierinātībai ar e-vidi. *SWL* – Studenta vērtējums savai vēlmei mācīties. *SAL* – Studenta spējas mācīties.

Lineārās regresijas vienādojumi studenta prognozētai digitālo prasmju lietošanai.

Vairums tēmās prognozētās lietošanas lineārās regresijas modelī ir divi mainīgie. Mainīgie “Studenta vērtējums apmierinātībai ar e-materiāliem” un “Studenta vērtējums apmierinātībai ar e-vidi” ir prediktori trīs tēmām: perifērijas ierīču pieslēgšana; iemaņas darbā ar *DBVS Access* datu bāzi; e-pasts. Tēmai par video apstrādi ir šādi prediktori: “Studenta vērtējums apmierinātībai ar e-materiāliem” un “Studenta vērtējums savai vēlmei mācīties”. Tēmai par *PDF* formāta faili kā prediktori ir: “Studenta vērtējums apmierinātībai ar e-vidi” un “Studenta spējas mācīties”. Tēmai par sociālajiem tīkliem ir sekojoši prediktori: “Studenta vērtējums apmierinātībai ar e-materiāliem” un “Studenta vērtējums savai vēlmei mācīties”.

Viens mainīgais “Studenta vērtējums apmierinātībai ar e-materiāliem” ir prediktors trīs tēmām: mājas lapas izveides pamati un publicēšana; e-studiju kursi internetā pasaulē; drošs darbs ar datoru. Mainīgais “Studenta vērtējums apmierinātībai ar e-vidi” ir prediktors tēmai par darbu ar skeneri.

3.17. tabula

Prediktori un lineārās regresijas vienādojumi iespējamai digitālo prasmju lietošanai.

Prediktoru skaits	Iekļautie prediktori	Mainīgie	Tēma	Vienādojums
1	1. prediktors	<i>ELE</i>	Video apstrāde	$PU&OU=1,703+0,720ELE$
			Darbs ar skeneri	$PU&OU=2,550+0,741ELE$
			Iemaņas darbā ar <i>DBVS Access</i> datu bāzi	$PU&OU=0,808+0,851ELE$
	2. prediktors	<i>SAL</i>	Mājas lapas izveides pamati un publicēšana	$PU&OU=2,662+0,019SAL$
2	1. prediktors	<i>ELM, ELE</i>	Perifērijas ierīču pieslēgšana	$PU&OU=0,636+0,519ELM+0,641ELE$
			E-pasts	$PU&OU=2,165+0,422ELM+0,452ELE$
	1. prediktors, 2. prediktors	<i>ELM, SAL</i>	Sociālie tīkli	$PU&OU=0,490+0,783ELM+0,014SAL$
			E-studiju kursi internetā pasaulē	$PU&OU=0,228+0,544ELM+0,807SWL$
		<i>ELE, SAL</i>	PDF formāta faili	$PU&OU=1,790+0,636ELE+0,015SAL$
	2. prediktors	<i>SWL, SAL</i>	Drošs darbs ar datoru	$PU&OU=2,507+0,487SWL+0,0175SAL$

IWS – Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām. *ELM* – Studenta vērtējums apmierinātībai ar e-materiāliem. *ELE* – Studenta vērtējums apmierinātībai ar e-vidi. *SWL* – Studenta vērtējums savai vēlmei mācīties. *SAL* – Studenta spējas mācīties.

Līdzīgi kā prognozētās lietošanas regresijas modelim iegūtie rezultāti rāda, ka iespējamai lietošanai lineārās regresijas modelī lielākajai daļai tēmu ir divi mainīgie. Četrām tēmām ir

tikai viens mainīgais – mainīgais “Studenta vērtējums apmierinātībai ar e-vidi” ir prediktors tēmām: video apstrāde; darbs ar skeneri; iemaņas darbā ar *DBVS Access* datu bāzi. Kā arī mainīgais “Studenta spējas mācīties” ir prediktors tēmai par mājas lapas izveides pamatiem un publicēšanu.

Pārējām tēmām prediktori ir divi mainīgie. Mainīgie “Studenta vērtējums apmierinātībai ar e-vidi” un “Studenta vērtējums apmierinātībai ar e-materiāliem” ir prediktori tēmām: perifērijas ierīču pieslēgšana; e-pasts. Mainīgie “Studenta vērtējums apmierinātībai ar e-materiāliem” un “Studenta spējas mācīties” ir prediktori tēmai par sociālajiem tīkliem. Mainīgie “Studenta vērtējums apmierinātībai ar e-materiāliem” un “Studenta vērtējums savai vēlmei mācīties” ir prediktori tēmai par e-studiju kursiem internetā pasaulē. Tēmai par *PDF* formāta failiem ir sekojoši prediktori: “Studenta vērtējums apmierinātībai ar e-vidi” un “Studenta spējas mācīties”. Tēmai par drošu darbu ar datoru ir sekojoši prediktori: “Studenta vērtējums savai vēlmei mācīties” un “Studenta spējas mācīties”.

Pēdējā kolona tabulās atspoguļo prognozētās lietošanas un iespējamās lietošanas lineārās regresijas vienādojumus dažādām tēmām.

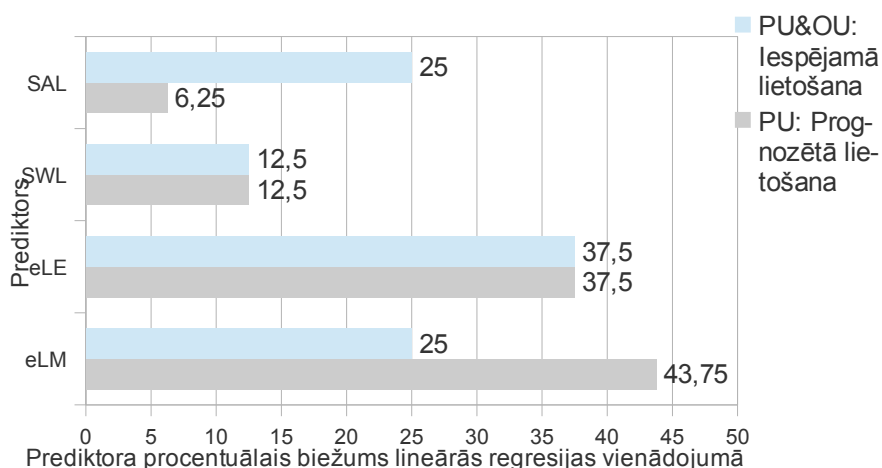
3.18. tabula

Prediktoru biežums tēmās prognozētai lietošanai un iespējamai lietošanai.

Prediktors	Tēmu skaits <i>PU</i>	Tēmu skaits <i>PU&OU</i>
<i>ELE</i>	6	6
<i>ELM</i>	7	4
<i>IWS</i>	0	0
<i>SWL</i>	2	2
<i>SAL</i>	1	4

Kā redzams 3.18. tabulā, ir prediktori, kuru skaits nemainās prognozētā un iespējamā lietošanā. Tā ir mainīgajiem “Studenta vērtējums apmierinātībai ar e-vidi” un “Studenta vērtējums savai vēlmei mācīties”. Bet ir prediktors, kura skaits vienādojumos pieaug iespējamajai lietošanai. Tas ir mainīgais “Studenta spējas mācīties”. Savukārt prediktora skaits “Studenta vērtējums apmierinātībai ar e-materiāliem” iespējamās lietošanas tēmās samazinās.

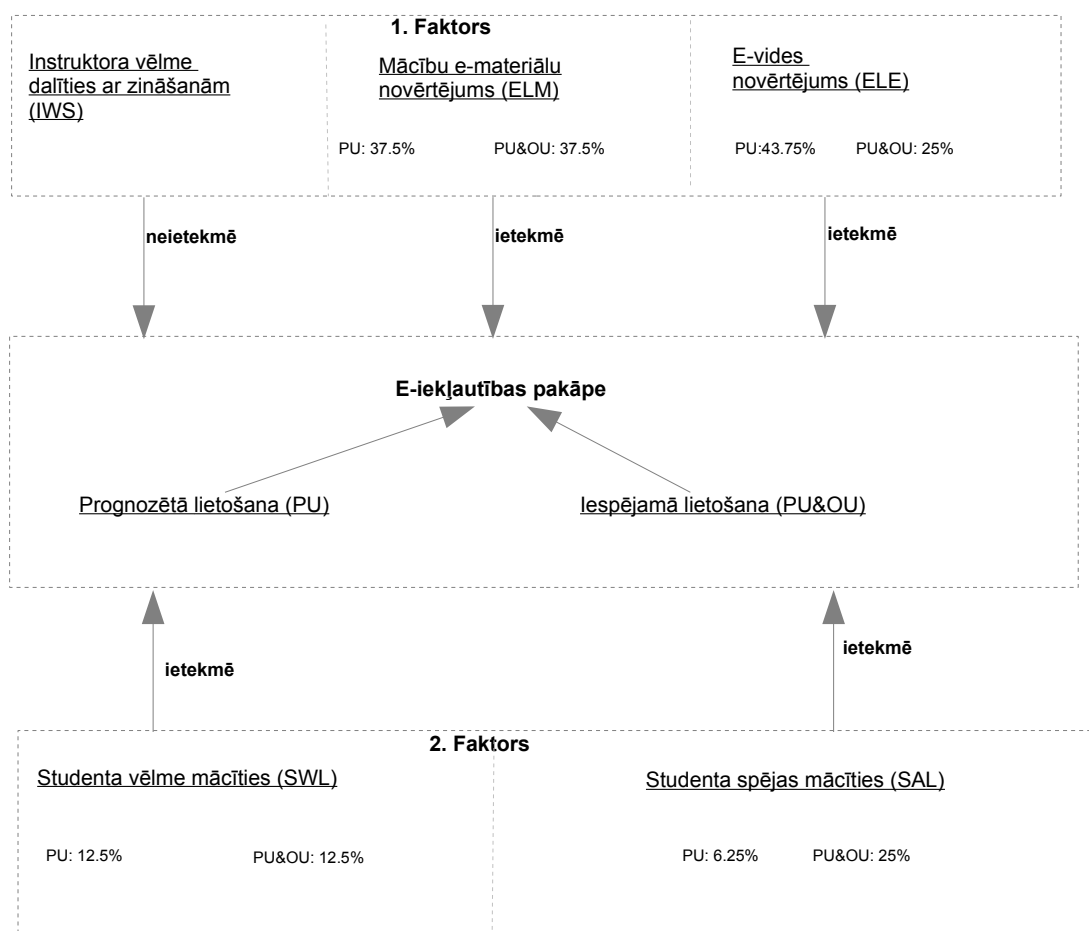
3.4. attēlā ir parādīti procentuāli biežāk izmantotie prediktori lineārās regresijas modeļiem prognozētai lietošanai un iespējamai lietošanai. Visbiežāk kā prediktors ir izmantots “Studenta vērtējums apmierinātībai ar e-materiāliem”(43,75 %). Tad seko “Studenta vērtējums apmierinātībai ar e-vidi” (37,5 %). “Studenta vērtējums savai vēlmei mācīties” ir prediktors 12,5 %, bet “Studenta spējas mācīties” ir prediktors tikai 6,25 % gadījumos.



3.4. att. Biežāk izmantotie prediktori lineārās regresija modelī studenta prognozētai digitālo prasmju lietošanai un iespējamai lietošanai. *ELM* – Studenta vērtējums apmierinātībai ar e-materiāliem. *ELE* – Studenta vērtējums apmierinātībai ar e-vidi. *SWL* – Studenta vērtējums savai vēlmei mācīties. *SAL* – Studenta spējas mācīties.

Kopsavilkums un secinājumi par e-iekļautības pakāpes prognozēšanu ar e-iekļaušanas faktoriem lineārās regresijas modeli

Kopsavilkums par lineārās regresijas modelēšanas rezultātiem ir dots 3.5. attēlā.



3.5. att. Prognozētās un iespējamās lietošanas lineārās regresijas modeļos izmantotie indivīda e-iekļautību ietekmējošie faktori.

Atbilstoši pētījuma jautājumam noskaidrots, ka ir iespējams prognozēt studenta e-iekļautības pakāpi ar e-iekļaušanas faktoriem, kurus var izteikt ar šādiem mainīgumiem – studenta ieinteresētības līmenis un spēja mācīties, studenta apmierinātības līmenis ar e-mācību materiāliem un e-vidi. Studenta e-iekļautības pakāpe lineārās regresijas modelī tiek mērīta divējādi: (1) kā studenta prognoze tam, ka students pēc kursa pabeigšanas apgūtās prasmes izmantos profesionālām vai privātām vajadzībām; (2) kā jaunapgūto prasmju iespējamā lietošana pēc kursa pabeigšanas.

Lineārās regresijas modelēšanas rezultāti rāda, ka prognozēšanai izmantojamie vienādojumi un e-iekļaušanas faktoru mainīgie dažādiem kursiem ir atšķirīgi. Rezultāti neuzrāda vienotu e-iekļaušanu prognozējošu modeli.

Lai arī ir pieci iespējamie prediktori lineārās regresijas modeļiem, rezultāti uzrāda, ka tikai viens vai divi prediktori vienlaicīgi izmantoti vienādojumā. Viens no prediktoriem vispār neparādās, tas ir mainīgais “Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām”. Šis mainīgais neietekmē prognozēto lietošanu un iespējamo lietošanu.

Prognozētā lietošana un prediktori. Biežāk izmantotie prediktori prognozētajai lietošanai ir šādi 1. faktora neatkarīgie mainīgie: “Studenta vērtējums apmierinātībai ar e-materiāliem” (43,75 %) un “Studenta vērtējums apmierinātībai ar e-vidi” (37,5 %).

2. faktora mainīgais “Studenta vērtējums savai vēlmei mācīties” salīdzinoši mazāk tēmās ietekmē prognozēto lietošanu, tas tiek iekļauts vienādojumos kā otrais faktors 12,5 %. Tikai 6 % 2. faktora mainīgais “Studenta spējas mācīties” noteica prognozēto lietošanu.

Iespējamā lietošana un prediktori. Biežāk izmantotie prediktori iespējamai lietošanai ir šādi 1. faktora neatkarīgie mainīgie: “Studenta vērtējums apmierinātībai ar e-vidi” (37,5 %), “Studenta vērtējums apmierinātībai ar e-materiāliem” (25 %) un “Studenta spējas mācīties” (25 %).

2. faktora mainīgais “Studenta vērtējums savai vēlmei mācīties” salīdzinoši mazāk tēmās ietekmē iespējamo lietošanu, tas tiek iekļauts vienādojumos kā otrais faktors 12,5 %.

Iegūtie rezultāti rāda, ka ar lineārās regresijas modeļiem var prognozēt indivīda e-iekļaušanas pakāpi. Ar iegūtajiem lineārās regresijas e-iekļaušanas prognozēšanas modeļiem ir iespējams izskaidrot indivīda e-iekļautības pakāpi no 13,1 % līdz 46,2 % no kopējā variāciju skaita. Ar lineārās regresijas metodi tiek izskaidrots salīdzinoši neliels procents, tāpēc autore 3.4. apakšnodaļā turpina e-iekļaušanas prognozēšanas modeļu pētījumus, izmantojot klasteranalīzes metodes.

3.4. Indivīda e-iekļautību raksturojošu klasteru izveide un e-iekļautību ietekmējo faktoru atšķirību izvērtējums klasteros

Apakšnodaļas mērķis ir aprakstīt pētījumu, kurā, izmantojot klasteranalīzi, ir pārbaudīts, vai iepriekš noteiktie e-iekļaušanu ietekmējošie faktori atšķiras dažādām e-iekļautības pakāpēm.

Pētījuma mērķis un pētnieciskie jautājumi

Pētījuma mērķis ir noskaidrot iespējamo e-iekļaušanas faktoru, kas raksturo zināšanu plūsmu starp instruktoru un indivīdu, atšķirības profesionālo izglītības iestāžu pedagogiem, kuri apgūst digitālās prasmes instruktora vadībā e-vidē un kuriem ir dažādas e-iekļautības pakāpes.

Pētījuma jautājumi:

1) kā studentu vērtējums instruktora vēlmei dalīties ar zināšanām atšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes pēc mācību kursa beigām nelieto;

2) kā studentu apmierinātības līmenis ar e-mācību materiāliem atšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes pēc mācību kursa beigām nelieto;

3) kā studentu apmierinātības līmenis ar e-vidi atšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes pēc mācību kursa beigām nelieto;

4) kā studentu vēlme mācīties atšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes pēc mācību kursa beigām nelieto;

5) kā studentu spējas mācīties atšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes pēc mācību kursa beigām nelieto.

Pētījuma dalībnieki, izmantotie dati un datu analīzes metodes

Pētījuma dalībnieki ir profesionālo izglītības iestāžu pedagogi, kuri apgūst moduļa “Informācijas tehnoloģiju prasmju kompetenču paaugstināšana” vienpadsmit tēmas instruktora vadībā klātienē un attālinātās nodarbībās, izmantojot *Moodle* platformā izvietotus mācību materiālus.

Lai raksturotu profesionālo izglītības iestāžu pedagogus (mācīšanās kontekstā tiek dēvēti par studentiem), kuri apgūst digitālās prasmes kursā “Informācijas tehnoloģiju prasmju kompetenču paaugstināšana”, tiek izmantoti e-iekļaušanas faktorus raksturojošie mainīgie.

Pētījumā izmantotais e-iekļaušanas faktors – instruktora vēlme un spēja dalīties ar zināšanām e-mācību kursa laikā, – tiek mērīts ar trīs mainīgiem (iespējamās vērtības ir no 1 līdz 5):

1. “Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām”, *IWS*;
2. “Studenta vērtējums apmierinātībai ar e-materiāliem”, *ELM*;
3. “Studenta vērtējums apmierinātībai ar e-vidi”, *ELE*.

Pētījumā izmantotais e-iekļaušanas faktors – studenta vēlme un spējas apgūt digitālās prasmes e-mācību kursa laikā, – tiek mērīts ar diviem mainīgiem:

1. “Studenta vērtējums savai vēlmei mācīties”, *SWL*, (iespējamās vērtības ir no 1 līdz 5).
2. “Studenta spējas mācīties”, *SAL* (iespējamās vērtības ir no 1 līdz 100 %).

E-iekļautības pakāpi autore nosaka, izmantojot mainīgo “Novērotā prasmju lietošana”, *OU*. Mainīgajam ir trīs iespējamās vērtības:

- 0 – nē, neesmu vispār izmantojis/usi ar šo tēmu saistītas prasmes.
- 1 – nē, bet izmantoju prasmes tādā pašā līmenī kā pirms kursa apguves.
- 2 – jā, izmantoju jaunapgūtās prasmes.

Papildus šiem mainīgajiem autore izmanto mainīgos:

- “Studenta prognoze” - vai pēc kursa pabeigšanas apgūtās prasmes students izmantos profesionālām vai privātām vajadzībām, *PU* (iespējamās vērtības ir no 1 līdz 5).
- “Studenta vispārīgās digitālās pamatprasmes”, *DS* (iespējamās vērtības ir no 0 līdz 1).

Pētījumā izmantotā datu kopa satur 916 ierakstus, apvienojot datus par visām vienpadsmit kursa tēmām.

Pētījuma dalībnieki, datu ieguves metodes un izmantotā datu kopas detalizētāk ir aprakstītas 3.1. un 3.2. apakšnodaļās.

Datu analīzes metode. Lai sagrupētu profesionālo pedagogus, balstoties uz tos raksturojošiem datiem, un veiktu šo grupu salīdzināšanu vienlaikus pēc vairākiem parametriem, autore izmantoja klasteru analīzes metodi.

Klasteru analīze ir vairāku mainīgo datu kopas sadalīšana grupās tā, ka punkti vienas grupas ietvaros ir savstarpēji līdzīgi, bet punkti no dažādām grupām ir, cik vien iespējams, atšķirīgi (Mirkin, 2012).

Autore izmantoja iteratīvu attālumā balstītu klasterēšanas pieeju, kas pazīstama kā *kMeans* jeb “*k* vidējo vērtību” algoritms (Witten, 2005). Neskatoties uz to, ka metode radīta 20. gs. vidū un mūsdienās ir radītas alternatīvas, *kMeans* metode tiek plaši izmantota pētījumos datu analīzē (Jain, 2010). Metode paredz, ka vispirms nosaka, cik klasteri tiks veidoti. Klasteru skaits ir *k* vērtība. Tad *k* punkti tiek nejauši izvēlēti kā klasteru centri. Pēc tam visas instances tiek piekārtotas tuvākam klastera centram saskaņā ar Eiklīda attāluma metriku. Tālāk tiek izrēķinātas vērtības instanču centriem, tās ir vidējās vērtības katram klasterim. Šīs vidējās vērtības ir centru vērtības klasteriem. Process tiek atkārtots līdz klasteru centri stabilizējas un nemainās vairs to vērtības.


Praksē ir problemātiski noteikt optimālo klasteru skaitu (Hamerly un Elkan, 2003; Ray un Turi, 1999). Daļa pētnieku nosaka klasteru skaitu empīriski, tas ir, vadoties no iepriekšējās pieredzes un zināšanām, izvēloties tādu skaitu, lai iegūtie klasteri jēgpilni raksturotu grupu (Perera u. c., 2009). Kā arī pētījumos tiek izmantoti citi klasteranalīzes algoritmi, kas palīdz noteikt optimālo klasteru skaitu (Komarasamy un Wahi, 2013; Osamor u. c., 2012). Viena no iespējām, ko izmanto pētījumos, ir *EM* (*Expectation-Maximization*) jeb cerību maksimizācijas algoritms (Zorrilla u. c., 2010).

Lai noteiktu klasteru skaitu *kMeans* algoritmam profesionālo izglītības iestāžu pedagogu analīzē, autore izmantoja *EM* (*Expectation-Maximization*) algoritmu, kā arī empīriski noteica *k* lielumu.

Autore klasteranalīzi veica ar atvērtā pirmkoda programmatūru *WEKA*, kas ir izstrādāta Jaunzēlandē Vakaito universitātē (*Machine Learning Group at the University of Waikato*, 2014).

Rezultāti: indivīdu e-iekļautības klasteru izveides rezultāti un to analīze

Lai gūtu atbildes uz pētnieciskajiem jautājumiem, autore vispirms ar *WEKA* programmatūru izpildīja *EM* (*Expectation-Maximization*) algoritmu, rezultātā iegūstot četrus klasterus. Izvēloties *k* vērtību 4, tika izpildīts *kMeans* algoritms ar *WEKA* programmatūru un rezultātā iegūtie klasteri un to parametri ir redzami 3.6. attēlā (normētās vērtības).



3.6. att. Profesionālo izglītības iestāžu pedagogus raksturojoši klasteri (*kMeans* algoritms, $k=4$, normalizētas vērtības).

3.19. tabulā dotas absolūtās klasteru vērtības.

3.19. tabula

Profesionālo izglītības iestāžu pedagogus raksturojoši klasteri (*kMeans* algoritms, $k=4$, absolūtās vērtības).

Parametrs /Klastera veids un gadījumu skaits	Visi dati (916)	0 (298) Nelieto digitālās prasmes vispār	1 (334) Ir prasmes, bet nelieto jauniegūtās	2 (147) Lieto jauniegūtās prasmes	3 (137) Lieto jauniegūtās prasmes
<i>SWL</i> (no 1 līdz 5)	3,8	3,6	3,8	4,0	3,7
<i>DS</i> (no 0 līdz 1)	0,7	0,6	0,7	0,7	0,7
<i>SAL</i> (no 1 līdz 100 %)	50,5	45,8	52,3	81,0	23,7
<i>ELM</i> (no 1 līdz 5)	4,0	3,9	4,0	4,5	3,8
<i>IWS</i> (no 1 līdz 5)	4,6	4,6	4,6	4,8	4,6
<i>ELE</i> (no 1 līdz 5)	4,1	4,1	4,1	4,5	4,0
<i>PU</i> (no 1 līdz 5)	4,0	3,5	4,1	4,6	3,9

IWS – Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām. *ELM* – Studenta vērtējums apmierinātībai ar e-materiāliem. *ELE* – Studenta vērtējums apmierinātībai ar e-vidi. *SWL* – Studenta vērtējums savai vēlmei mācīties. *SAL* – Studenta spējas mācīties. *PU* – Studenta prognoze, vai pēc kursa pabeigšanas apgūtās prasmes students izmantos profesionālām vai privātām vajadzībām. *DS* – Studenta vispārīgās digitālās pamatprasmes.

0. klasteris raksturo studentus, kuri pēc kursa pabeigšanas neizmanto vispār ar kursa tēmu saistītas digitālās prasmes savā ikdienas profesionālajā vai privātajā dzīvē. Šajā klasterī ir apvienoti 298 novērojumi.

1. klasteris raksturo studentus, kuri arī neizmanto jaunapgūtās prasmes, bet turpina izmantot savas esošās digitālās prasmes tādā pašā līmenī kā pirms kursa apguves. Šajā klasterī ir apvienoti 334 novērojumi.

2. un 3. klasteris raksturo studentus, kas jaunapgūtās digitālās prasmes pēc kursa pabeigšanas izmanto savā ikdienā. Šajos klasteros ir apvienoti attiecīgi 147 un 137 novērojumi.

Klasteranalīze atklāja, ka studenti, kuri jaunapgūtās digitālās prasmes lieto pēc kursa pabeigšanas, atrodas divos atšķirīgos klasteros (2. un 3. klasteris). Šo klasteru parametru vērtības ir atšķirīgas. 2. klastera parametru vērtības ir augstākas par 3. klastera vērtībām, izņemot vispārīgo iepriekšējo digitālo prasmju (*DS*) vērtējumu, kas abiem klasteriem ir vienādi augsts 0,7. Izteikti atšķirīga vērtība ir studentu spējai mācīties (*SAL*). 2. klasterim *SAL* vērtība ir 81,0 % no maksimāli iespējamās, bet 3. klasterim, salīdzinot ar visiem klasteriem, ir viszemākā vērtība 23,7 %. 2. klastera vērtības, ja salīdzina ar citiem klasteriem, ir augstākas. Izņēmums ir vispārējās digitālās prasmes *DS* (0,7), kas sakrīt ar 1. un 2. klastera parametru vērtībām. 3. klastera parametru vērtības, salīdzinot ar citiem klasteriem, ir vienas no zemākām, tās ir līdzīgas, kā klasteriem, kuri nelieto digitālās prasmes.

0. klasteris, kas apvieno studentus, kas pēc kursu pabeigšanas nelieto vispār ar tēmu saistītās digitālās prasmes, satur zemākās vērtības parametriem – studenta vēlmei mācīties (*SWL* – 3,6), vispārējām digitālām prasmēm (*DS* – 0,6) prognozētai prasmju lietošanai (*PU* – 3,5), ja salīdzina ar citiem klasteriem. Šim klasterim studenta spēja mācīties (*SAL* – 45,8 %) ir augstāka nekā 3. klasterim, kas apvieno studentus, kuri izmanto jaunapgūtās prasmes.

1. klasterim, kas apvieno studentus, kuri turpina izmantot savas prasmes tajā pašā līmenī, kā pirms mācībām kursā, parametru vērtības (*SWL* – 3,8; *DS* – 0,7; *SAL* – 52,3 %; *ELM* – 4,0; *IWS* – 4,6; *ELE* – 4,1; *PU* – 4,1) ir starp 0. un 2. klastera parametru vērtībām, tas ir, starp vērtībām klasteriem, kuri vispār nelieto digitālās prasmes un kuri lieto jaunapgūtās digitālās prasmes. Izņēmums ir vērtējumam šādiem parametriem: instruktora vēlmei dalīties ar zināšanām un mācību materiālu novērtējumam. Šo atribūtu vērtības sakrīt ar 0. klastera atribūtu vērtībām. Bet vērtējums vispārējām digitālām prasmēm sakrīt ar 2. klasteri.

Prognozētā prasmju lietošana. Iegūtie rezultāti atspoguļo to, ka studenti, kuri pēc kursu pabeigšanas neizmanto digitālās prasmes, sniedz vājākas prognozes par prasmju lietošanu nākotnē. Prognozes vērtība ir 3,5 studentiem, kuri nelieto vispār digitālās prasmes, bet 3,9 vai 4,6 – tiem studentiem, kuri lieto jaunapgūtās prasmes pēc kursu beigām.

Vispārējās digitālās prasmes. Vispārējās digitālās prasmes visos klasteros ir vidēji augstas. Tiem, kas nelieto vispār ar tēmu saistītās digitālās prasmes pēc kursa beigām, ir 0,6, bet pārējiem klasteriem ir 0,7. Atšķirība ir salīdzinoši neliela, var uzskatīt, ka vispārējās digitālās prasmes visiem klasteriem ir līdzīgas.

Iegūtie rezultāti atbilstoši izvirzītajiem pētījuma jautājumiem

Instruktoru ieinteresētība dalīties ar zināšanām. Studentu vērtējums instruktora vēlmei dalīties ar zināšanām neatšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes nelieto pēc mācību kursa beigām.

Iegūtie rezultāti rāda, ka daļa no studentiem, kuri lieto jauniegūtās digitālās prasmes pēc kursa beigšanas, vērtē instruktora vēlmi dalīties ar zināšanām augstāk vai tāpat kā citu klasteru pārstāvji, tas ir, novērtējums ir 4,8 vai 4,9. Citu klasteru studentiem novērtējums ir

4,8. Studentu vērtējums instruktora vēlmei dalīties ar zināšanām būtiski neatšķiras dažādu klasteru studentiem, tas ir salīdzinoši augsts visiem klasteriem, jo iegūts gandrīz maksimāli iespējamais vērtējums 5,0. Līdz ar to var uzskatīt, ka instruktora vēlmes dalīties ar zināšanām vērtējums visiem klasteriem ir līdzīgs.

E-mācību materiāli. Studentu apmierinātības līmenis ar e-mācību materiāliem atšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes nelieto pēc mācību kursa beigām.

Iegūtie rezultāti rāda, ka daļa studentu, kuri lieto jaunapgūtās prasmes, ir apmierinātāki ar mācību materiāliem, salīdzinot ar citu klasteru studentiem. Šo studentu vērtējums ir 4,5. Tomēr daļa no tiem studentiem, kas lieto jaunapgūtās prasmes, mācību materiālus vērtē zemāk, tas ir 3,8. Šis vērtējums ir pat nedaudz zemāks par citu klasteru studentu vērtējumu. E-mācību materiālu vērtējums, kuri nelieto jaunapgūtās prasmes ir 3,9 un 4,0. Šie vērtējumi ir tuvāk zemākajai robežai, kā vērtē studenti, kuri lieto jaunapgūtās prasmes pēc kursu beigšanas. Rezultāti rāda, ka augstākais vērtējums 4,5, kas ir tuvu maksimāli iespējamam 5,0, liecina par to, ka students pieder klasterim, kas turpinās lietot jaunapgūtās digitālās prasmes pēc kursa apguves beigām, bet zemākais vērtējums 3,8 ir tuvu pārējo klasteru vērtējumam, kuri nelieto jaunapgūtās digitālās prasmes. Līdz ar to var uzskatīt, ka augstāks e-materiālu vērtējums liecina par piederību klasterim, kur studenti izmanto jaunapgūtās digitālās prasmes.

E-studiju vide. Studentu apmierinātības līmenis ar e-vidi atšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes nelieto pēc mācību kursa beigām.

Iegūtie rezultāti rāda, ka daļa studentu, kuri lieto jaunapgūtās prasmes, ir apmierinātāki ar e-vides lietošanu, to vērtējumi ir atšķirīgi no citiem klasterim. Šo studentu vērtējums ir augstāks: 4,5. Tomēr daļa no studentiem, kas lieto jaunapgūtās digitālās prasmes, vērtē e-studiju vidi pat zemāk nekā citu klasteru studenti: 4,0. Šis zemākais vērtējums neatšķiras daudz no citu studentu klasteru vērtējuma, kas ir 4,1. Līdz ar to var uzskatīt, ka augstākais vērtējums 4,5, kas ir tuvu maksimāli iespējamam 5,0, liecina par to, ka students pieder klasterim, kas turpinās lietot jaunapgūtās prasmes, bet zemākie vērtējumi ir tuvu pārējo klasteru, kuri nelieto, vērtējumam.

Studenta vēlme mācīties. Studentu vēlme mācīties neatšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes nelieto pēc mācību kursa beigām.

Iegūtie rezultāti rāda, ka studenti, kuri lieto jaunapgūtās prasmes, vērtē savu vēlmi apgūt digitālās prasmes atšķirīgi no citiem klasterim, šo studentu vērtējums ir gan augstāks no visiem klasteriem: 4,0, gan daļai zemāks 3,7. Tomēr vērtējumi neatšķiras daudz no citu studentu klasteru vērtējumiem, kas ir 3,6 un 3,8. Līdz ar to var uzskatīt nav būtiskas atšķirības studentu vēlmei mācīties dažādiem klasteriem.

Studenta spējas mācīties. Studentu spējas mācīties atšķiras studentiem, kuri turpina lietot apgūtās digitālās prasmes pēc mācību kursa beigām, no tiem studentiem, kuri jaunapgūtās prasmes nelieto pēc mācību kursa beigām.

Iegūtie rezultāti rāda, ka daļai studentu, kuri lieto jaunapgūtās prasmes, spējas mācīties ir augstākas par citu klasteru vērtībām, tas ir, tiem piemīt 81,0 % no maksimālās spējas mācīties. Daļai studentu, kuri arī turpina lietot jauniegūtās digitālās prasmes, spēja mācīties ir viszemākā – 23,7 % no maksimāli iespējamā. Pārējiem klasteriem vērtējums ir 45,8 % (nelieto vispār digitālās prasmes) un 52,3 % (lieto, bet, neizmanto jauniegūtās). Iespējams, ka

zemā studentu spēja mācīties ir izskaidrojama ar to, ka students savas zināšanas pirms tēmas ir novērtējis salīdzinoši augstu vai pat ar maksimāli augstāko vērtējumu. Tāpēc studentam nav bijusi iespēja parādīt, ka pēc tēmas viņas zināšanas ir pieaugušas. Šo studentu augstais zināšanu līmenis varētu izskaidrot studentu kritisko attieksmi, tas ir, salīdzinoši zemo vērtējumu e-vidē – 4,0 un e-materiāliem par apgūstamo tēmu – 3,8, jo tie studentam nav daudz noderējuši. Kā arī ne pārāk augsto vērtējumu vēlmei mācīties – 3,7, jo studentam jau ir bijušas pietiekamas zināšanas par kursu.

Kopsavilkums un secinājumi par indivīdu e-iekļautības klasteru izveidi un e-iekļautību raksturojošiem faktoriem zināšanu radīšanas un pārneses kontekstā

Klasteranalīzes pētījuma rezultāti parādīja, ka ne visiem indivīda e-iekļautību raksturojošajiem mainīgiem ir atšķirīgas vērtības, ja atšķiras indivīda e-iekļautības pakāpe. Neatšķiras vērtējumi par studenta vēlmi mācīties un instruktora vēlmi dalīties ar zināšanām. Toties vērtējumi par e-vidi, e-materiāliem un spēju mācīties ir atšķirīgi dažādu e-pakāpju klasteriem.

Par e-vidi. Studenti, kuri lieto digitālās prasmes, e-vidi vērtē augstāk. E-vidē visiem studentiem ir viena un tā pati, tomēr vērtējumi ir dažādi. Tas nozīmē, ka daļai e-vidē ir pieņemamāka, izprotamāka, ērtāk lietojama, nekā citai studentu daļai. Tas rada secinājumus, ka jāpievērš uzmanība tam, kā students jūtas e-vidē. Jāprecizē, kur studentam ir problēmas un laikā, kamēr students apgūst e-vidē mācību kursu, jāpiedāvā studentam dažādas iespējas, kas atvieglotu studentam e-vides lietošanu. Piemēram, jāpiedāvā atbalstoši materiāli zināšanu pilnveidei par darbošanos e-vidē, par iespējām tajā. Otrkārt, jānodrošina, ka students var uzlabot savu darbošanos e-vidē to personalizējot, sistēmai jābūt spējīgai, pielāgoties studenta spējām un vajadzībām. E-vidē studenta vērtējumā ir jābūt ērti, studentam pieņemamā veidā lietojamai, lai tā sekmētu studenta e-iekļaušanos.

Par mācību materiāliem. Studenti, kuri lieto jaunapgūtās digitālās prasmes mācību materiālus vērtē augstāk par citu klasteru studentiem. Vērtējums ir augsts, tuvu maksimāli iespējamam, kas liecina, ka studenti vērtē materiālus kā piemērotus, ērti izmantojamus, saprotamus. Ņemot vērā to, ka visiem studentiem mācību materiāli ir vienādi, to attieksme pret materiāliem ir dažāda. Tas norāda uz to, ka studentu vajadzības ir atšķirīgas un e-iekļaušanas procesa mērķu sasniegšanai ir nepieciešams e-vidē nodrošināt to, ka mācību materiāli tiek pielāgoti studenta vajadzībām, studentam ir iespējas izvēlēties mācību materiāla formu (teksts, video, prezentācija, vingrinājumi, testi utt.), studentam ir iespējams papildus saturiski iedziļināties atsevišķos tematos utt. Sistēmai ir jānodrošina, ka studentam ir iespējas pielāgot materiālus (pēc formas) savām vajadzībām. Mācību materiāliem studenta vērtējumā ir jābūt gandrīz izciliem, lai tie sekmētu studenta e-iekļaušanos.

Par spēju mācīties. Klasteranalīzē iegūtie rezultāti uzrāda, ka studentiem, kuri pēc kursa beigšanas lieto digitālās prasmes profesionālajām vai privātajām vajadzībām, spēja mācīties ir radikāli atšķirīga – gan visaugstākā, gan viszemākā. Ņemot vērā to, ka spēja mācīties ir saistīta ar studentu zināšanu pašvērtējumu pirms un pēc tēmas apguves un to, ka zināšanu apguve notiek izmantojot tēmas e-materiālus, kas visiem studentiem ir vienādi, tad varētu būt, ka studenta neapmierinātība ar mācību materiāliem ietekmē studenta spējas apgūt kursa tēmas. Klasteranalīze uzrādīja arī, ka šie studenti ar viszemākajām spējām mācīties, viszemāk vērtē mācību materiālus. Tomēr šie studenti lieto jauniegūtās digitālās prasmes pēc kursu apguves.

Par datu kopas analīzi, apvienojot datus no dažādām kursa tēmām. Klasteranalīzes rezultāti parāda, ka var iegūt studentu klasterus par visa kursa tēmām, nevis katrai atsevišķai kursa tēmai.

Par centroīdu vērtībām un klasteranalīzi studenta e-iekļautības paredzēšanai. Klasteranalīzes rezultāti norāda, ka studentus var sadalīt klasteros, vadoties pēc tā, kādā veidā studenti pēc kursu apgūšanas lieto jauniegūtās digitālās prasmes. Studentus raksturojošo mainīgo centroīdi dažādiem klasteriem ir atšķirīgi, tomēr var novērot tendenci, ka tiem klasteriem, kur iekļauti studenti, kas lieto jaunapgūtās prasmes centroīdu vērtības ir augstākas, salīdzinot ar tiem klasteriem, kur studenti nelieto jauniegūtās prasmes. Autore secina, ka, zinot klasteru centroīdu vērtības, tas ir – e-iekļautības faktoru mainīgo vērtības, var novērtēt, kādam klasterim būs piederīgs students, kam jānosaka tā e-iekļautības pakāpe. Tādējādi klasteranalīzi ir iespējams izmantot studenta e-iekļautības paredzēšanā, izmantojot indivīda e-iekļautības faktoros.

3.5. Indivīda e-iekļautības modelēšana ar klasifikācijas algoritmiem un e-iekļautības faktoriem

Šīs apakšnodaļas mērķis ir aprakstīt pētījumu, kurā, izmantojot klasifikācijas algoritmus, ir pārbaudīts, vai ar iepriekš noteiktajiem e-iekļaušanu ietekmējošajiem faktoriem var prognozēt indivīda e-iekļautības pakāpi.

Pētījuma mērķis un pētnieciskie jautājumi

Pētījuma mērķis ir noskaidrot, cik lielā mērā, izmantojot klasifikācijā balstītas metodes un iepriekš noteiktos indivīda e-iekļautību raksturojošos faktoros, iespējams paredzēt e-iekļautību profesionālo izglītības iestāžu pedagogiem, kuri apgūst digitālās prasmes instruktora vadībā klātienē un attālinātās nodarbībās e-vidē.

Pētījuma jautājumi:

1) noskaidrot, kuri klasifikatori ģenerē modeļus ar augstākiem veikspējās rādītājiem F1 mēram, paredzot indivīda e-iekļautību;

2) noskaidrot, vai ir tāds klasifikators, ar kuru ģenerētie modeļi uzrāda augstākos veikspējās rādītājus F1 mēram visiem trīs mācību kursiem: video tehnoloģijas un dizains; mobilās tehnoloģijas; robotika;

3) noskaidrot, kā dažādiem datu kopu veidiem atšķiras modeļu veikspējās rādītāji F1 mēram.

Pētījuma dalībnieki, izmantotie dati un metodes indivīda e-iekļautības prognozēšanai

Pētījuma dalībnieki ir profesionālo izglītības iestāžu pedagogi, kuri apgūst mācību programmas “Mūsdienu interešu izglītība” trīs kursus: mobilās tehnoloģijas; robotika; video tehnoloģijas. Kursu apguve notiek instruktora vadībā klātienē un attālinātās nodarbībās, izmantojot Moodle platformā izvietotus mācību materiālus.

Lai raksturotu profesionālo izglītības iestāžu pedagogus (mācīšanās kontekstā tiek dēvēti par studentiem), kuri apgūst digitālās prasmes programmā “Mūsdienu interešu izglītība”, tiek izmantoti e-iekļaušanas faktoros raksturojošie atribūti (mainīgie).

Pētījumā izmantotais e-iekļaušanas faktors – instruktora vēlme un spēja dalīties ar zināšanām e-mācību kursa laikā, – tiek mērīts ar trīs atribūtiem (iespējamās vērtības ir no 1 līdz 5):

1. “Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām”, *IWS*;
2. “Studenta vērtējums apmierinātībai ar e-materiāliem”, *ELM*;
3. “Studenta vērtējums apmierinātībai ar e-vidi”, *ELE*.

Pētījumā izmantotais e-iekļaušanas faktors – studenta vēlme un spējas apgūt digitālās prasmes e-mācību kursa laikā – tiek mērīts ar diviem atribūtiem:

1. “Studenta vērtējums savai vēlmei mācīties”, *SWL*, (iespējamās vērtības ir no 1 līdz 5).
2. “Studenta spējas mācīties”, *SAL*, (iespējamās vērtības ir no 1 līdz 5).

E-iekļautības pakāpi autore nosaka, izmantojot atribūtu: novērotā prasmju lietošana studentam, *OU*. Mainīgajam ir divas iespējamās vērtības:

- 0 jeb “nav e-iekļauts” – ja tiek novērots, ka izglītojamais neizmanto tikko iegūtās prasmes pēc kursa beigām.
- 2 jeb “e-iekļauts” – ja tiek novērots, ka izglītojamais izmanto nesenu apgūtās prasmes profesionālām vajadzībām, kad mācību kurss ir beidzies

Papildus šiem atribūtiem autore izmanto:

- “Studenta prognoze” – vai pēc kursa pabeigšanas apgūtās prasmes students izmantos profesionālām vai privātām vajadzībām, *PU*, (iespējamās vērtības ir no 1 līdz 5).
- “Studenta vispārīgās digitālās pamatprasmes”, *DS*, (iespējamās vērtības ir no 1 līdz 5).

Pētījuma veikšanai autore sagatavoja 12 datu kopas. Katram no kursiem (mobilās tehnoloģijas; robotika; video tehnoloģijas) tika izveidotas datu kopas, kas satur visu studentu ierakstus vai kas satur tikai to studentu ierakstus, kam ir tehnoloģijas jaunapgūto prasmju izmantošanai. Datu kopas tika līdzsvarotas. Pētījuma dalībnieki, datu ieguves metodes un izmantotā datu kopas detalizētāk ir aprakstītas 3.1. un 3.2. apakšnodaļās.

Prognozējošā modeļa izveides metode. Lai sagrupētu profesionālo pedagogus “e-iekļauto” un “ne e-iekļauto” grupās, balstoties uz pedagogus raksturojošiem datiem, tika izmantoti klasifikācijas un mašīnmācīšanās metodes prognozējošā modeļa apmācībai.

Pētījumā tika apmācīti pieci klasifikācijas modeļi, izmantojot šādus klasifikatoru ģenerēšanas algoritmus: *NaiveBayes*, *SimpleLogistic*, *LWL*, *OneR* un *LMT Waikato Environment for Knowledge Analysis (WEKA)* platformā. Autore izvēlējās šos piecus klasifikatoru ģenerēšanas algoritmus atbilstoši *WEKA* platformas kategorijām, nodrošinot atšķirīgas metodes problēmas risināšanai (3.20. tab.). *WEKA* platformā tika saglabāta klasifikatoru parametru noklusējuma konfigurācija, pamatojoties uz to, ka literatūrā pieejamajos pētījumos ir norādīts, ka parametru noklusējuma konfigurācija nodrošina optimālu veikspēju lielākajai daļai klasifikatoru (*Amancio* u. c., 2014).

Klasifikācijas modeļu veikspējas novērtēšanas rādītāji. Izveidoto klasifikācijas modeļu veikspējas novērtēšanai autore izmanto pārpratuma matricas metodiku un nosaka modeļa precizitāti (*nav e-iekļauts* klasei), pārklājumu (*nav e-iekļauts* klasei), akurātumu, līdzsvaroto akurātumu, F1 un F2 mērus.

E-iekļautību prognozējošo klasifikācijas modeļu novērtēšanas stratēģija. E-iekļautību prognozējošo klasifikācijas modeļu novērtēšanai tiek izmantota desmitkārtīgā šķērsvalidācija. (*Yadav* un *Shukla*, 2016).

Indivīda e-iekļautības prognozēšanai izmantotie klasifikatoru ģenerēšanas algoritmi.

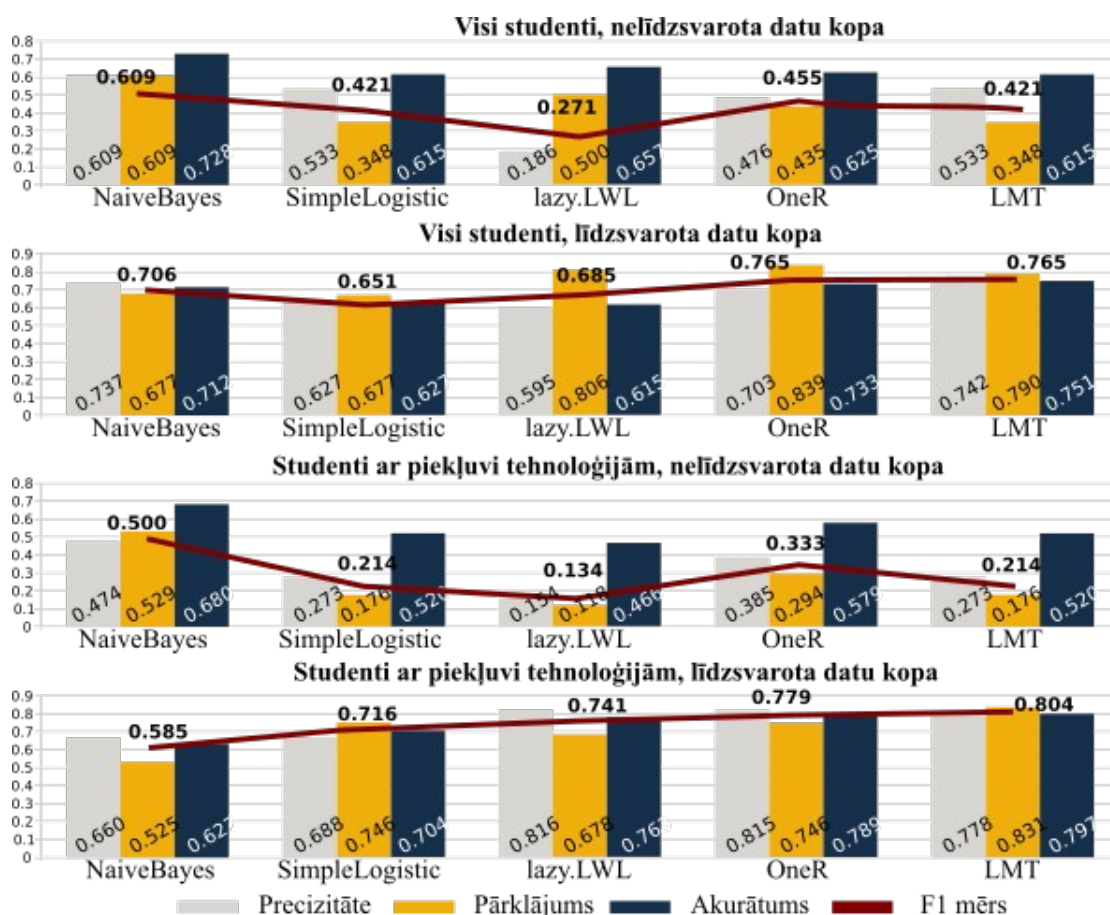
Kategorija	Klasifikatoru ģenerēšanas algoritms	Apraksts
Beijesa	Naivais Beijesa (angļu val. – <i>Naive Bayes</i>)	Naivais Beijesa klasifikators izmanto novērtējuma klases. Skaitliskas novērtējuma precizitātes vērtības tiek izvēlētas balstoties uz apmācības datu analīzi (<i>John u. c., 1995</i>).
Funkcija	Vienkāršā loģistika (angļu val. – <i>Simple-Logistic</i>)	Klasifikators, kas veido lineārus loģistiskās regresijas modeļus (<i>Landwehr u. c., 2005</i>).
Slinkā - atliktā mācīšanās (angļu val. – <i>Lazy-learning</i>)	<i>LWL</i> (angļu val. – (<i>Locally weighted learning</i>))	<i>LWL</i> izmanto uz instancēm balstītu algoritmu, lai piešķirtu instances svarus, kuri pēc tam tiek izmantoti (<i>Atkeson u. c., 1997; Englert u. c., 2012</i>). Ar <i>LWL</i> algoritmu var veikt klasifikāciju vai regresiju.
Koki (angļu val. – <i>Tree-based Learning</i>)	<i>LMT</i> (angļu val. – <i>logistic model trees</i>)	Klasifikators, kas būvē loģistikas modeļu kokus, kas ir koki ar loģistiskās regresijas funkcijām pie koku lapām. (<i>Landwehr u. c., 2005</i>).
Likumi (angļu val. – <i>Rules-based Learning</i>)	<i>OneR</i>	<i>OneR</i> ir vienkārša klasificēšanas metode, kas balstās uz 1 līmeņa lēmuma koku (<i>Holte, 1993</i>).

Rezultāti: indivīda e-iekļautības modelēšana ar klasifikatoriem un e-iekļautības faktoriem

Indivīda e-iekļautības prognozēšanai tika izmantoti pieci klasifikatoru ģenerēšanas algoritmi. Ar katru no izveidotajiem klasifikācijas modeļiem tika prognozēts, izmantojot oriģinālo un līdzsvaroto datu kopu, kas tika iegūtas no: (1) visu studentu datu kopas; (2) to studentu datu kopas, kuriem ir piekļuve tehnoloģijām. Indivīda e-iekļautību prognozējošie rezultāti ir iegūti katram no trīs kursiem: video tehnoloģijas un dizains; mobilās tehnoloģijas; robotika. Turpinājumā aprakstīti iegūtie rezultāti katram kursam, kurus apguva profesionālo izglītības iestāžu pedagogi.

E-iekļautības prognozēšanas klasifikācijas modeļu veiktspējas rādītāji video tehnoloģiju un dizaina kursam

3.7. attēlā ir parādīti veiktspējas rādītāji pieci klasifikācijas modeļiem, kas apmācīti prognozēt studentu e-iekļautību pēc Video tehnoloģiju un dizaina kursa pabeigšanas.



3.7. att. Klasifikācijas modeļu veikspējas rādītāji video tehnoloģiju un dizaina kursam.

Ar *LMT* algoritmu veidotajam modelim ir visaugstākais F1 mērs 0,804, ja ir līdzsvaroti dati par studentiem, kuriem ir piekļuve tehnoloģijām. Šajā gadījumā akurātums ir 0,797, precizitāte ir 0,778, pārklājums ir 0,831. *LMT* klasifikācijas algoritmam ir visaugstākā akurātuma vērtība salīdzinājumā ar citiem algoritmiem. *LMT* klasifikācijas algoritma precizitāte norāda, ka studenti 77,80 % pareizi tiek klasificēti “nav e-iekļauts” klasē. *LMT* klasifikācijas modeļa pārklājuma vērtība parāda, ka 83,10 % no “nav e-iekļauts” klases izglītojamajiem ir pareizi klasificēti. Ar *LMT* klasifikācijas modeli pareizi tiek prognozēti 79,70 % gadījumu no kopējā gadījumu skaita.

Otrs augstākais vērtējums F1 mēram ir 77,90 % ar *OneR* algoritmu veidotajam klasifikācijas modelim līdzsvarotai datu kopai studentiem ar piekļuvi tehnoloģijām. Bet trešais augstākais F1 vērtējums 76,50 % ir *LMT* un *OneR* klasifikācijas modeļiem visu studentu līdzsvarotiem datiem. *OneR* klasifikācijas modelim ir visaugstākais pārklājuma rādītājs 0,839. Ar *lazy.LWL* algoritmu veidotajam modelim ir visaugstākā precizitātes pakāpe 0,816 līdzsvarotai datu kopai, ja izglītojamiem ir piekļuve tehnoloģijām.

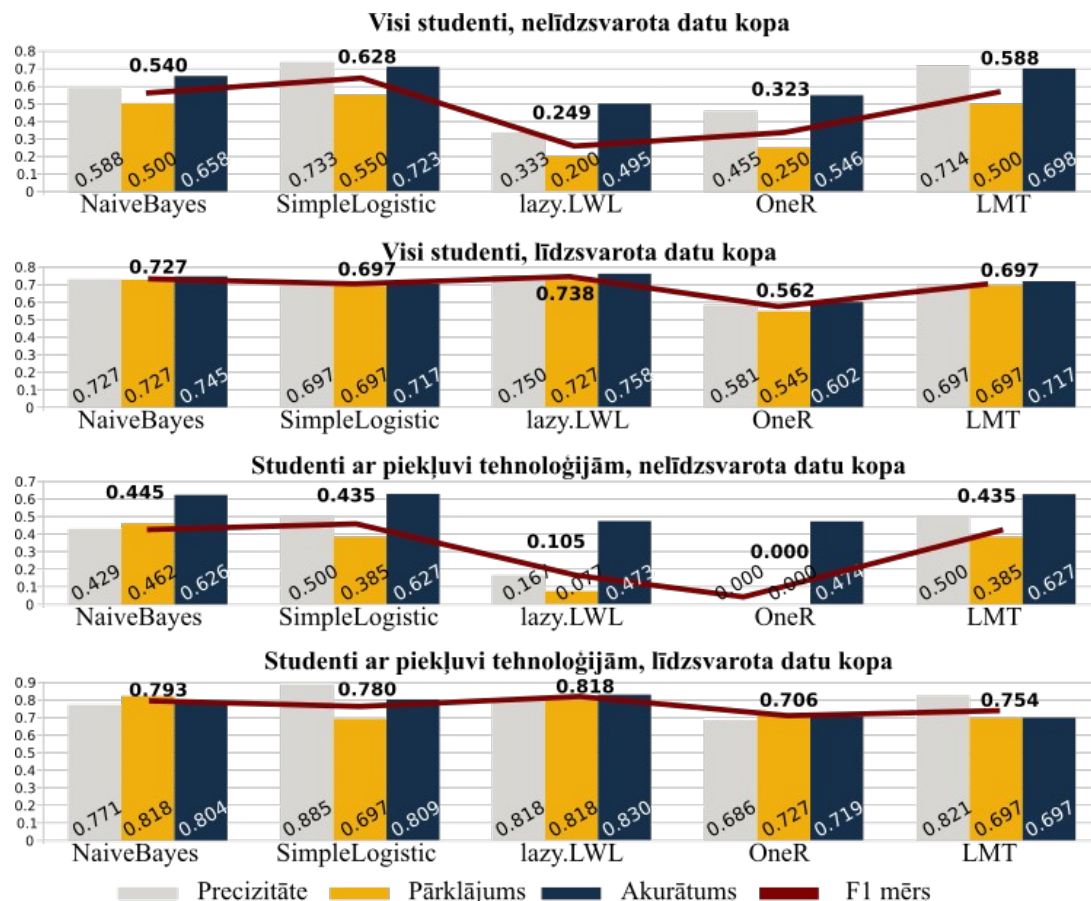
Nelīdzsvarotām datu kopām ir viszemākie rādītāji, piemēram, ar *lazy.LWL* algoritmu F1 mērs ir tikai 13,40 % studentiem ar piekļuvi tehnoloģijām. Klasifikācijas modeļi uzrāda augstākus rādītājus līdzsvarotu datu kopu gadījumā studentiem ar piekļuvi tehnoloģijām.

Pēc datu kopu līdzsvarošanas F1 mērs visvairāk uzlabojās *LMT* un *lazy.LWL* modeļiem. Visu studentu datu kopā *lazy.LWL* modelim F1 mēra rādītāji uzlabojās par 0,413 un *LMT* modelim par 0,344. Datu kopā par studentiem, kam ir pieeja tehnoloģijām, F1 mēra rādītāji uzlabojās *lazy.LWL* klasifikācijas modelim par 0,607 un *LMT* klasifikācijas modelim par

0,590 (3.10., 3.11. att.).

E-iekļautības prognozēšanas klasifikācijas modeļu veikspējas rādītāji mobilo tehnoloģiju kursam

3.8. attēlā ir parādīti veikspējas rādītāji pieciem klasifikācijas modeļiem, kas apmācīti prognozēt studentu e-iekļautību pēc mobilo tehnoloģiju kursa pabeigšanas.



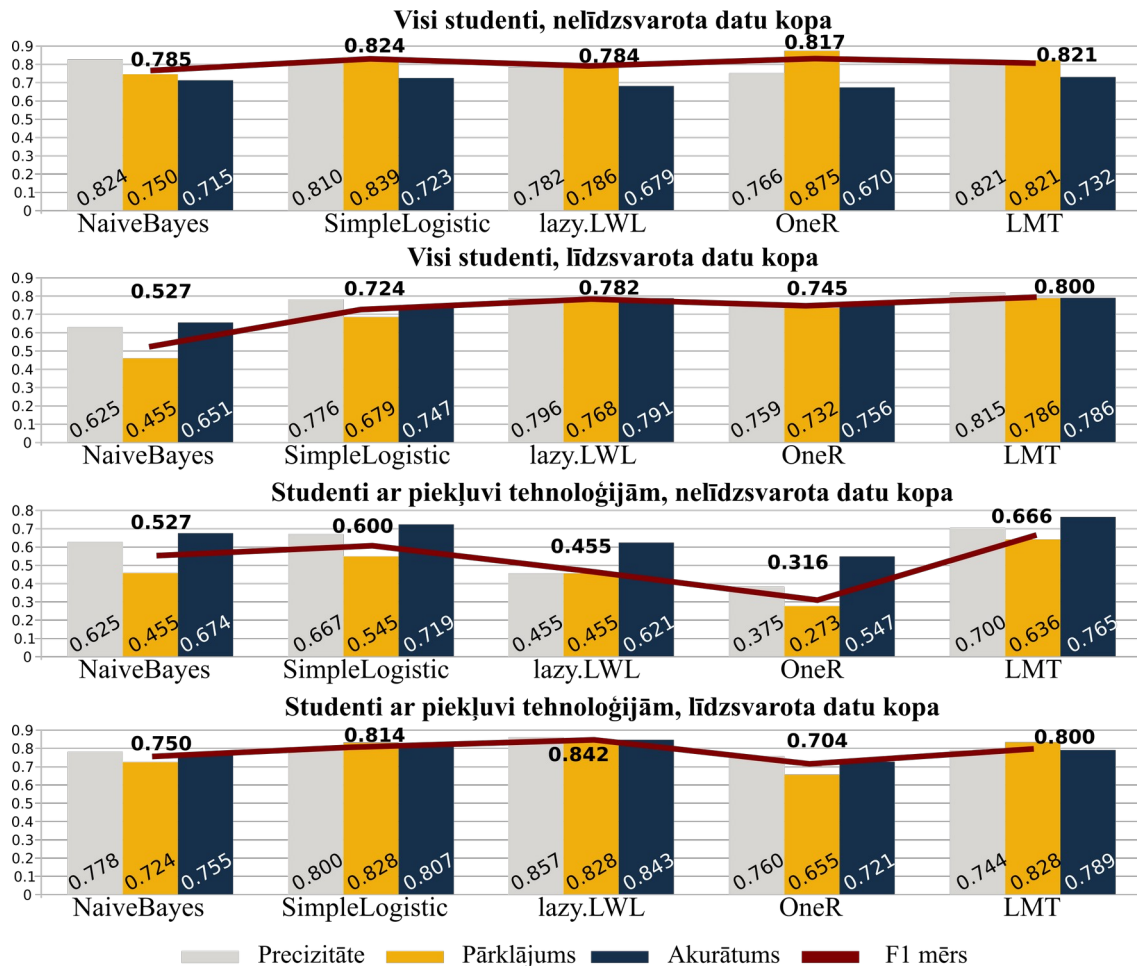
3.8. att. Klasifikācijas modeļu veikspējas rādītāji mobilo tehnoloģiju kursam.

Līdzsvarotas datu kopas gadījumā izglītojamiem ar piekļuvi tehnoloģijām izveidotie klasifikācijas modeļi uzrāda vairākus augstākos rādītājus.

Mobilo tehnoloģiju kursā ar *lazy.LWL* algoritmu ģenerētajam klasifikācijas modelim studentiem ar piekļuvi tehnoloģijām līdzsvarotai datu kopai ir visaugstākais F1 mēra rādītājs 0,818 atbilstoši akurātums ir 0,830, precizitāte ir 0,818, pārklājums arī – 0,818. Precizitāte norāda, ka 81,80 % no tiem studentiem, kas tiek klasificēti kā “nav e-iekļauts”, ir pareizi klasificēti. Pārklājums norāda, ka 81,80 % no visiem tiem studentiem, kas pieder klasei “nav e-iekļauts”, klasifikācijas algoritms ir klasificējis pareizi. Saskaņā ar akurātuma rādītāju 83,00 % no kopējā studentu (gan “e-iekļauts”, gan “nav e-iekļauts”) skaita ir pareizi klasificēti. Otrs augstākais F1 mēra rādītājs ir 79,30 % ar Naivā Beijesa (angļu val. – *NaiveBayes*) algoritmu veidotajam modelim. Ar *SimpleLogistic* algoritmu veidotajam modelim ir visaugstākā precizitāte 0,885. Vislielākais pārklājums 0,818 ir Naivā Beijesa un *lazy.LWL* klasifikācijas modeļiem. Vislielākā akurātuma vērtība ir 0,830 *lazy.LWL* klasifikācijas modelim.

Tāpat kā video tehnoloģiju un dizaina kursā, modeļa veikspēja uzlabojās pēc datu kopu

līdzsvarošanas un studentu, kuriem nebija piekļuves tehnoloģijām, izslēgšanas. *lazy.LWL* klasifikatoram ir visaugstākais F1 mēra rādītāja uzlabojums – par 0,713 studentiem ar piekļuvi tehnoloģijām un par 0,488 visu studentu datu kopai. Otrs augstākais pieaugums F1 mēram ir *OneR* klasifikācijas modelim – par 0,706 studentiem ar piekļuvi tehnoloģijām un par 0,240 visu studentu datu kopai (3.10., 3.11. att.).




3.9. att. Klasifikācijas modeļu veiktspējas rādītāji robotikas kursam.

Tāpat kā citosursos, arī robotikas kursā augstākais rezultāts klasifikācijas modeļiem ir līdzsvarotai datu kopai studentiem, kuriem ir piekļuve tehnoloģijām (3.9. att.). Robotikas kursā augstākais F1 mēra rādītājs 0,842 ir ar *lazy.LWL* algoritmu ģenerētajam modelim līdzsvarotā datu kopā studentiem, kuriem ir piekļuve tehnoloģijām. Ar *lazy.LWL* algoritmu modelim akurātums ir 0,843, precizitāte ir 0,857, pārklājums ir 0,828. Precizitāte norāda, ka 85,70 % no izglītojamo prognozēm par pozitīvo klasi (“nav e-iekļauts” klase) ir pareizas. Pārklājums rāda, ka 82,80 % no tiem izglītojamajiem, kam ir digitālās atstumtības risks, ir pareizi klasificēti klasē “nav e-iekļauts”. Saskaņā ar iegūto akurātuma rādītāju 84,30 % no kopējā gadījumu skaita ir pareizi klasificēti.


Otrs augstākais rezultāts ir F1 mēram ir 0,824 *SimpleLogistic* klasifikācijas modelim. Bet trešais augstākais F1 mēra rādītājs ir 0,821 *LMT* klasifikācijas modelim. Nelīdzsvarotu datu gadījumā *OneR* modelim ir visaugstākā pārklājuma vērtība 0,875 datu kopai ar visiem studentiem.

Pēc datu kopas līdzsvarošanas vairāku klasifikācijas modeļu rādītāji samazinās.

Piemēram, tie samazinās ar Naivā Beijesa un *OneR* algoritmiem veidotajiem modeļiem. Tas izskaidrojams ar to, ka nelīdzsvarotai datu kopai robotikas kursa studentu skaits, kuri neizmantoja jauniegūtās prasmes (klase “nav e-iekļauts”), pārsniedza to studentu skaitu, kuri izmantoja jaunās prasmes (klase “e-iekļauts”). Tāpēc pēc datu līdzsvarošanas dažiem algoritmiem samazinājās pārklājuma un precizitātes vērtības. Pārklājums un precizitāte tiek aprēķināta pozitīvajai klasei (“nav e-iekļauts”), bet robotikas kursā šajā klasē pirms datu līdzsvarošanas ir lielāks gadījumu skaits, salīdzinot ar klasi “e-iekļauts”. Vislielākais F1 mēra rādītāju pieaugums 0,388 ir *OneR* klasifikācijas modelim pēc datu līdzsvarošanas visu studentu datu kopai (3.10., 3.11 att.).




3.10. att. Izmaiņas F1 mēra vērtībām 5 klasifikācijas modeļiem pēc visu studentu datu kopas līdzsvarošanas 3 dažādiem mācību kursiem.



3.11. att. Izmaiņas F1 mēra vērtībām 5 klasifikācijas modeļiem pēc studentu, kam ir piekļuve tehnoloģijām, datu kopas līdzsvarošanas 3 dažādiem mācību kursiem.

LMT klasifikācijas modelim visu mācību kursu vidējais F1 mēram ir visaugstākā vērtība

0,770, ja datu kopas ir līdzsvarotas (3.12. att.). Otrs visaugstākais visu mācību kursu vidējais F1 mērs ir *lazy.LWL* klasifikācijas modelim – 0,768. Ja datu kopas nav līdzsvarotas, tad visu mācību kursu vidējais F1 mērs ir visaugstākais *NaiveBayes* klasifikācijas modelim – 0,568, bet otrs visaugstākais LMT klasifikācijas modelim.



3.12. att. 3 dažādu mācību kursu vidējo F1 mēru salīdzinājums 5 klasifikācijas modeļiem līdzsvarotām un nelīdzsvarotām datu kopām.

Kopsavilkums un secinājumi par indivīda e-iekļautības modelēšanu ar klasifikācijas algoritmiem un e-iekļautības faktoriem

Šajā pētījumā autore aprakstīja indivīda e-iekļautības prognozēšanas modeļus, izmantojot klasifikatoru ģenerēšanas algoritmus. Klasifikācijas modeļi paredz, kurai klasei profesionālo izglītības iestāžu pedagogi, kas apgūst digitālās prasmes, piederēs – jauniegūto prasmju lietotājiem (“e-iekļauts” klase) vai nelietotājiem (“nav e-iekļauts” klase).

Atbilstoši izvirzītajiem pētījuma jautājumam ir noskaidrots, ka dažādiem datu kopu veidiem atšķiras veikspējas rādītāji F1 mēram. Pētījumā iegūtie F1 mēra rādītāji apstiprina, ka datu kopas līdzsvarošana pirms klasifikācijas modeļu ģenerēšanas procedūras uzlabo veikspējas rezultātus izveidotajiem klasifikācijas modeļiem, it īpaši ar *lazy.LWL* algoritmu ģenerētajiem modeļiem.

Pētījumā ir salīdzināti pieci dažādi klasifikācijas modeļi un konstatēts, ka vislabākie veikspējas rādītāji F1 mēram ir modeļiem, kas izmanto apmācībai līdzsvarotas datu kopas, studentiem ar piekļuvi tehnoloģijām.

Atbilstoši izvirzītajiem pētījuma jautājumam ir noskaidrots, ka nepastāv viens klasifikatoru ģenerēšanas algoritms, ar kuru veidotie klasifikācijas modeļi uzrāda vislabākos veikspējas rādītājus visos trīs mācībuursos. Ar *LMT* algoritmu veidotajam klasifikācijas modelim ir visaugstākais F1 mēra rādītājs 0,842 robotikas kursā. Mobilo tehnoloģiju kursā visaugstākais F1 mēra rādītājs 0,818 ir ar *lazy.LWL* algoritmu veidotajam klasifikācijas modelim, bet video tehnoloģiju un dizaina kursā visaugstākais F1 mēra rādītājs 0,804 ir ar *LMT* algoritmu veidotajam klasifikācijas modelim.

Atbilstoši pētījuma jautājumam ir noskaidrots, ka no visiem pieciem izmantotajiem klasifikatoru ģenerēšanas algoritmiem var izcelt divus: *lazy.LWL* un *LMT*. Ar šiem

algoritmiem veidotie modeļi uzrādīja visaugstākos veiktspējas rādītājus.

Turklāt ar *lazy.LWL* un *LMT* algoritmiem veidotie modeļi sabalansētām datu kopām uzrādīja augstākos visu mācību kursu vidējos F1 mēra rādītājus: *lazy.LWL* klasifikācijas modeļu vidējais F1 mērs ir 0,768, *LMT* klasifikācijas modeļu vidējais F1 mērs ir 0,770. Tādējādi var uzskatīt, ka *lazy.LWL* un *LMT* klasifikācijas modeļus var izmantot dažādiem digitālo prasmju attīstības kursiem. Ar *lazy.LWL* klasifikācijas modeli iespējams prognozēt neiekļautos izglītojamos ar veiktspējas F1 mēra rādītāju, kas svārstās no 0,741 līdz 0,842, ja ir līdzsvarotas izglītojamo datu kopas, kurām ir piekļuve tehnoloģijām. *lazy.LWL* klasifikācijas modeļa veiktspējas rādītāji katram kursam ir atšķirīgi. *lazy.LWL* algoritma pārklājums līdzsvarotai datu kopai studentiem ar piekļuvi tehnoloģijām ir robežās no 0,678 līdz 0,828, precizitāte svārstās no 0,816 līdz 0,857, akurātums ir no 0,763 līdz 0,843. Visaugstākie rādītāji ir precizitātes vērtībām. Ar *lazy.LWL* klasifikācijas modeli prognoze vismaz 81,60 % izglītojamo ir pareiza, tiek atpazīsti vismaz 67,80 % studentu, kuriem ir risks, ka nelietots jaunapgūtās prasmes, un vismaz 76,30 % studentu ir pareizi noteikts, kurai no klasēm “e-iekļauts” vai “nav e-iekļauts” tie atbilst. Ar *LMT* klasifikācijas modeli ir iespējams noteikt, vai students pēc kursa pabeigšanas lietos jaunapgūtās prasmes ar veiktspējas F1 mēra rādītāju, kas svārstās no 0,754 līdz 0,804, ja ir līdzsvarotas izglītojamo datu kopas, kurām ir piekļuve tehnoloģijām. Līdzīgi kā *lazy.LWL* klasifikācijas modelim arī *LMT* modeļa rādītāji ir atšķirīgi katrā no kursiem. *LMT* klasifikācijas modeļa pārklājums līdzsvarotai datu kopai studentiem ar piekļuvi tehnoloģijām ir robežās no 0,697 līdz 0,831, precizitāte svārstās no 0,744 līdz 0,821, akurātums ir no 0,697 līdz 0,797. Tādējādi ar *LMT* klasifikācijas modelī tiks atpazīti vismaz 69,70 % no studentiem, kam ir risks nelietot jaunapgūtās digitālās prasmes, prognozes precizitāte par riska grupas studentiem ir vismaz 74,40 %, modeļa akurātums, kas raksturo pareizi atpazītos studentus no abām klasēm (“e-iekļauts” vai “nav e-iekļauts”), ir vismaz 69,70 %.

Secinājumi

Pētījums parādīja, ka viena daļa no tiem studentiem, kas pēc kursa apguves nelietos jaunapgūtās prasmes, ir izglītojamie, kuriem nav pieejamas atbilstošas tehnoloģijas. Piekļuve tehnoloģijai ir būtisks priekšnoteikums, lai izglītojamais pēc kursu pabeigšanas lietu jaunapgūtās prasmes, kā arī, lai prognozētu, vai izglītojamais izmantos jauniegūtās prasmes. Pirms apmācības uzsākšanas ir svarīgi pārbaudīt izglītojamā iespējas tehnoloģiju pieejamībai. Tehnoloģiju pieejamība varētu būt jautājums, ko izglītojamie varētu risināt kopā ar organizāciju, kas nosūta izglītojamo uz kursiem. Tas varētu būt veids, kā organizācija varētu samazināt nelietderīgi iztērētus finanšu līdzekļus un cilvēkstundas reāli neizmantojamu prasmju apguvei.

Veiktais pētījums ļauj secināt, ka indivīda e-iekļautības faktori ar klasifikācijas metodēm ļauj paredzēt indivīda e-iekļautību un ka ir iespējams apmācīt indivīda e-iekļautību prognozējošu modeli, izmantojot klasifikatoru veidošanas algoritmus.

Pētījuma rezultāti neapstiprināja, ka kāds no klasifikatoru algoritmiem, ar ko tika ģenerēti klasifikācijas modeļi, visos trīsursos uzrāda augstākos veiktspējas rādītājus. Tas nozīmē, ka katram kursam būtu jāveido tikai tam paredzēts prognozēšanas modelis, tomēr jāatzīmē, ka tas ir neizdevīgi, ja kursi nenotiek atkārtoti un ilgstoši. Tā kā tehnoloģiju attīstība notiek nepārtraukti, tad pastāvīgi tiek veidoti jauni digitālo prasmju apguves kursi un tādējādi e-iekļautību prognozējošo modeli ir nepieciešams pilnveidot, lai tas būtu nesaistīts ar kādu

konkrētu kursu, bet derētu ikvienam digitālo prasmju apguves kursam. Kā arī indivīda e-iekļautību prognozējošo modeli ir nepieciešams pilnveidot, lai tas uzrāda konkrētus indivīda riska faktorus, piemēram, e-mācību materiāli, e-vide, sadarbība ar instruktoru vai citi.

Vadoties no šiem secinājumiem, autore nākamajā apakšnodaļā veic pētījumu, veidojot indivīda e-iekļautību prognozējošo modeli, apmācot to ar datu kopām, kas apvieno datus no vairākiem digitālo prasmju apguves kursiem.

3.6. Indivīda e-iekļautību prognozējošā algoritmiskā modeļa izveide

Studentu apmācību procesā nav iespējams katram kursam izveidot savu prognozējošo modeli, jo mainoties tehnoloģijām, pastāvīgi tiek izstrādāti jauni kursi, tāpēc nākamā pētījuma mērķis ir izveidot vienu algoritmu, ar kuru varētu prognozēt e-iekļautību studentiem, kas apgūst digitālās prasmes dažādosursos.

Pētījuma mērķis un pētnieciskie jautājumi

Pētījuma mērķis ir, kombinējot lineārās regresijas, klasteranalīzes un klasifikācijas metodes, izveidot e-iekļautību prognozējošu modeli ar iespējami augstākiem veiktspējas rādītājiem, vienlaikus atpazīstot pēc iespējas vairāk digitālās atstumtības riska studentus. Modelim papildus izvirzītās prasības:

- tas jāapmāca ar datu kopu, kas satur datus no dažādiem digitālo prasmju apguves kursiem;
- modelis prognozē e-iekļautību profesionālo izglītības iestāžu pedagogiem, kuri apgūst digitālās prasmes instruktora vadībā e-vidē;
- modelim jāspēj noteikt riska faktori konkrētam indivīdam.

Pētījuma jautājumi:

1) noteikt, kādām lineārās regresijas, klasteranalīzes un klasifikācijas modeļu kombinācijām, prognozējošā modeļa veiktspējas rādītāji ir augstāki.

2) cik procentu no visiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos, modelis spēj prognozēt kā piederošus riska grupai;

2) cik procentu no modeļa prognozētajiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos, reāli pieder riska grupai.

Pētījuma dalībnieki, izmantotie dati un metodes indivīda e-iekļautības prognozēšanai

Pētījuma dalībnieki ir profesionālo izglītības iestāžu pedagogi, kuri apgūst mācību programmu “Mūsdienu interešu izglītība” un moduli “Informācijas tehnoloģiju prasmju kompetenču paaugstināšana”. Pētījumā izmantota datu kopu, kas satur 928 ierakstus gan no moduļa “Informācijas tehnoloģiju prasmju kompetenču paaugstināšana” tēmām, gan no mācību programmas “Mūsdienu interešu izglītība” kursiem. Lai raksturotu profesionālo izglītības iestāžu pedagogus (mācīšanās kontekstā tiek dēvēti par studentiem), kuri apgūst digitālās prasmes programmā “Mūsdienu interešu izglītība”, tiek izmantoti e-iekļaušanas faktorus raksturojošie atribūti (mainīgie).

Pētījumā izmantots e-iekļaušanas faktors – instruktora vēlme un spēja dalīties ar zināšanām e-mācību kursa laikā. Tas tiek mērīts ar trīs atribūtiem (iespējamās vērtības ir no 1 līdz 5):

1. “Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām”, *IWS*;
2. “Studenta vērtējums apmierinātībai ar e-materiāliem”, *ELM*;
3. “Studenta vērtējums apmierinātībai ar e-vidi”, *ELE*.

Pētījumā izmantots e-iekļaušanas faktors – studenta vēlme un spējas apgūt digitālās prasmes e-mācību kursa laikā. Tas tiek mērīts ar diviem atribūtiem:

1. “Studenta vērtējums savai vēlmei mācīties”, *SWL* (iespējamās vērtības ir no 1 līdz 5);
2. “Studenta spējas mācīties”, *SAL* (iespējamās vērtības ir no 1 līdz 5).

E-iekļautības pakāpi autore nosaka, izmantojot atribūtu novērotā prasmju lietošana studentam – *OU*. Mainīgajam ir divas iespējamās vērtības:

- 0 jeb “nav e-iekļauts” – ja tiek novērots, ka izglītojamais neizmanto tikko iegūtās prasmes pēc kursa beigām;
- 2 jeb “e-iekļauts” – ja tiek novērots, ka izglītojamais izmanto nesen apgūtās prasmes profesionālām vajadzībām, kad mācību kurss ir beidzies

Papildus šiem atribūtiem autore izmanto:

- “Studenta prognoze” – vai pēc kursa pabeigšanas apgūtās prasmes students izmantos profesionālām vai privātām vajadzībām, *PU* (iespējamās vērtības ir no 1 līdz 5);
- “Studenta vispārīgās digitālās pamatprasmes”, *DS*, (iespējamās vērtības ir no 1 līdz 5);
- “Iespējamā prasmju lietošana”, *PU&OU* (iespējamās vērtības ir no 1 līdz 7).

Pētījuma dalībnieki, datu ieguves metodes un izmantotā datu kopas detalizētāk ir aprakstītas 3.1. un 3.2. apakšnodaļās.

Prognozējošā modeļa izveides metode. Lai izveidotu indivīda e-iekļautību prognozējošu modeli, vispirms apmācot ar datu kopu, kas satur datus no dažādiem digitālo prasmju pilnveides kursiem, tika izveidoti trīs modeļi:

- klasifikatoru ansamblī balstīts modelis;
- klasteranalīzē balstīts modelis;
- lineārajā regresijā balstīts modelis.

Pētījuma turpinājumā tika veidotas šo trīs modeļu kombinācijas, meklējot kombinācijas ar augstāko veikspējas rādītāju, paturot spēkā nosacījumu, ka modelim jāspēj atpazīst pēc iespējas vairāk digitālās atstumtības riska studentus.

Prognozējošo modeļu apmācībai autore izmantoja *Waikato Environment for Knowledge Analysis* (WEKA) platformu (*Hall* u. c., 2009; *Frank* u. c., 2009). Lai uzlabotu lineārās regresijas modeļa veikspēju, veidojot lineārās regresijas modeli, *WEKA* atpazīst un izņem atribūtus, kam ir augsta savstarpēja korelācija.

Modeļu veikspējas metrikas. Modeļu veikspēja tika novērtēta, izmantojot pārklājuma, precizitātes, F1 mēra un F2 mēra rādītājus.

E-iekļautību prognozējošo klasifikācijas modeļu novērtēšanas stratēģija. E-iekļautību prognozējošo klasifikācijas modeļa novērtēšanai tiek izmantota desmitkārtīgā šķērsvalidācija, kas plaši tiek lietota modeļa novērtēšanai mašīnmācīšanā (*Yadav* un *Shukla*, 2016).

Prognozes M1 modelis: klasifikatoru ansamblī balstīts modelis

Lai nodrošinātu prognozēšanas modeļa veikspējas uzlabošanu, šajā pētījumā tiek izmantota klasifikatoru ansambla metode (Kumari u. c., 2018). Iepriekšējā pētījumā tika pārbaudīta veikspēja klasifikācijas modeļiem, kas veidoti ar šādiem algoritmiem *NaiveBayes*, *SimpleLogistic*, *lazy.LWL*, *OneR* un *LMT* trīs dažādos kombinētās mācīšanāsursos. Iepriekšējais pētījums neapstiprināja, ka kāds no klasifikatoru veidošanas algoritmiem ģenerētu modeļus ar augstāko veikspēju visosursos. Tomēr iegūtie rezultāti parādīja, ka ar *lazy.LWL* un *LMT* algoritmiem ģenerētajiem modeļiem ir augstākie veikspējas rādītāji. Tāpēc šajā pētījumā, lai uzzinātu, kad klasifikatoru ansamblim ir augstākā veikspēja modeļi, kas ģenerēti ar *lazy.LWL* un *LMT* algoritmiem, tiek izmantoti kā bāzes modeļi, apvienojot tos ar citiem klasifikācijas modeļiem, kas veidoti izmantojot šādus algoritmus: *NaiveBayes*, *Simple Logistic* un *OneR*.

Klasifikatoru ansamblim tika meklēta to modeļu kombinācija, kurai ir visaugstākie veikspējas rādītāji F1 un F2 mēriem (3.21. tabula). Modeļu prognozes tika apvienotas, izmantojot vairākuma balsošanas (angļu val. – *majority voiting*) pieeju (Dietterich, 2000). Augstākais veikspējas rādītājs F1 mēram ir 0,809, ja ir četri bāzes modeļi, kur katrs no tiem veidots attiecīgi ar šādiem algoritmiem: *lazy.LWL* ar *Random Forest*, *LMT*, *OneR* un *SimpleLogistic*. F2 mēra rādītājs 0,799 ir visaugstākais trīs bāzes modeļu gadījumā, kur modeļu izveidē izmantots *lazy.LWL* algoritms ar *Random Forest*, *LMT* un *SimpleLogistic* algoritmi.

3.21. tabula

Ansambļa klasifikatora veikspējas rādītāji dažādām bāzes modeļu kombinācijām.

<i>LMT</i>	<i>Lazy.LWL</i>	<i>NaiveBayes</i>	<i>OneR</i>	<i>Simple Logistic</i>	F1 mērs	F2 mērs
x	x	x			0,801	0,785
x	x	x	x	x	0,800	0,775
x	x	x		x	0,804	0,789
x	x	x	x		0,808	0,771
x	x			x	0,807	0,799
x	x		x	x	0,809	0,784
x	x		x		0,807	0,785

Prognozes M1 modelis ir ansambļa klasifikators, kas apvieno:

1) četrus klasifikācijas modeļus, kas veidoti ar *lazy.LWL* (ar *Random Forest*), *LMT*, *OneR* un *SimpleLogistic* algoritmiem, izmantojot vairākuma balsošanas pieeju, ja par modeļa veikspējas kritēriju uzskata F1 mēru.

2) trīs klasifikācijas modeļus, kas veidoti ar *lazy.LWL* (ar *Random Forest*), *LMT* un *SimpleLogistic* algoritmiem, izmantojot vairākuma balsošanas pieeju, ja par modeļa veikspējas kritēriju uzskata F2 mēru.

Prognozes M2 modelis: klasteranalīzē balstīts modelis

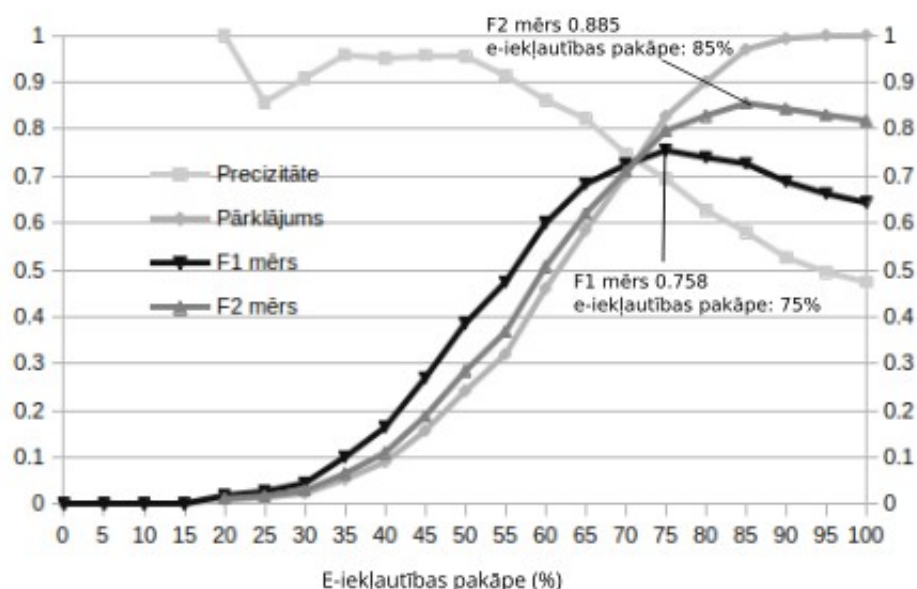
Prognozes M2 modelis tiek veidots, izmantojot klasteru analīzes pieeju, jo iepriekšējie pētījumi ir parādījuši, ka klasteru analīzi var izmantot e-iekļautības prognozēšanai (skat. 3.4. nodaļa). Klasteru izveidei tiek izmantota *kMeans* klasteranalīzes metode, kurā katrs objekts pieder tieši vienam klasterim. Eiklīda attālums tiek izmantots, lai izmērītu attālumu starp

konkrēto datu punktu un citiem datu kopas punktiem. Pētījumā *kMeans* klasteranalīzes metode tiek izmantota datu grupēšanai pa klasēm (“e-iekļauts” un “nav e-iekļauts”) (Kumari u. c., 2012). Prognozes M2 modelis, kas izmanto *kMeans* metodi, datus sadala divos klasteros, kur katrs no klasteriem atbilst “e-iekļauts” vai “nav e-iekļauts” grupai.

Prognozes M3 modelis: lineārā regresijā balstīts modelis

Pamatojoties uz iepriekšējiem pētījumiem (skat. 3.3 nodaļa), lai prognozētu indivīda e-iekļautības pakāpi, tiek veidots daudzfaktoru lineārās regresijas modelis.

Modelis prognozē e-iekļautības pakāpi procentos no maksimāli iespējamās pakāpes. Lai noteiktu, vai students būs e-iekļauts, ir nepieciešams noteikt pakāpes vērtību - sliekšni, kuru sasniedzot un pārsniedzot, var uzskatīt, ka students lietos jaunapgūtās prasmes profesionālām vajadzībām. Lai noteiktu e-iekļautības pakāpes sliekšni, tika salīdzināta prognozētā e-iekļautības pakāpe ar faktisko novērojumu par to, vai students izmanto jauniegūtās prasmes, tas ir, vai students atbilst klasei “e-iekļauts” vai “nav e-iekļauts”. 3.13. attēlā redzamas veiktspējas rādītāju izmaiņas, palielinoties e-iekļautības pakāpei. Palielinoties e-iekļautības pakāpei, modeļa precizitāte samazinās, bet pārklājums palielinās.



3.13. att. Veiktspējas metrikas izmaiņas atkarībā no prognozētās e-iekļautības pakāpes. E-iekļautības pakāpes sliekšņa noteikšana.

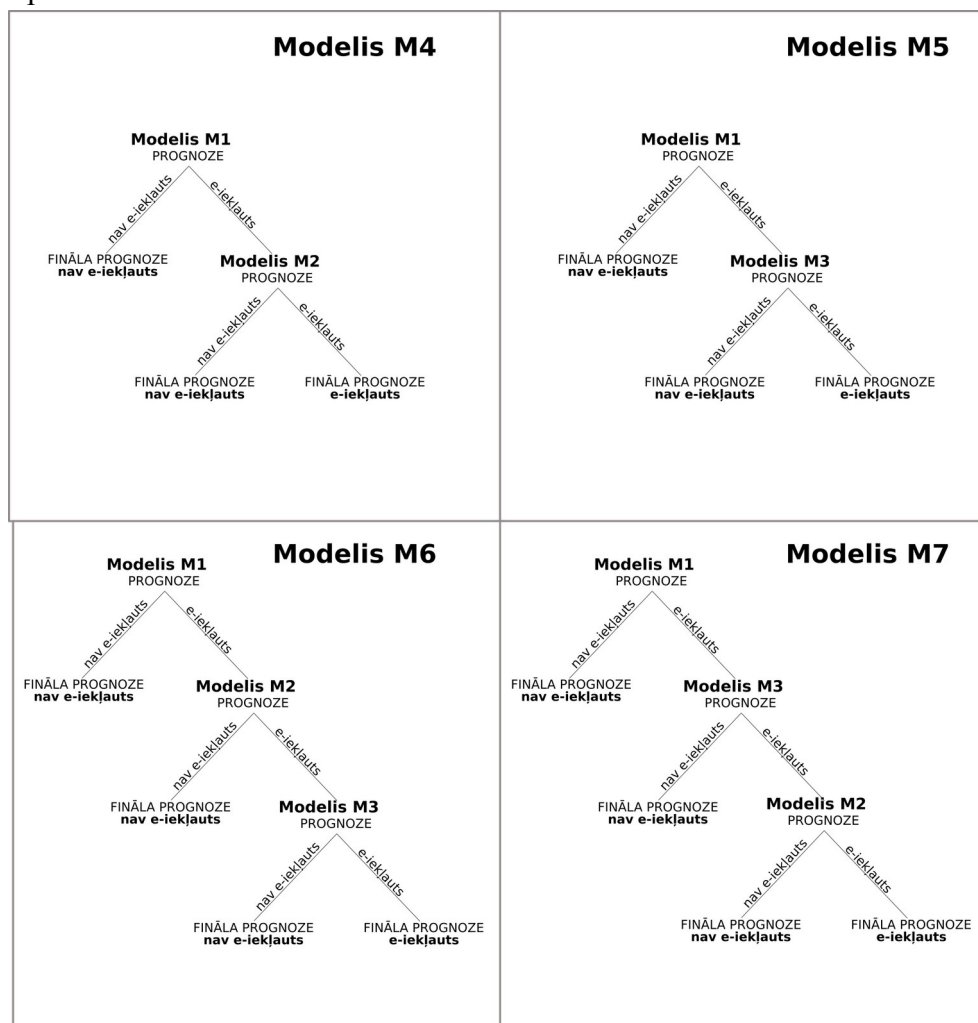
Augstākā F1 mēra vērtība ir, kad tiek sasniegti 75 % no e-iekļautības maksimālās pakāpes. Tas nozīmē, ja studentam tiek noteikts e-iekļautības līmenis, kas ir mazāks par 75 %, tad tiek pieņemts, ka studentam draud digitāla atstumtība. Ja e-iekļautības pakāpe ir 75 %, tad pārklājums ir 0,828, precizitāte ir 0,695. Augstākā F2 mēra vērtība ir, kad e-iekļautības pakāpe ir sasniegusi 85 %. Ja par noteicošo metriku izvēlamies F2 mēru, tad var uzskatīt, ka students ir pakļauts digitālās atstumtības riskam, ja tā e-iekļautības pakāpe ir zemāka par 85 %. Ja e-iekļautības pakāpe ir 85 %, pārklājuma vērtība ir 0,970, precizitāte ir 0,580.

Prognozes M3 modelis ir daudzfaktoru lineārās regresijas modelis, kas paredz, ka izglītojamais ir pakļauts digitālās atstumtības riskam:

- 1) ja prognozētā e-iekļautības pakāpe ir mazāka par 75 % un F1 mērs ir noteicošā metrika;
- 2) ja prognozētā e-iekļautības pakāpe ir mazāka par 85 % un F2 mērs ir noteicošā metrika.

E-iekļautības modeļu kombinācijas

Autore meklēja veidus, kā uzlabot pārklājumu un samazināt to studentu skaitu, kurus modelis prognozē, kā e-iekļautus, taču patiesībā studenti nav e-iekļauti. Autore izveidoja četrus papildu modeļus: M4, M5, M6, M7 modeļus. 3.14. attēlā parādīti noteikumi, kas izmantoti, lai apvienotu M1, M2 un M3 modeļus. Modeļu kombinācijas ir balstītas uz prognozes vērtības maiņu no “e-iekļauts” uz “nav e-iekļauts”, ja otrā (pievienotā) modeļa prognozes vērtība ir “nav e-iekļauts”. Tādējādi prognozēšanas rezultātā tiek palielināts pārklājums un palielinās studentu skaits, kuri ir digitālās atstumtības riska grupā un kurus modelis atpazīst kā riska studentus.



3.14. att. Noteikumi jaunu prognozēšanas modeļu izveidošanai, apvienojot M1, M2 un M3 modeļus, un, mainot prognozes vērtības no “e-iekļauts” uz “nav e-iekļauts” ar mērķi palielināt pārklājumu.

Rezultāti: indivīda e-iekļautību prognozējošā modeļa izveide

Izmantojot *WEKA* platformu, tika apmācīti M1, M2 un M3 modeļi, un pēc tam, apvienojot šos modeļus, tika iegūti M4, M5, M6 un M7 modeļi.

Modeļu apmācības rezultāti: F1 mērs kā galvenais veikspējas rādītājs

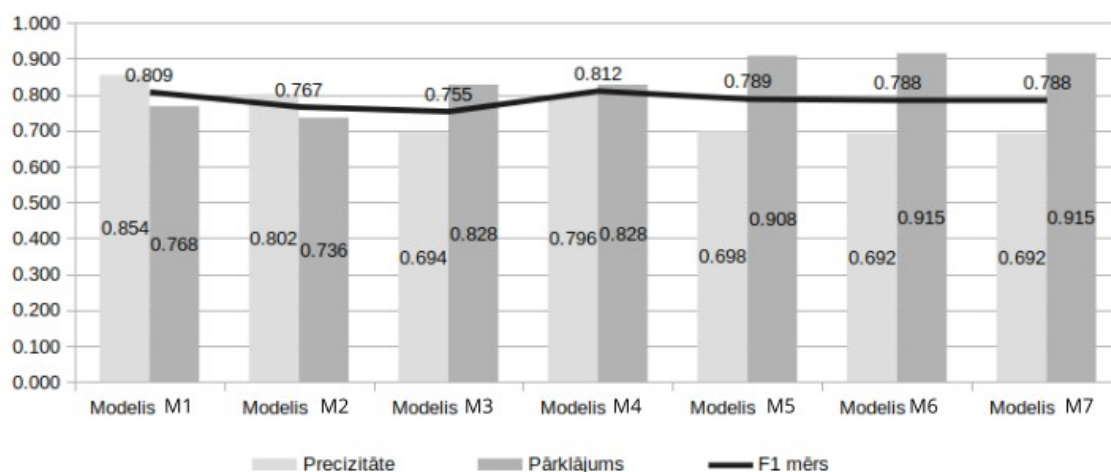
Vispirms kā modeļa veikspējas kritērijs tika izmantota F1 mēra vērtība, šajā gadījumā gan

pārklājums, gan precizitāte tika uzskatīta par vienlīdz svarīgu.

Iegūtie rezultāti rāda, ka F1 mērs ir visaugstākais modelim, kas apvieno kombināciju no klasifikatoru ansambļa un klasteriem.

3.15. attēlā parādīts, ka augstākā F1 mēra vērtība 0,812 ir M4 modelim, ko iegūst, apvienojot M1 un M2 modeļus. M1 modelī tiek izmantoti klasifikācijas modeļi, kas balstīti šādos algoritmos *lazy.LWL*, *LMT*, *OneR* un *SimpleLogistic*, apvienojot tos ar ansambļa un vairākuma balsojuma metodi. M2 modelis ir *kMeans* klasteranalīzes modelis, kur dati tiek sagrupēti “e-iekļauts” un “nav e-iekļauts” klasteros. M4 modeļa pārklājums ir 0,828, precizitāte ir 0,796.

Ar šo modeli iespējams 82,80 % no visiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos, prognozēt kā piederošus riska grupai. Savukārt 17,20 % digitāli atstumtos studentus modelis kļūdaini prognozē, kā e-iekļautus. Modelis spēj pareizi atpazīt 79,60 % no tiem studentiem, kas ir prognozēti kā riska studenti, bet 20,40 % no tiem, kas ir e-iekļauti, kļūdaini tiks ietverti riska grupā.



3.15. att. Rezultāti. F1 mēra, precizitātes, pārklājuma vērtības e-iekļautības prognozēšanas modeļiem, ja pieņem, ka pārklājumam un precizitātei ir vienlīdz svarīgi.

Augstākā pārklājuma vērtība 0,915 ir M6 un M7 modeļiem, taču tajā pašā laikā šiem modeļiem ir viszemākā precizitātes vērtība 0,692, F1 mērs šiem modeļiem ir 0,788. M6 un M7 modeļi ir M1, M2 un M3 modeļu kombinācijas rezultāts. Tādējādi šie modeļi ir klasifikācijas, klastera un lineārās regresijas prognozes kombinācija.


Modeļu apmācības rezultāti: F2 mērs kā galvenais veikspējas rādītājs

Lai uzzinātu, kuri modeļi ir piemērotāki, ja pārklājums ir svarīgāks par precizitāti, autore izmantoja F2 mēru kā modeļa veikspējas rādītāju.

Iegūtie rezultāti rāda, ka F2 mērs ir visaugstākais modeļiem, kurus iegūst, kombinējot klasifikatoru ansambli ar lineārās regresijas modeli vai klasifikatoru ansambli ar lineārās regresijas modeli un klasteranalīzes modeli.

Augstākā F2 mēra vērtība 0,865 ir M5, M6 un M7 modeļiem. M5 modelis tiek iegūts, apvienojot M1 un M3 modeļus. M1 modelī tiek izmantoti klasifikācijas modeļi, kas veidoti ar algoritmiem *lazy.LWL*, *LMT* un *SimpleLogistic*, apvienojot tos ar ansambļa metodi un izmantojot vairākuma balsošanas metodi (3.16. attēls). M3 modelis ir lineārās regresijas

modelis, kur izglītojama tiek uzskatīts par e-iekļautu, ja tā e-iekļautības pakāpe ir augstāka par 85 %. M6 un M7 modeļi ir M1, M2 un M3 modeļu kombinācijas rezultāts. Šiem modeļiem ir izmantota klasifikācijas, klastera un lineārās regresijas metodes kombinācija. M5, M6 un M7 modeļiem pārklājums ir 0,984, bet precizitāte ir 0,582.



3.16. att. Rezultāti. F2 mēra, precizitātes, pārklājuma vērtības e-iekļautības prognozēšanas modeļiem, ja pieņem, ka pārklājums ir svarīgāks nekā precizitāte.

Ar šiem modeļiem iespējams 98,40 % no visiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos, prognozēt kā piederošus riska grupai. 58,20 % procenti no modeļu prognozētajiem digitālās atstumtības riska grupas pedagogiem reāli pieder riska grupai. 41,80 % no tiem, kas tiek prognozēti kā riska studenti, ir e-iekļauti.

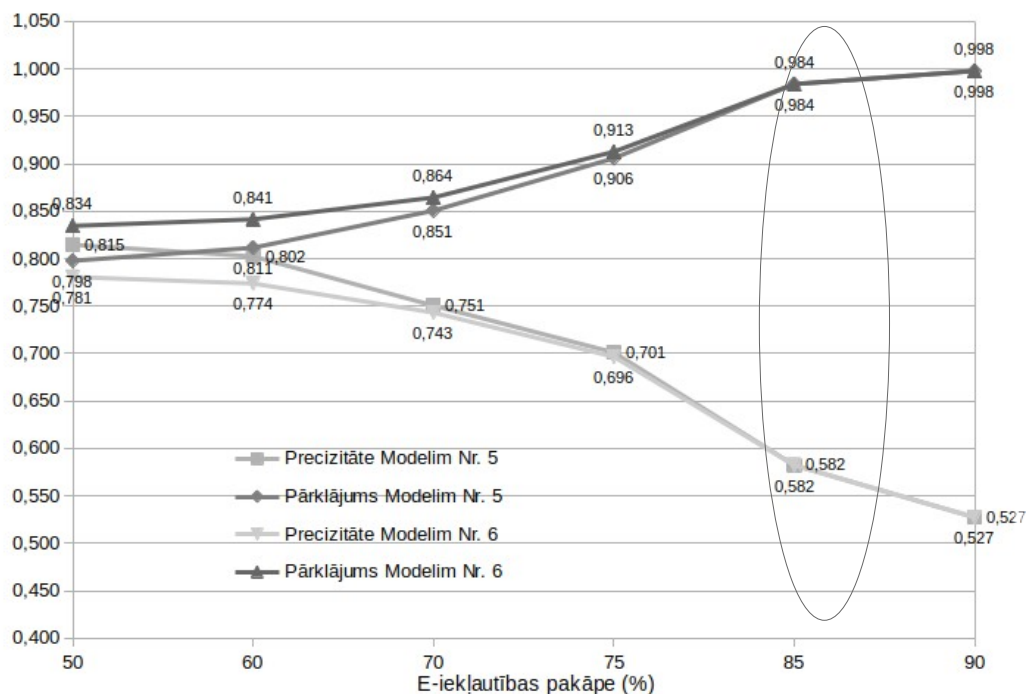
M4 modelim, kas apvieno ansambļa klasifikatoru pieeju ar klasteranalīzi, F2 mēra vērtība ir 0,824, precizitātes vērtība ir 0,782 un pārklājuma vērtība ir 0,834. Šim modelim pārklājums ir mazāks nekā M5, M6 un M7 modeļiem, bet precizitātes vērtība ir augstāka.

Detalizēts apskats indivīda e-iekļautību prognozēšanas modeļiem ar augstākiem veikspējas rādītājiem

Prognozējot profesionālo izglītības iestāžu pedagogu e-iekļautību, autore uzskata, svarīgāk ir atpazīt pēc iespējas vairāk riska grupas pārstāvjus (lielāks pārklājums), nekā nodrošināt lielāku modeļa precizitāti, bet nepamanīt riska grupas indivīdus. Salīdzinot modeļu veikspējas rādītājus, autore secina, ka augstākā pārklājuma vērtība, vienlaikus saglabājot augstāko modeļa kopējo veikspējas rādītāju, ir gadījumā, kad noteicošais veikspējas rādītājs ir F2 mērs un prognozēšanas modeļi ir M5, M6, M7, kurus iegūst, kombinējot klasifikatoru ansambli ar lineārās regresijas modeli vai klasifikatoru ansambli ar lineārās regresijas modeli un klasteranalīzes modeli. Tāpēc autore detalizētāk apskatīja M5, M6, M7 modeļus.

E-iekļautības sliekšņa ietekme uz modeļa veikspējas rādītājiem. Autore noteica, kā mainās šo modeļu veikspējas rādītāji, ja tiek mainīts e-iekļautības sliekšnis. Mainot lineārās regresijas algoritma e-iekļautības sliekšni, autore novēroja izmaiņas modeļa kombināciju pārklājuma un precizitātes vērtībās (3.17. att). Piemēram, ja e-iekļautības sliekšnis ir 70 %, tad M5 modelim F2 mērs ir 0,828, pārklājums 0,851 un precizitāte ir 0,782. M6 un M7 modeļiem ir šādas vērtības: F2 mērs ir 0,837, pārklājums ir 0,864 un precizitāte ir 0,743.

Savukārt, ja e-iekļautības sliekšnis ir 75 %, Modelim M5 F2 mērs ir 0,855, pārklājums ir 0,906 un precizitāte ir 0,701. M6 un M7 modeļiem F2 mēra vērtība ir 0,859, pārklājums ir 0,913 un precizitāte ir 0,696. Ja sliekšnis ir 85 % un augstāks, tad F2 mēra, pārklājuma un precizitātes vērtības sakrīt visiem trīs modeļiem.



3.17. att. E-iekļautības pakāpes un atbilstošās pārklājuma un precizitātes vērtību izmaiņas M5 un M6 modeļiem (F2 mērs).

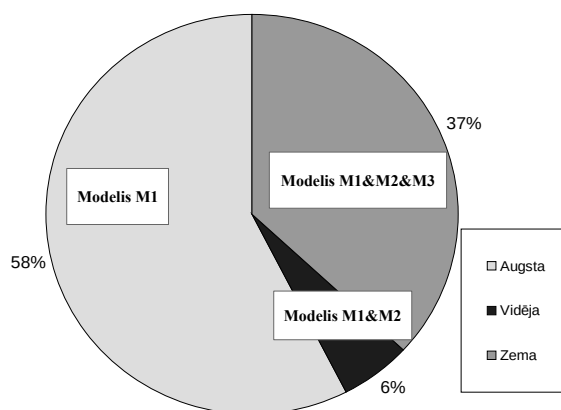
Pieaugot e-iekļautības sliekšnim, samazinās modeļa precizitāte, bet palielinās modeļa pārklājums. Tas nozīmē, ka e-iekļautības sliekšņa maiņa prognozēšanas modelī ļauj norādīt, kas lietotājam ir svarīgāks - precizitāte vai pārklājums.

Modeļa precizitātes līmeņu salīdzinājums. Detalizētāk autore apskatīja M6 modeli, kas apvieno klasifikatora ansambļa, klasteranalīzes un lineārās regresijas modeļus.

Promocijas darbā ar modeļa precizitāti tiek saprasts, cik no modeļa prognozētajiem riska studentiem (ne e-iekļautajiem) patiesi ir riska studenti.

M6 modelis prognozi studenta e-iekļautībai nosaka sekojoši (skat. 3.14. att.): vispirms ar M1 modeli prognozē riska studentus, tad ar M2 modeli prognozi papildina riska studentu skaitu, ja M2 modeļa prognoze ir “nav e-iekļauts”, un visbeidzot ar M3 modeli papildina riska studentu skaitu, ja M3 modeļa prognoze ir “nav e-iekļauts”. Attiecīgi iepriekš iegūtie precizitātes rādītāji ir M1 modelim 81,80 %, M1 un M2 modeļu kombinācijai – 78,20 %, M1, M2, M3 modeļu kombinācijai – 58,20 %.

3.18. attēlā parādīts, ka 58 % riska studenti ir prognozēti, izmantojot M1 modeli. 6 % riska studentu prognozes balstās uz M1 un M2 modeļu kombināciju. Bet 37 % riska studentu prognoze balstās uz M1, M2 un M3 modeļu kombināciju. Tā kā M1 modeļa precizitāte ir augstāka nekā M1 un M2 modeļu kombinācijas precizitāte, un M1, M2 un M3 modeļu kombinācijas precizitāte ir zemāka nekā M1 un M2 modeļu kombinācijas precizitāte, autore secina, ka prognozēšanas modeļa precizitāti var iedalīt trīs līmeņos: augsta, vidēja un zema, atkarībā no tā, kāda modeļu kombinācija nosaka prognozi.



3.18. att. Augstas, vidējas un zemas prognozēšanas precizitātes līmeņi un atbilstoši tiem prognozēto riska studentu sadalījums M1 modelim, M1 un M2 modeļu kombinācijai, M1, M2 un M3 modeļu kombinācijai.

E-iekļautās klases gadījumā prognozēšanas precizitāte ir balstīta uz pareizi prognozēto e-iekļauto klases aprēķiniem. Autore aprēķināja, ka 92,63 % no e-iekļautajiem izglītojamajiem ir pareizi prognozēti kā piederoši “e-iekļauts” klasei. Tādējādi var secināt, ka precizitātes līmenis e-iekļauto klases prognozei ir augsts.

Indivīda e-iekļautības riska faktoru noteikšana

Lai noteiktu, kādi ir konkrētā studenta riska faktori, autore izmanto klasteru centroīdu vērtības kā robežvērtības, kas jāsasniedz konkrētā studenta atribūtiem, lai students atbilstu e-iekļauto klasei (3.19. att.).

Final cluster centroids:

Attribute	Full Data (928.0)	Cluster#	
		0 (529.0)	1 (399.0)
SWL	3.7884	4.0457	3.4471
DS	3.7183	3.8601	3.5303
SAL	3.1094	3.7719	2.231
ELM	4.0477	4.4805	3.4739
IWS	4.6056	4.8507	4.2807
ELE	4.1525	4.5388	3.6404
PU	3.986	4.569	3.213

3.19. att. M2 modeļa e-iekļauto un e-neiekļauto studentu kopu centroīdi. Klasteris “0” ir paredzēts e-iekļautai klasei, klasteris “1” – e-neiekļautai klasei. Atribūti ir studentu pašnovērtējumi. *IWS* – Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām.

ELM – Studenta vērtējums apmierinātībai ar e-materiāliem. *ELE* – Studenta vērtējums apmierinātībai ar e-vidi. *SWL* – Studenta vērtējums savai vēlmei mācīties. *SAL* – Studenta spējas mācīties. *DS* – Studenta vispārīgās digitālās pamatprasmes. *PU* – Studenta prognoze, vai pēc kursa pabeigšanas apgūtās prasmes students izmantos profesionālām vai privātām vajadzībām.

Piemēram, studenta vērtējumam par e-vidi vai e-materiāliem jātiecas uz 4,5, vai arī digitālām pamatprasmēm jābūt novērtētām vismaz uz 3.8 (maksimālā vērtība ir 5).

Otrs skats uz studenta riska faktoriem tiek nodrošināts, izmantojot lineārās regresijas modeli M3. Iegūtais lineārās regresijas algoritms dots 3.20. attēlā.

PUOU =

0.538 * SWL +
0.2807 * SAL +
0.6354 * ELM +
0.3163 * ELE +
-1.7483

3.20. att. M3 modeļa lineārās regresijas vērtības. Atribūti ir studentu pašnovērtējumi. *ELM* – Studenta vērtējums apmierinātībai ar e-materiāliem. *ELE* – Studenta vērtējums apmierinātībai ar e-vidi. *SWL* – Studenta vērtējums savai vēlmei mācīties. *SAL* – Studenta spējas mācīties. *PUOU* - iespējamā prasmju lietošanas vērtība.

Modeļa apmācības procesā tika iegūts, ka lineārās regresijas modelī e-iekļaušanas pakāpes prognozēšanai tiek izmantoti tikai četri atribūti, kas raksturo studenta motivāciju, studenta spēju mācīties, e-mācību materiālu novērtējumu un e-mācību vides novērtējumu. Instruktora vēlme dalīties ar zināšanās neietekmēja lineārās regresijas rezultātus saskaņā ar M3 modeļa algoritmu. Lineārie korelācijas koeficienti rāda, ka studenta pazīmēm ir atšķirīga ietekme uz prognozi. E-mācību materiāliem un studenta motivācijai ir lielāka ietekme, e-mācību videi un studenta spējai mācīties – ir mazāka ietekme. Atkarībā no konkrēta studenta atribūtiem ar lineārās regresijas prognozēšanas algoritmu iespējams noteikt, kuri ir noteicošie riska faktori studentam.

Iespēja noteikt riska faktoru vērtības ir priekšnoteikums, lai instruktors varētu pieņemt lēmumu par turpmāko rīcību, kā novērst risku studentiem.

Kopsavilkums un secinājumi par indivīda e-iekļautību prognozējošā modeļa izveide

1) Ir iespējams izveidot e-iekļautību prognozējošus modeļus, apmācot ar datu kopu, kas satur datus no dažādiem kursiem, nevis tikai no viena kursa. Šajā pētījumā tika salīdzināti septiņi e-iekļautību prognozējoši modeļi. Modeļi tika apmācīti ar datu kopu, kas satur ierakstus no vairākiem mācību kursiem, nevis tikai no viena kursa. Modeļi prognozē, kuri studenti, kas apgūst kursus, jaunapgūtās prasmes pēc kursu pabeigšanas varētu neizmantot profesionālajām vajadzībām, tas ir, - prognozē, vai studentiem draud digitālā atstumtība.

Modeļi aprēķina prognozi, izmantojot klasifikatoru ansambļa, klasteranalīzes un daudzfaktoru lineārās regresijas algoritmus, kā arī šo algoritmu kombinācijas.

2) E-iekļautības modeļu apvienošana uzlabo modeļa veikspējas rādītājus.

Prognozēšanas modeļiem tika izmantoti divi veikspējas rādītāji – F1 mērs un F2 mērs.

Lai izvēlētos, kādu no septiņiem izveidotajiem e-iekļautību prognozējošajiem modeļiem, ir svarīgi noteikt, kas ir būtiskāks – pēc iespējas lielāks riska grupas pārklājums, bet mazāka precizitāte prognozei, vai prognozes precizitāte ir tikpat būtiska kā pārklājums. Ja ir svarīgi noteikt pēc iespējas vairāk riska grupas studentu, F2 mērs ir piemērots modeļa veikspējas rādītājs un kritērijs, pēc kura izvēlēties prognozējošo modeli. Ja pārklājums un precizitāte ir vienlīdz svarīgi, tad par modeļa izvēles kritēriju noder F1 mērs. Izveidoto e-iekļautības prognozēšanas modeļu dažādība ir priekšrocība, ka modeļa lietotājs var izvēlēties vispiemērotāko modeli atkarībā no sava mērķa. Tomēr jāatzīmē, ka tika novērots, ja modelis palielina pārklājuma vērtību, tad precizitātes vērtība samazinās, un tas ir jāņem vērā, izvēloties modeli e-iekļautības prognozēšanai.

3) Ja mērķis ir prognozēt aptvert pēc iespējas vairāk riska studentu, tad ir piemērota klasifikatoru ansambļa metode ar vairākuma balsošanas pieeju, kas kombinēta ar lineāras regresijas modeli vai ar klasteranalīzes un lineārās regresijas modeli. Šāds modelis spēj atpazīt

98,40 % no digitāli atstumtajiem, bet tajā pašā laikā tikai 58,20 % no tiem, kas tiek prognozēti kā digitāli atstumti, ir patiesi riska studenti. Tas nozīmē, ka resursi tiks nevajadzīgi izmantoti, lai papildus atbalstītu 41,80 % izglītojamo apmācību. Tomēr, ja ir pieejami laika un finanšu resursi, tad iespējams, ka zema precizitātes vērtība nav šķērslis un organizācija tikai nostiprinās studentu digitālās prasmes, papildus uzlabojot mācīšanās procesa norisi šiem studentiem. Šajā gadījumā būtisks ir arī studentu skaits, kas paredzējuši apgūt kursus. Jo nelielāks studentu skaits, jo iespējams, ka pastāv iespēja, vairāk veltīt laiku katram studentam un precizitātes kļūda ir mazāk nozīmīga.

4) Ja precizitāte un pārklājums ir vienlīdz svarīgi un kā veikspējas kritērijs tiek izmantots F1 mērs, tad augstākos veikspējas rādītājus var iegūt, apvienojot klasifikatoru ansambļa modeli un klasteranalīzes modeli. Šis prognozēšanas modelis atpazīst 82,80 % digitāli atstumto studentu un spēj pareizi prognozēt 79,60 % no tiem studentiem, kas prognozēti, kā riska studenti. Šajā gadījumā tikai 20,40 % no e-iekļautajiem izglītojamajiem tiks prognozēti kā digitāli izslēgti, un tas ir salīdzinoši mazāk nekā tad, ja F2 mēru izmanto kā veikspējas kritēriju. Izmantojot šo modeli, ir svarīgi saprast, cik būtisks zaudējums ir tas, ka modelis neatpazīna 27,20 % kā riska studentus.

5) E-iekļautības pakāpe ietekmē prognozēšanas modeļa pārklājuma un precizitātes vērtības. E-iekļautības pakāpes sliekšņa izmaiņas lineārās regresijas modelī ietekmē pārklājuma un precizitātes vērtības. Atkarībā no veikspējas metrikas izvēles un e-iekļautības pakāpes sliekšņa modeļu prognozes precizitāte un pārklājums mainīsies. Jo augstāks e-iekļautības pakāpes sliekšnis, jo vairāk riska studentus modelis spēs atpazīt, bet tajā pašā laikā modelis kļūs neprecīzāks nosakot riska studentus.

6) Izmantojot klasteranalīzes un lineārās regresijas modeli ir iespējams noteikt konkrēta studenta e-iekļautību ietekmējošos riska faktorus un to vērtības, kas atbilst e-iekļauto indivīdu klasei.

Izveidoti e-iekļautību prognozējošie modeļi būs noderīgi gan pasniedzējiem, gan izglītojamajiem, lai pēc iespējas ātrāk identificētu riskus studentu apmācības procesā. Turklāt modeļi palīdzēs organizācijām, kas “sūta” uz apmācībām savus darbiniekus, savlaicīgi novērst nevajadzīgu resursu patēriņu, finansējot apmācības, kur darbinieki iegūtās prasmes neizmanto organizācijas vajadzībām.

3.7. Kopsavilkums un secinājumi par indivīda e-iekļaušanu ietekmējošiem faktoriem un prognozējošo modeli

Šajā promocijas darba nodaļā atbilstoši *CRISP-DM* un *CRISP-ML (Q)* metodēm ir atspoguļots indivīda e-iekļaušanu prognozējošā modeļa izveide un e-iekļautību ietekmējošo faktoru noteikšana.

Šajā nodaļā ir aprakstīts vairāku indivīda e-iekļautību prognozējošo modeļu veidošanas process, izmantojot lineārās regresijas, klasteranalīzes un klasikācijas pieejas. Kā piemērotākie prognozēšanas modeļi noteikti tie, kuriem ir augstākie veikspējas rādītāji – F mērs, pārklājums un precizitāte.

Pētījumos iegūtie modeļi, kuri plānoti izmantot e-iekļaušanu prognozējošas sistēmas prototipa izveidē, apmācīti ar datu kopu, kas iegūta apvienojot datus no vairākiem kursiem, kurus instruktora vadībā klātienē nodarbībā un patstāvīgi Moodle e-vidē apguva profesionālo

izglītības iestāžu darbinieki, kuri pilnveidoja savas digitālās prasmes.

Nodaļas galvenie secinājumi:

1) Pamatojot izvēli uz to, ka modelim jānodrošina pēc iespējas lielāks pārklājums riska grupas indivīdiem, vienlaikus nodrošinot modeļa veiktspējas kvalitāti (F2 mērs), kā piemērotākais indivīda e-iekļautības prognozēšanai ir noteikts modelis, kurš prognozi veido, kombinējot klasifikatoru ansambli, klasteranalīzes un lineārās regresijas modeli. Ar šo modeli ir iespējams atpazīt 98,40 % no riska studentiem. F2 mēra vērtība ir 0,865. Modeļa veiktspējas rādītāji atbilst zinātniskajā literatūrā norādītajiem studentu sasniegumu prognozēšanas modeļu rādītājiem dažādās mašīnmācīšanās tehnikās.

2) Izmantojot amerikāņu zinātnieka M. Nisena zināšanu pārvaldības teoriju par zināšanu radīšanu un pārnesi individuālā līmenī ir noteikti indivīda e-iekļautību ietekmējošie faktori:

- studenta ieinteresētība mācīties;
- studenta spējas mācīties (tiek noteiktas, izmantojot studenta pašvērtējumu zināšanu līmenim pirms un pēc tēmas apguves);
- instruktora vēlme dalīties ar zināšanām;
- studenta vērtējums e-videi;
- studenta vērtējums e-mācību materiāliem.

Šie faktori papildināti ar vērtējumu par studentu digitālām pamatprasmēm un studenta prognozi par jaunapgūto prasmju izmantošanu profesionālām vai privātām vajadzībām.

4. TEHNOLOĢISKAIS MODELIS UN TĀ NOVĒRTĒJUMS INDIVĪDA E-IEKĻAUTĪBAS PROGNOZĒŠANAI

Atbilstoši *CRISP-DM* un *CRISP-ML (Q)* metodēm šajā nodaļā ir atspoguļots e-iekļaušanu prognozējošā algoritmiskā modeļa novērtēšanas posms, kā arī daļēji modeļa izvietojanas programmatūras prototipā posms un modeļa pārraudzības posms.

Nodaļas mērķis ir novērtēt e-iekļaušanu prognozējošo algoritmisko modeli, izvietojot to e-iekļaušanas prognozēšanas sistēmas prototipā.

Lai sasniegtu mērķi, veikti šādi uzdevumi:

1) noteiktas e-iekļaušanu prognozējošas sistēmas programmatūras prasības un galvenie darbības principi;

2) atbilstoši noteiktajām prasībām izstrādāts e-iekļaušanu prognozējošas sistēmas prototips (tehnoloģiskais modelis), izvietojot tajā e-iekļaušanu prognozējošo algoritmisko modeli;

3) novērtēts e-iekļaušanu prognozējošais algoritmiskais modelis un izveidotais prototips.

Nodaļa sastāv no četrām apakšnodaļām. Pirmajā apakšnodaļā ir atspoguļotas e-iekļaušanu prognozējošas sistēmas programmatūras funkcionālās prasības un galvenie darbības principi. Otrajā apakšnodaļā ir attēlots e-iekļaušanu prognozējošās sistēmas prototips. Trešā nodaļa satur novērtējumu e-iekļaušanu prognozējošā algoritmiskā modeļa veiktspējai ar testa kopas datiem, prototipa atbilstībai biznesa mērķiem un modeļa veiktspējas izmaiņu novērtējumu apmācības un testa datu kopām. Ceturtā nodaļa satur kopsavilkumu un secinājumus par e-iekļaušanu prognozējošo tehnoloģisko modeli un tā novērtējumu.

4.1. E-iekļaušanu prognozējošas sistēmas funkcionālās prasības un galvenie darbības principi

E-iekļaušanu prognozējošās sistēmas funkcionālo prasību un galveno darbības principu attēlošanai ir izmantoti *UML (Unified Modeling Language)* modeļi (*Medvidovic* u. c., 2002) un datu plūsmu diagrammas (*Li* un *Chen*, 2009).

Lai attēlotu e-iekļaušanu prognozējošās sistēmas funkcionālās prasības un galvenos darbības principus, veikti šādi uzdevumi:

1) izveidots mērķu modelis;

2) noteiktas prasības sistēmas funkcionalitātei;


3) izveidots lietošanas gadījumu modelis;

4) izveidots datu plūsmu un pamatprocesu modelis, ieskaitot apmācības, prognozēšanas, modeļa pārraudzības algoritmus.

E-iekļaušanu prognozējošās sistēmas mērķi

Ņemot vērā iepriekš izvirzīto mērķi, ka instruktoram jāspēj ar prognozējošo modeli noteikt riska studentus, kuri jaunapgūtās digitālās prasmes nelietos, ir izveidota e-iekļaušanu prognozējošās sistēmas mērķu diagramma (4.1. att.). Modelējot mērķus, ir ņemta vērā mašīnmācīšanās balstītu sistēmu galvenie procesi – modeļa apmācības process, prognozēšanas process un sistēmas uzturēšanas process. Kā arī ietvertas 2. nodaļā iegūtās atziņas, ka sistēmai ir jāspēj:

- 1) prognozēt, izmantojot iepriekš aprakstīto prognozēšanas modeli, kas paredz riska studentus, kombinējot klasifikācijas, lineārās regresijas un klasternalīzes metodes;
- 2) izveidot prognozi patvaļīgai kursa tēmai, neskatoties uz to, ka modelis ir apmācīts ar dažādu kursu datu kopām;
- 3) iegūstot jaunus datus, pilnveidot prognozējošo modeli precīzākas prognozes iegūšanai.



4.1. att. Indivīda e-iekļautības prognozēšanas sistēmas mērķu diagramma.

E-iekļaušanu prognozējošās sistēmas galvenais mērķis ir noteikt studentus, kam ir e-iekļaušanas risks. Pirmais apakšmērķis ir veidot zināšanu bāzi, kas sastāv no apmācības piemēru datu bāzes un apmācīta prognozēšanas modeļa PROGN. Otrais apakšmērķis ir paredzēt studentus ar digitālās atstumtības risku, balstoties uz iepriekš noteikto e-iekļautības pakāpes sliekšni un aprēķiniem, kas iegūti, izmantojot PROGN modeli. Ja prognoze paredz, ka studentam ir risks tikt izslēgtam, tad uzdevums ir noteikt, kādi faktori ietekmē studentu sniegumu. E-iekļautības prognozēšanas sistēmas trešais apakšmērķis ir uzraudzīt prognozēšanas modeļa veiktspējas kvalitāti.

E-iekļaušanu prognozējošās sistēmas indivīda e-iekļautības prognozēšanai mērķi, atbilstošie nosacījumi, kad mērķis ir sasniegts, ir doti 4.1. tabulā.

E-iekļaušanu prognozējošās sistēmas mērķi, nosacījumi, kad mērķis ir sasniegts.

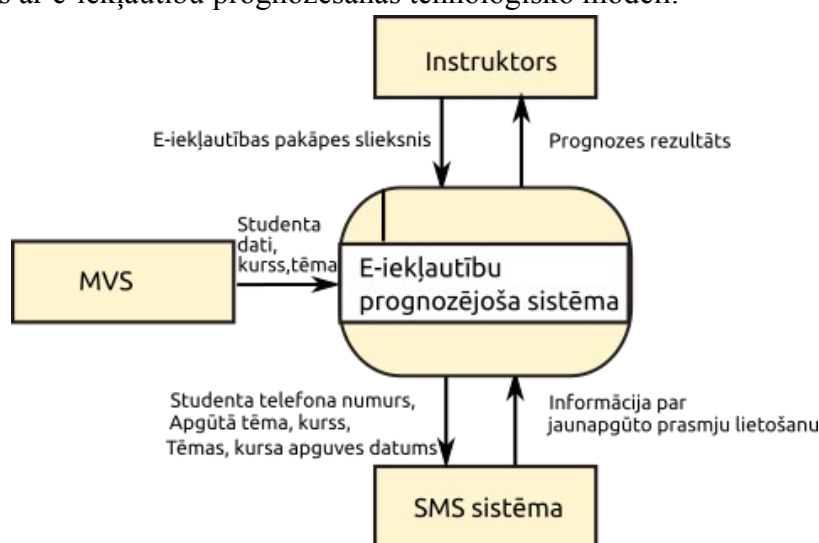
Mērķis	Nosacījums, kad mērķis ir sasniegts
Noteikt indivīdu, kam ir e-iekļautības risks	Instruktors ir uzzinājis par riska studentu kursa tēmai un saņēmis informāciju par riska faktoriem.
Veidot zināšanu bāzi	Izmantojot apmācību datu bāzi, ir izveidots prognozējošais modelis PROGN, ar kuru palīdzību var aprēķināt konkrētam indivīdam noteikta kursa tēmas e-iekļautības pazīmi.
Veidot apmācības piemēru datu bāzi	Izmantojot pirmapstrādes datus no e-studiju sistēmas un noskaidroto reālo indivīda e-iekļautības pazīmi, ir sagatavota piemēru datu bāze prognozes modeļa izveidei atbilstoši izvēlētajiem algoritmiem (klasifikatoru, lineārās regresijas, klasternalīzes).
Iegūt datus no e-studiju sistēmas	Studenta dati (aptauju rezultāti un studentu identificējoši dati) no dažādiem kursiem e-studiju sistēmā ir ievietoti pirmapstrādes datu bāzē.
Noskaidrot studenta reālo e-iekļautības pakāpi	Saņemta atbilde no studenta, vai students izmanto jēgpilni tēmā apgūtās digitālās prasmes. Ar iepriekš noteiktu laika nobīdi studentam tiek nosūtīts jautājums (SMS, e-pasts ar aptauju).
Veidot prognozējošo modeli $PROGN=f(M1, M2, M3, e\text{-iekļautības sliexsnis})$	Izveidots modelis studenta e-iekļautības pazīmes aprēķināšanai, izmantojot prognozēšanas M1, M2, M3 modeļus pie noteikta e-iekļautības sliexšņa. Novērtēta modeļa precizitāte.
Veidot prognozējošo M1 modeli	Izveidots studenta e-iekļautību prognozējošs modelis, izmantojot piemēru datu bāzi un klasifikatoru ansambļa metodi. Novērtēta modeļa precizitāte.
Veidot prognozējošo M2 modeli	Izveidots studenta e-iekļautību prognozējošs modelis, izmantojot piemēru datu bāzi un klasteranalīzes metodi. Novērtēta modeļa precizitāte.
Veidot prognozējošo M3 modeli	Izveidots studenta e-iekļautību prognozējošs modelis, izmantojot piemēru datu bāzi un daudzfaktoru lineārās metodi. Novērtēta modeļa precizitāte ar konkrētām e-iekļautības pakāpēm.
Aprēķināt M3 modeļa vērtību dažādām e-iekļautības pakāpēm	Izrēķinātas M3 modeļa vērtības, ja e-iekļautības pakāpe mainās no 0 līdz 100 % ar soli 5 %.
Prognozēt indivīda e-iekļautību	Prognozēta indivīda e-iekļautības pazīme konkrētam kursam un noteikti faktori, kas ietekmē indivīda e-iekļautības pakāpi (piem., instruktora spēja, dalīties ar zināšanām, studenta apmierinātība ar e-studiju vidi vai materiāliem). Par risku informēts instruktors.
Aprēķināt e-iekļautības prognozi	Aprēķināta indivīda e-iekļautības prognoze ar modeli PROGN, pirms tam nosakot e-iekļautības pazīmi katram modelim un izvēloties e-iekļautības sliexsni. Lai uzsāktu mērķa īstenošanu iegūti dati par studentu, kuram jāveic prognoze.
Noteikt e-iekļautības sliexsni	Izvēlēts, kāds būs e-iekļautības pakāpes sliexsnis, ar kuru rēķinās M3 modeļa vērtību
Noteikt un analizēt riska faktorus	Vadoties no atbilstošā prognozējošā modeļa, noteikti tur iekļautie riska faktori. Noteikta riska faktoru ietekme uz e-iekļautības pazīmi.
Informēt par risku instruktoru	Instruktors ieguvjis par riska studentu informāciju sistēmā.
Monitorēt modeļa kvalitāti	Noteikti produkcijā esošā prognozējošā modeļa veiktspējas rādītāji.

E-iekļaušanu prognozējošās sistēmas lietošanas gadījumi.

Mērķis	Lietošanas gadījums
Veidot zināšanu bāzi	Datu ievietošana piemēru un zināšanu datu bāzē, kas ietver datu saņemšanu no e-studiju sistēmas, datu saņemšanu par studenta reālo e-iekļaušanas pakāpi un prognozējošā modeļa izveidi.
Prognozēt studenta e-iekļautību	Pārskata pieprasīšana par studentiem, ka ietver konkrēta studenta identificēšanu, prognozes pieprasījumu. Atkarībā no prognozes, tas ir, ja prognoze ir, kas students atbilst riska grupai, tiek noteikti riska faktori un nepieciešamības gadījumā informēts students, administrācija.
Monitorēt modeļa kvalitāti	Prognozējošā modeļa kvalitāte tiek pārraudzīta, noskaidrojot studenta reālo iekļaušanas pakāpi, nosakot modeļa veiktspējas rādītājus ar produkcijas datiem un salīdzinot tos ar apmācītā modeļa veiktspējas rādītājiem.

E-iekļaušanu prognozējošās sistēmas pamatprocesi un datu plūsmas starp tiem

4.3. attēlā parādīta konteksta līmeņa datu plūsmas diagramma e-iekļautību prognozēšanas tehnoloģiskajam modelim. Šī diagramma sniedz pārskatu par citām sistēmām un personām, kas mijiedarbojas ar e-iekļautību prognozēšanas tehnoloģisko modeli.

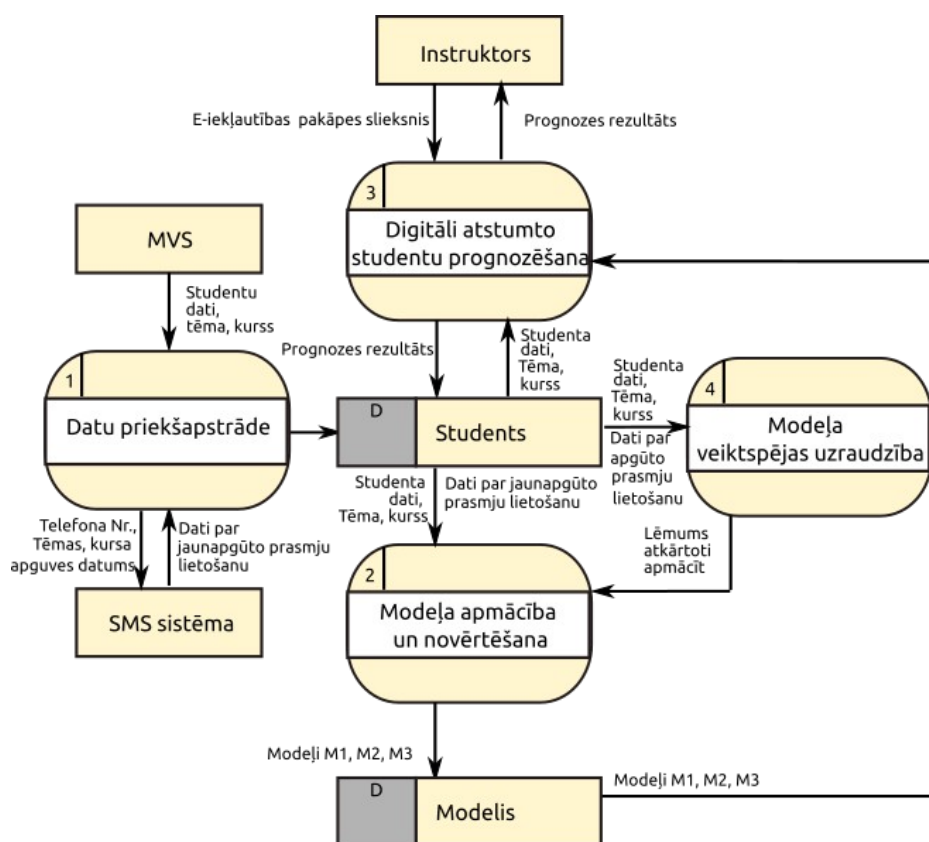


4.3. att. Konteksta līmeņa datu plūsmas diagramma, kas parāda saikni starp e-iekļautību prognozēšanas sistēmu, instruktoru, MVS (mācīšanās vadības sistēma) un SMS sistēmu.

Galvenais e-iekļautības tehnoloģiskā modeļa lietotājs ir instruktors, kurš māca studentus kombinētos mācīšanāsursos. Instruktors nosaka e-iekļautības pakāpes sliekšņa vērtības vai izmanto e-iekļautības sliekšņa noklusējuma vērtību. Instruktors saņem informāciju par riska studentiem un riska faktoriem, kas ietekmē studentu sniegumu. E-iekļautības tehnoloģiskais modelis saņem studentu datus un studenta kursa nosaukumu no mācību vadības sistēmas. Autore nolēma izmantot Moodle kā mācību vadības sistēmu, jo Moodle ir viena no visizplatītākajām atvērta koda platformām pasaulē (Moodle, 2020). Lai saņemtu studentu atsauksmes par apgūto prasmju izmantošanu pēc kursiem, tiek nosūtītas īsziņas uz studentu viedtālruniem. Lēmums izmantot SMS pieeju saziņai ar studentiem ir balstīts uz iepriekšējo pieredzi, nodrošinot kombinētas mācīšanās kursus, izmantojot vairāku ekrānu pieeju

(Kapenieks u. c., 2014; Žuga u. c., 2014). SMS sistēma saņem no e-iekļautību prognozējošās sistēmas studenta tālruņa numuru, apgūto kursu un pabeigšanas datumu. Četrus līdz sešus mēnešus pēc kursa pabeigšanas studenti no SMS sistēmas saņem jautājumu par to, vai jauniegūtās prasmes ir izmantotas profesionālām vai privātām vajadzībām. Jautājums tiek nosūtīts kā īsziņa. Studentam tiek lūgts atbildēt ar īsziņu par jauniegūto prasmju izmantošanu. Tad e-iekļautību prognozējošās sistēmas datu bāze tiek papildināta ar datiem par jauniegūto prasmju faktisko izmantošanu.

4.4. attēlā parādīti četri e-iekļaušanas prognozēšanas sistēmas pamatprocesi un datu plūsma starp šiem procesiem. Pamatprocesi ir: (1) datu priekšapstrāde; (2) prognozēšanas modeļa apmācība un novērtēšana; (3) riska studentu prognozēšana; (4) prognozēšanas modeļa veikspējas uzraudzība.



4.4. att. Datu plūsmas diagramma, kas parāda pamatprocesus un datu plūsmu starp procesiem e-iekļaušanas prognozēšanas sistēmā.

Datu priekšapstrāde. Datu iepriekšēja apstrāde e-iekļaušanas prognozēšanas sistēmai ietver datu kvalitātes novērtēšanu, datu tīrīšanu, datu pārveidošanu un citus datus sagatavošanas apmācībai vai prognozei procesus.

Dati tiek iegūti kā strukturētas tabulas no Moodle sistēmas. Datus veido studentu atbildes uz iepriekš izstrādātiem anketas jautājumiem, kur atbildes ir skaitliskas vērtības no 1 līdz 5. Moodle aptaujas jautājumi veidoti, balstoties uz zināšanu pārvaldības teoriju, un iegūtās atbildes izmantotas kā dati, no kuriem prognozēti studenta mācību rezultāti (Nissen, 2006). Tā kā studentiem ir iespēja vairākas reizes aizpildīt aptaujas, datus var būt dublikāti, tāpēc tiek izmantota pēdējā studenta atbildes versija. Datu sagatavošanas posmā sistēma kartē (savieno) studentu datus, kas iegūti no mācību vides Moodle ar atgriezeniskās saites datiem, kas iegūti

no SMS sistēmas. Problemātiski ir iegūt no studentiem datus par prasmju faktisko izmantošanu, jo atgriezeniskās saites sniegšana nav obligāta, bet gan brīvprātīga. Studentiem Moodle sistēmā anketas jāaizpilda divas reizes (pirms un pēc tēmas apguves), ja students anketu ir aizpildījis tikai vienu reizi, tad dati ir nepilnīgi. Nepilnīgus datus no datu bāzes attīra, kad apmācības kurss ir beidzies.

Šajā priekšapstrādes posmā sistēma arī aprēķina prognozēšanas modeļiem nepieciešamās atribūtu vērtības no studentu datiem. Datu priekšapstrādes rezultāts ir sagatavota studentu datu bāze, kas tiek izmantota modeļa apmācībai un prognozēšanai.

Prognozējošā modeļa veidošana un novērtēšana. Otrais e-iekļaušanas prognozējošās sistēmas process ir prognozēšanas modeļa apmācība un novērtēšana. e-iekļaušanas prognozēšanas sistēma kā pazīmes izmanto šādus mainīgos, kas raksturo:

- studenta vēlmi mācīties;
- studenta spējas mācīties;
- instruktora vēlmi dalīties zināšanās;
- studenta vērtējumu par e-mācību vidi;
- studenta e-mācību materiālu novērtējumu;
- studenta digitālo prasmju līmeni;
- studenta prognozēto jauniegūto prasmju izmantošanu.

Katram studenta ierakstam tika piešķirta rezultatīvā pazīme: “e-iekļauts” vai “nav e-iekļauts”. Vērtība pazīmei ir “e-iekļauts”, ja tika novērots, ka izglītojamais izmanto nesen apgūtās prasmes. Vērtība pazīmei ir “nav e-iekļauts”, ja tika novērots, ka izglītojamais neizmanto tikko iegūtās prasmes savām profesionālajām vajadzībām. Datu kopa satur 435 izglītojamās, kuri atbilst pazīmei “nav e-iekļauts”, un 493 “e-iekļautos” izglītojamās. Šis mainīgais tika nosaukts par novēroto jauniegūto prasmju izmantošanu. Lineārās regresijas modeļa atkarīgais mainīgais ir skaitliskais mainīgais – e-iekļautības pakāpe, kas ir paša studenta prognozētās un novērotās jauniegūto digitālo prasmju izmantošanas kombinācija. Datu kopā ir iekļauti dati no šādiem mācību kursiem: video tehnoloģijas un dizaina kurss; mobilo tehnoloģiju kurss; robotikas kurss; IKT prasmju uzlabošanas kurss. Kursu dalībnieki bija pedagogi, kuri pilnveidoja savas digitālās prasmes tālākizglītībasursos, lai jauniegūtās prasmes izmantotu skolēnu mācīšanās skolās.

Pēc vairāku modeļu apmācības un novērtēšanas tika secināts, ka studenta e-iekļautību var paredzēt, kombinējot vairākus prognozēšanas modeļus (skat. 3.6. nodaļu). 3.6. nodaļā ir dots e-iekļaušanu prognozējošā algoritma apmācības process.

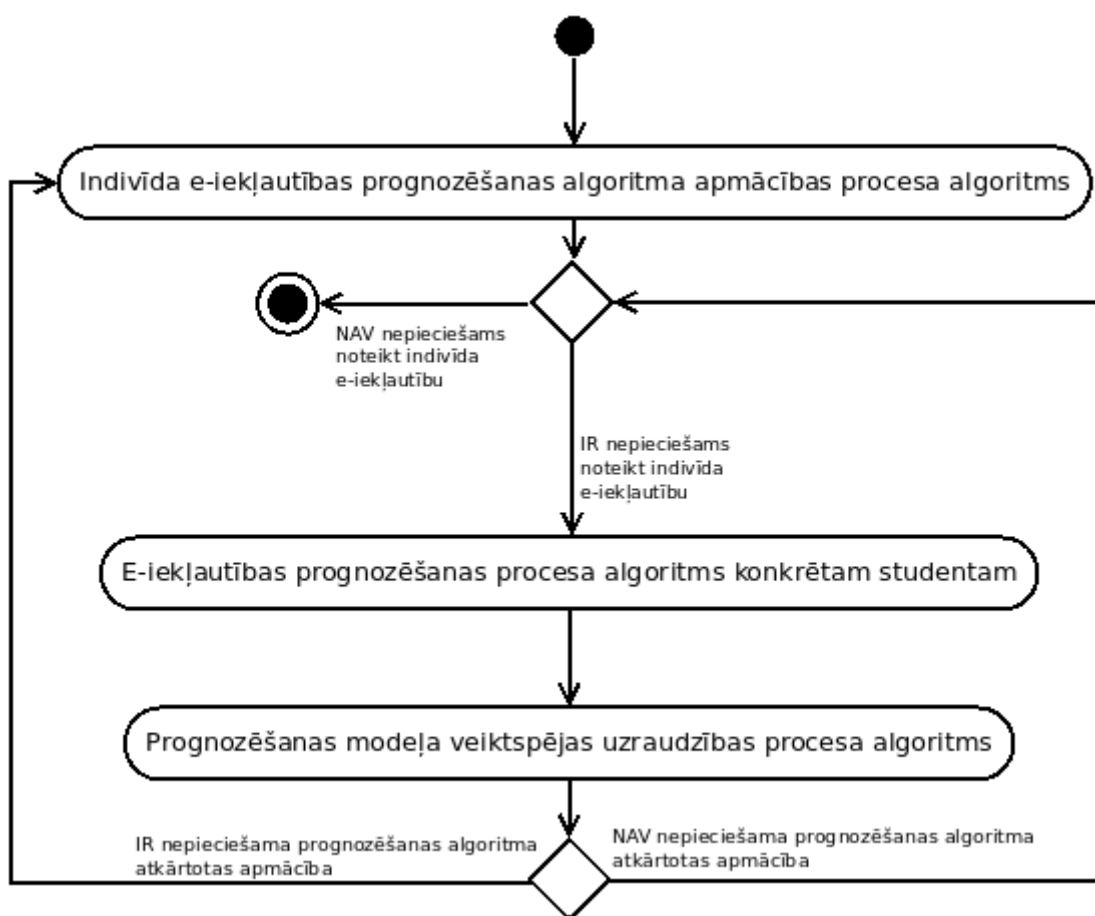
Riska grupas studentu prognozēšana. E-iekļaušanu prognozējošās sistēmas trešais process ir studenta mācību rezultātu aprēķināšana jaunapgūto prasmju izmantošanas kontekstā, nosakot digitālās atstumtības risku. Prognozēšanas procesā, tiek izmantoti studentu dati, kurus apmācītie modeļi iepriekš nav redzējuši. Prognozēšanas procesam nepieciešami iepriekš apmācīti modeļi, kas aprēķina studenta prognozi. Prognozēšanas procesa rezultāts ir riska grupas studentu noteikšana, lai instruktori varētu atbalstīt studentus mācību procesā un novērst to digitālo atstumtību. Prognozēšanas process ietver rezultātu atspoguļošanu instruktoram. Rezultātiem jābūt instruktoram viegli uztveramā formā, un tas ir viens no modeļa ieviešanas izaicinājumiem (Maskey u. c., 2019).

Modeļa prognozēšanas veikspējas uzraudzība. E-iekļaušanas prognozēšanas sistēmas izveides pēdējais process ir sistēmas uzturēšanas process, kas ietver prognozēšanas kvalitātes uzraudzību un atbilstošu rīcību, piemēram, prognozēšanas algoritma atkārtotu apmācību.

E-iekļaušanu prognozējošais algoritms

4.5. attēlā dota e-iekļaušanu prognozējošā algoritma shēma, kuru veido vairāki secīgi algoritmi:

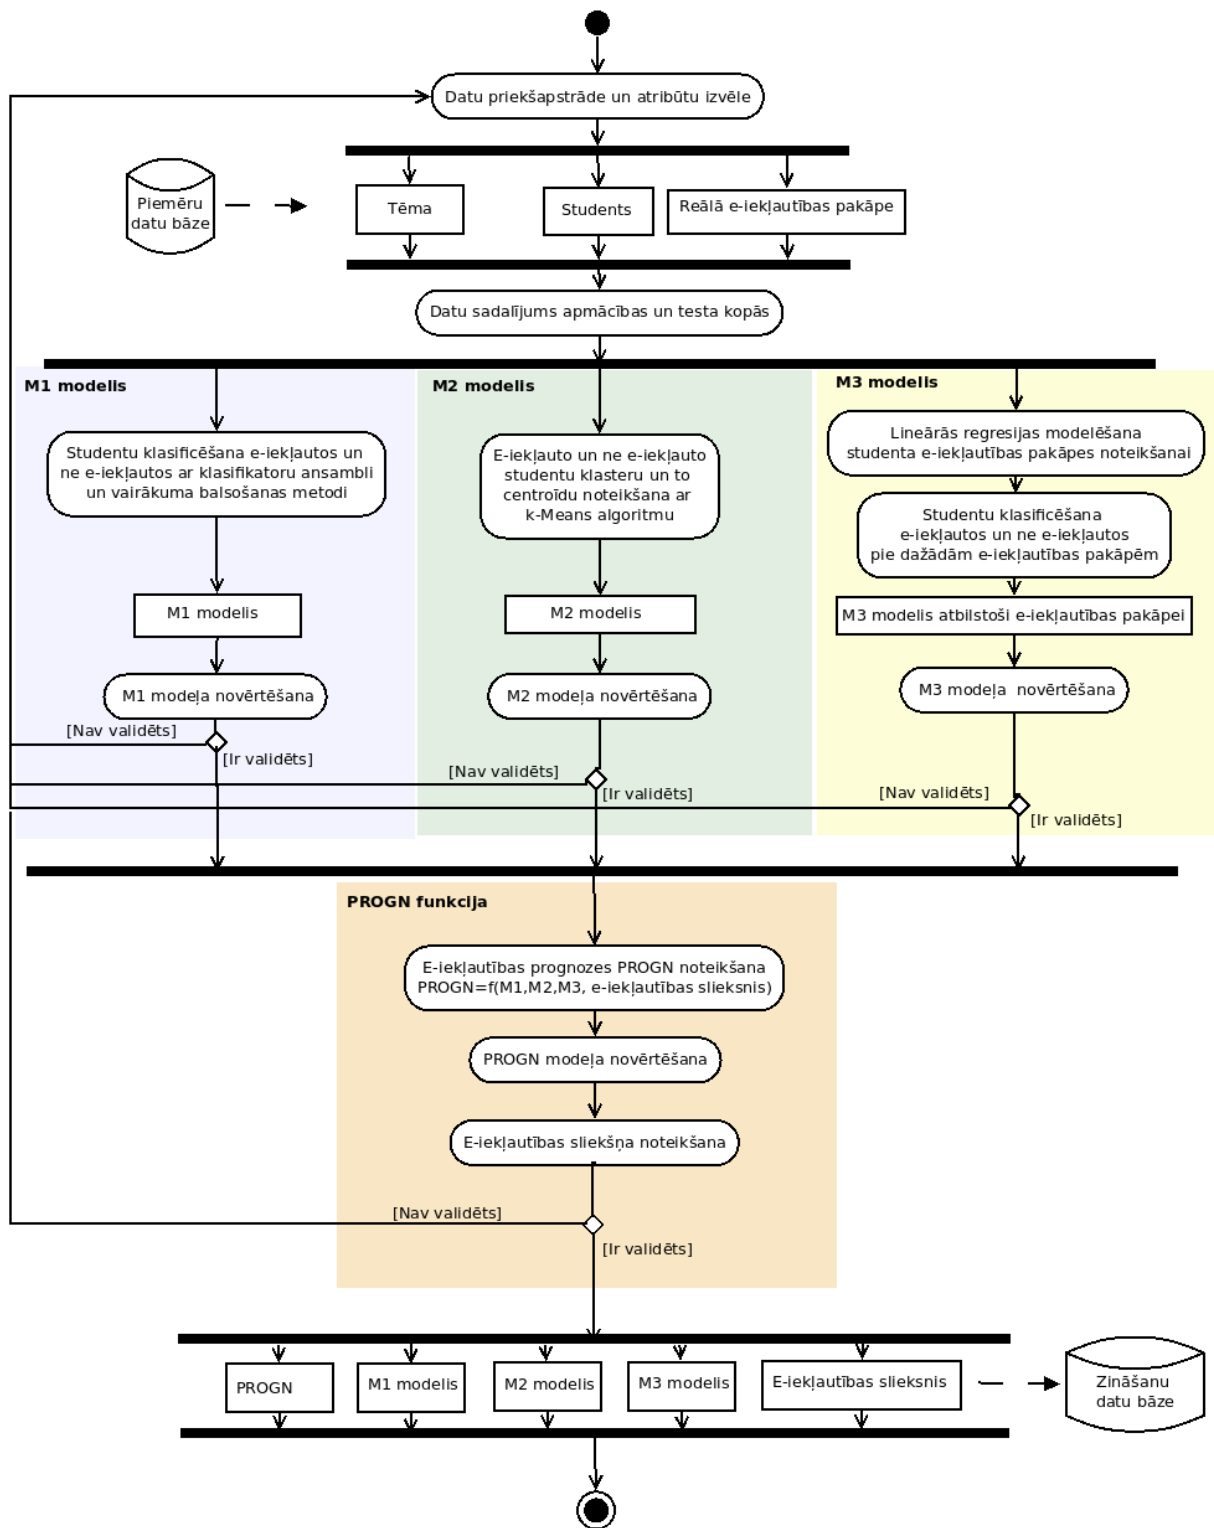
1. Apmācības procesa algoritms indivīda e-iekļautības prognozēšanas algoritmam, izmantojot trīs modeļu apmācību un PROGN funkcijas aprēķinu.
2. Prognozēšanas procesa algoritms konkrētam studentam, ja ir nepieciešams prognozēt studenta e-iekļautību.
3. Prognozēšanas modeļa veiktspējas uzraudzības procesa algoritms, ar kura palīdzību tiek secināts, vai atkārtoti nepieciešams apmācīt prognozēšanas algoritmu.



4.5. att. E-iekļaušanu prognozējošā algoritma shēma.

Shēmā attēlotie algoritmi detalizēti aprakstīti turpmāk šajā nodaļā.

E-iekļaušanu prognozējošā algoritma apmācības procesa algoritms. 4.6. attēlā parādīts e-iekļautības prognozēšanas algoritma apmācības process. Lai iegūtu e-iekļautību prognozējošo modeli PROGN, vispirms tiek apmācīti trīs dažādi prognožu M1, M2 un M3 modeļi, pēc tam tiek noteikta šo modeļu prognožu optimālā kombinācija un tiek aprēķināta galīgā prognozēšanas funkcija $PROGN = f(M1, M2, M2, e\text{-iekļautības sliexsnis})$.

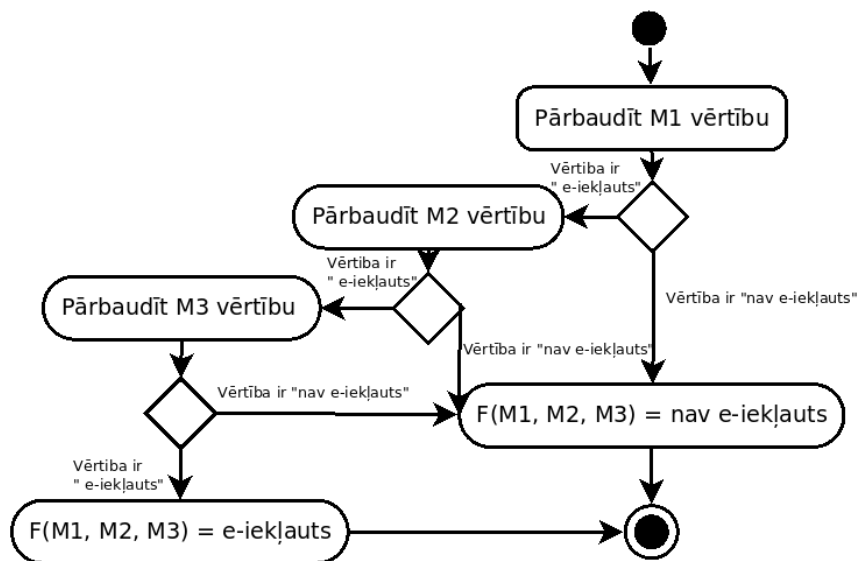


4.6. att. Apmācības process indivīda e-iekļautības prognozēšanas algoritmam, izmantojot trīs modeļu apmācību un PROGN funkcijas aprēķinu.

M1 modelis ir prognozēšanas modelis, kas klasifikatoru ansablī apvieno klasifikācijas modeļus, kas veidoti, izmantojot vairākuma balsošanas pieeju, ar šādiem algoritmiem – *lazy.LWL* ar *Random Forest*, *LMT* un *SimpleLogistic*. Prognozēšanas M2 modelis izmanto *kMeans* klasteru veidošanas algoritmu, tas sadala studentus divos klasteros, kur katrs no klasteriem atbilst e-iekļautiem vai ne e-iekļautiem studentiem. Prognozēšanas M3 modelis ir daudzfaktoru lineārās regresijas modelis, kas prognozē izglītojamā e-iekļautību atbilstoši

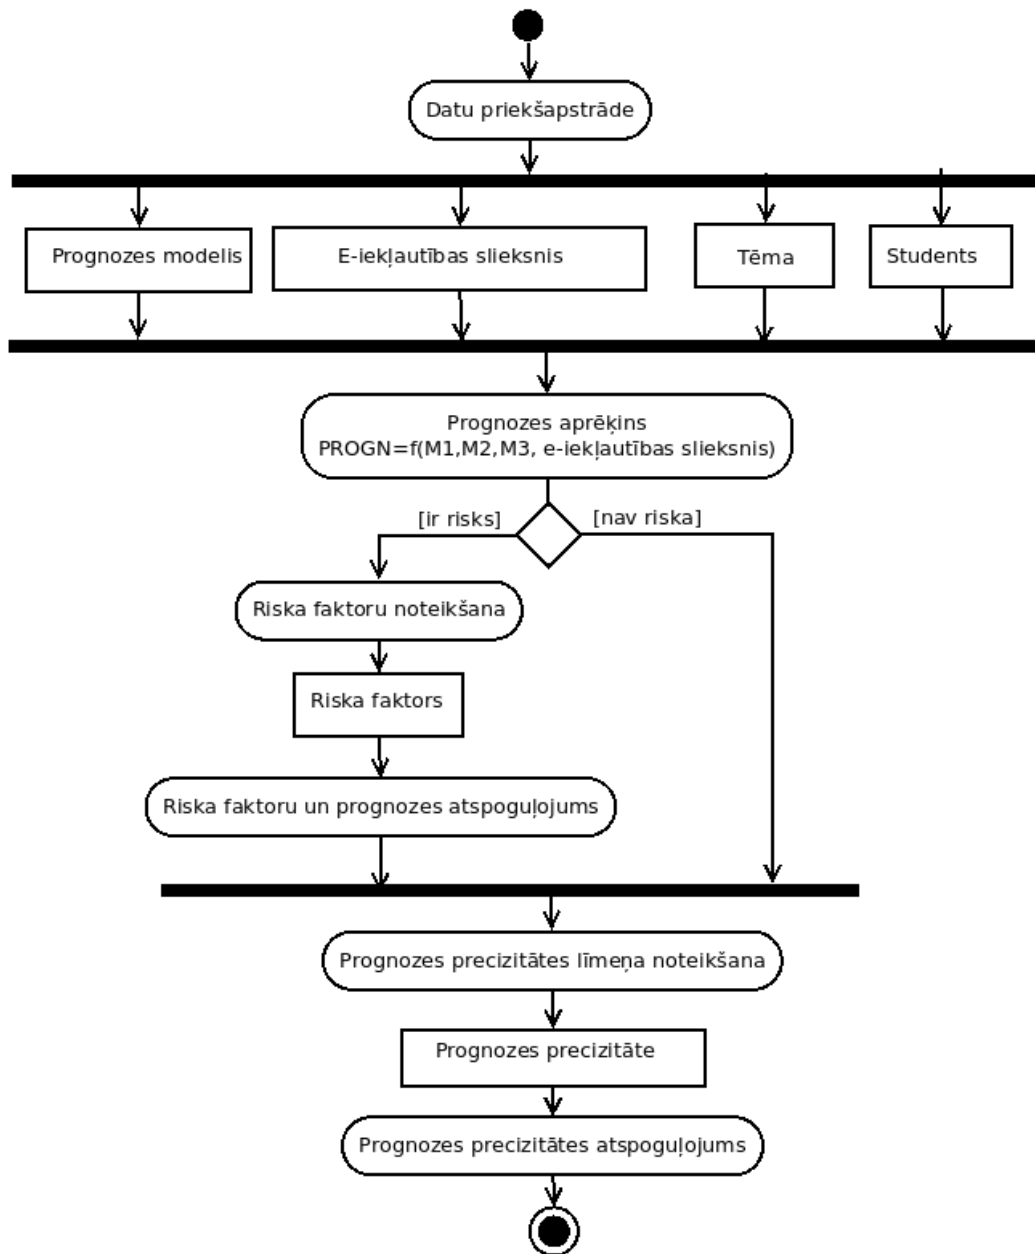
iepriekš noteiktam sliksnim.

Funkcija PROG, kas attēlo modeļu prognožu optimālo kombināciju, detalizētāk ir paskaidrota 4.7. attēlā. Ja M1 modelis paredz, ka students netiks digitāli iekļauts, tad gala rezultāts būs, ka students ir pakļauts riskam. Ja M1 modelis paredz, ka students tiks digitāli iekļauts, tad nākamais solis ir M2 modeļa prognozes pārbaude. Ja modelis M2 paredz, ka students netiek digitāli iekļauts, tad gala rezultāts atkal ir tāds, ka students ir pakļauts riskam. Līdzīgi tiek pārbaudīts M3 modelis. Šī pieeja tiek izvēlēta, lai pārbaudītu pēc iespējas vairāk studentu, kuri ir potenciāli pakļauti riskam. Tikai vienā gadījumā sistēma paredz, ka students nav pakļauts riskam, ja visi trīs modeļi prognozē, ka students ir digitāli iekļauts.




4.7. att. Fināla prognozes noteikšanas process, pamatojoties uz M1, M2, M3 modeļu prognozēm.

E-iekļaušanas prognozēšanas procesa algoritms. Prognozēšanas procesa algoritms konkrēta studenta e-iekļaušanas prognozei ir dots 4.8. attēlā. Lai sistēma veiktu prognozi, ir nepieciešams zināt tēmu, studenta datus, iepriekš definēto e-iekļautības sliksni un jābūt izveidotam (apmācītam) modelim, ar kuru prognozēt. Ja modeļa prognoze vēsta, ka pastāv digitālās izslēgšanas risks studentam, tiek noskaidroti, kādi riska faktori ir konkrētajam studentam, piemēram, e-vides novērtējums vai mācību materiālu novērtējums, vai arī instruktora spēja dalīties ar zināšanām. Prognozes vērtība un riska faktori tiek parādīti instruktoram, lai tas varētu pieņemt lēmumu par turpmāko rīcību, piemēram, mainīt kaut ko komunikācijā ar studentu, vai piedāvāt citus mācību materiālus utml.




4.8. att. Prognozēšanas procesa algoritms konkrētam studentam.

Prognozes precizitātes līmenis tiek noteikts atbilstoši 4.9. attēlā dotajam algoritmam. Ja modelis prognozi izdara, balstoties uz M1 modeļa prognozi, tad atbilstoši 3.6. nodaļā veiktajiem novērtējumiem tiek pieņemts, ka prognozes precizitātes līmenis ir augsts. Ja modelis prognozei izmanto M1 un M2 modeļu kombināciju, tad tiek pieņemts, ka prognozes precizitātes līmenis ir vidējs. Ja prognoze tiek balstīta uz M1, M2, M3 modeļu kombināciju un ja tiek prognozēts, ka students ir riska grupā, tad prognozes precizitātes līmenis ir zems, bet, ja tiek prognozēts, ka students nav riska grupā, tad prognozes precizitātes līmenis ir augsts.



4.9. att. Prognozēšanas precizitātes līmeņa noteikšanas algoritms konkrētam studentam.

Prognozēšanas modeļa veikspējas uzraudzības procesa algoritms. Prognozēšanas modeļa veikspējas uzraudzības process, kura mērķis ir noteikt, vai nepieciešama atkārtota prognozējošā modeļa apmācība, dots 4.10. attēlā. E-ieklausānu prognozējošās sistēmas piemēru datu bāze tiek papildināta, lai to varētu izmantot modeļa veikspējas novērtēšanai un atkārtotai modeļa apmācībai. Noteiktu laiku (piemēram, 8–10 nedēļas) pēc studenta datu apstrādes, sistēma nosūta studentam jautājumu par reālo digitālo prasmju izmantošanu. Atbilde tiek ierakstīta piemēru datu bāzē. Iepriekš noteiktos laika posmos tiek novērtēti modeļa veikspējas rādītāji. Ja modeļa kvalitāte samazinās, prognozējošais modelis tiek apmācīts atkārtoti ar jauniegūtajiem datiem, kas iekļauj datus par reālo prasmju lietojumu. Prognozējošā modeļa apmācību sistēma veic, izmantojot iepriekš aprakstīto algoritmu, kur apmācības process indivīda e-iekļautības prognozēšanas algoritmam notiek, izmantojot trīs modeļu apmācību, kas izmanto klasifikācijā, klasteranalīzē un lineārā regresijā balstītas metodes, un fināla prognozes funkcijas aprēķinu.



4.10. att. Prognozēšanas modeļa veiktspējas uzraudzības procesa algoritms.

4.2. E-iekļaušanu prognozējošas sistēmas prototips

E-iekļaušanas prognozēšanas sistēmas prototipam tika programmēta jauna lietojumprogramma. Kā programmēšanas valoda ir izvēlēta *Java*, izmantota atvērtā pirmkoda programmatūras izstrādes vide *Eclipse* (<http://www.eclipse.org/>) (izlaidums *eclipse 3.8*). Lai izveidotu prognozēšanai nepieciešamos modeļus, kas izmanto klasifikatoru ansambli, lineārās regresijas vienādojumu un klasteranalīzi, lietota atvērtā pirmkoda mašīnmācīšanās programmatūras *WEKA* (*Waikato Environment for Knowledge Analysis*, (<http://www.cs.waikato.ac.nz/~ml/weka/>) bibliotēkas.

Prototipa izveidē izmantota trīs līmeņu arhitektūra, kas loģiski sadala lietojumprogrammu trīs līmeņos: prezentācijas līmenis, biznesa loģikas līmenis un datu līmenis. Biznesa loģikas līmenī tiek realizēta prototipa funkcionalitāte (piemēram, apmāca prognozēšanas modeļus, prognozē, nosaka veiktspējas rādītājus). Prezentācijas līmeņa uzdevums ir informācijas saņemšana un tās atspoguļošana prototipa lietotājiem (piemēram, studentus raksturojošie dati, atbilstoša prognoze, prognozējošos modeļus raksturojošie parametri). Datu līmenis organizē datu pārvaldību. Prototipa klašu diagrammas ir pievienotas 8. pielikumā. Prototipa koda paraugi ir pievienoti 9. pielikumā. Prototipa ekrānu skati ir pievienoti 10. pielikumā.

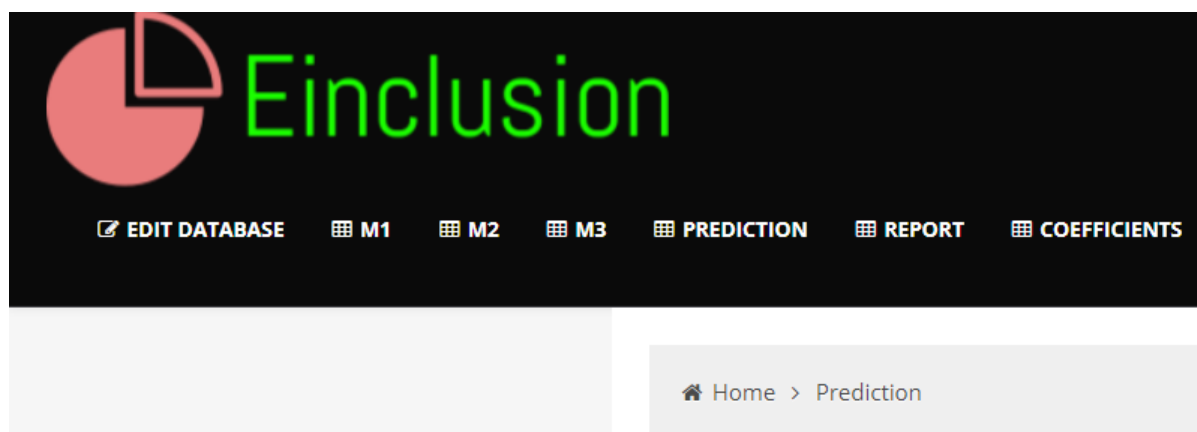
Prototips ir e-iekļaušanas prognozēšanas sistēmas agrīna versija, tas sastāv no bāzes funkcionalitātes un prototipā ir izvietots e-iekļaušanu prognozējošais algoritmiskais modelis. Prototipam ir daži ierobežojumi, bet tie neietekmē prognozējošā modeļa un prototipa mērķa novērtēšanas iespējamību atbilstoši iepriekš izvirzītajiem mērķiem. Piemēram, prototipā dati ir jāaugšupielādē manuāli, tiešsaistes datu importēšana no *Moodle* sistēmas prototipā netika ieviesta. Nav īstenota datu augšupielāde no *SMS* sistēmas. Studentiem jautājumi tika nosūtīti pa e-pastu, lai noteiktu, vai studenti izmanto kursā iegūtās prasmes, un atbildes tika iegūtas, izmantojot *Google* veidlapas.

E-iekļaušanas prognozēšanas prototipa galvenais uzdevums ir informēt instruktorus par riska studentiem. Prototipa izstrādes mērķis ir noteikt un novērtēt e-iekļaušanas

prognozēšanas sistēmas pamata funkcionalitātes atbilstību sistēmai izvirzītajiem mērķiem.

Galvenā e-iekļaušanas prognozēšanas sistēmas prototipa funkcionalitāte: (1) instruktors spēj meklēt studentus, iegūt prognozes par studentiem (e-iekļauts vai nav e-iekļauts); (2) sistēma instruktoram parāda faktoros, kas ietekmē prognozēšanas rezultātu (piemēram, studentu motivācija, studentu pašnovērtējums par mācību materiāliem vai e-mācību vidi u.c.); (3) instruktors spēj lejupielādēt prognozēšanas rezultātus.

Prototipā tiek izmantoti iepriekšējā nodaļā aprakstītie e-iekļaušanu prognozējošie M1, M2, M3 modeļi, lai prognozētu katra izglītojamā mācību rezultātus e-iekļaušanas kontekstā. Ja algoritms paredz, ka lietotājs tiks digitāli izslēgts, instruktors saņem informāciju par faktoriem, kas ietekmē studentu mācību rezultātus. Prototipa galvenās izvēles organizētas tā, lai būtu iespējams redzēt indivīda e-iekļautības prognozes rezultātus, kas iegūti ar katru no M1, M2, M3 modeļiem, kā arī fināla prognozi, kas veidota šos modeļus apvienojot. Prototipa galvenās izvēles paredz arī darbības ar studentu datu failiem, kas tiek izmantoti prognožu modeļu izveidē vai e-iekļautības prognozēšanā, pārskatu iegūšanu un prognozēšanas modeļu parametru apskati (4.11. att.)



4.11. att. E-iekļautības prognozēšanas prototipa galvenās izvēles.

Galveno prognozēšanas rezultātu skats instruktoram prototipā

4.12. attēlā parādīts prognozēšanas rezultātu skats tabulas formā. Katrā tabulas rindā ir šāda informācija par studentu: kādi modeļi (M1, M2 vai M3) ir izmantoti prognozēšanai, kāda ir paredzamā studenta e-iekļaušanas vērtība (riskam pakļauts vai nav pakļauts riskam) un kāds ir prognozēšanas precizitātes līmenis (augsts, vidējs, zems). Šajā tabulā ir norādītas četras iespējamās prognozēšanas un precizitātes līmeņa kombinācijas.

Video	Name	Submit date	M1	M2	M3	Prediction	Precision
Video	Jānis Bērziņš	2019-08-09	Risk	No risk	No risk	Risk	High
Video	Anna Liepiņa	2019-08-09	No risk	Risk	No risk	Risk	Medium
Video	Juris Ozols	2019-08-07	No risk	No risk	Risk	Risk	Low
Video	Eva Egle	2019-08-07	No risk	No risk	No risk	No risk	High

4.12. att. Prognozēšanas rezultātu skats un precizitātes līmenis tabulas formā.

Lai padarītu informāciju vieglāk uztveramu, prototipā ir izmantota sarkanās krāsas toņi

brīdinājumam par risku un zaļā krāsa, ja nav riska (*Silic un Cyr, 2016*).

Lai aprēķinātu galīgo prognozi, prototips izmanto M1 modeļa, M1 un M2 modeļu kombinācijas vai M1, M2 un M3 modeļu kombinācijas prognozēšanas rezultātus, atbilstoši iepriekšējā nodaļā 3.14. attēlā parādītajam algoritmam. Modelis PROGN ir funkcija, kuras vērtība ir M1 modeļa vērtība, ja M1 modelis prognozē, ka students ir riska grupā. Ja M1 modelis prognozē, ka students ir e-iekļauts, tad tiek pārbaudītas M2 modeļa vērtība un M3 modeļa vērtība, lai palielinātu pārklājumu.

Lai palīdzētu instruktoram interpretēt prognozēšanas rezultātus, prototipā prognozes vērtība tiek papildināta ar rādītāju, kas raksturo, kādā pakāpē var uzskatīt prognozi par precīzu. Modeļa veikspējas mērījumi parādīja, ka modeļu kombināciju precizitāte ir atšķirīga. Ja M1 modelis tiek salīdzināts ar M1 un M2 modeļa kombināciju, tad modeļa kombinācijas gadījumā tiek aptverti vairāk riska studentu, bet vienlaikus ar riska studentiem tiek prognozēti tie, kuri faktiski ir e-iekļauti. Detalizētāks skaidrojums ir 3. nodaļā.

Detalizēts prognozēšanas rezultātu skats instruktoram

Lai nodrošinātu, ka instruktoram ir iespēja dziļāk izprast iemeslus, kas ietekmē studentu mācību rezultātus, prototipam ir detalizēts studentu datu un atbilstošo prognozēšanas rezultātu skats tabulas veidā (4.13. att.).

Name	Motivation	Digital skills	Ability to learn	Instructor	E-environment	E-materials	Predicted usage	M2
Jānis Bērziņš	3.5	1.0	2.0	2.0	4.0	2.0	1.0	Risk
Anna Liepiņa	4.0	5.0	1.0	5.0	4.5	4.0	5.0	Risk
Juris Ozols	4.5	4.5	3.0	5.0	5.0	4.0	4.0	Risk
Eva Egle	5.0	4.0	4.0	5.0	5.0	5.0	5.0	No risk

4.13. att. Studentu datu skats un atbilstošās prognozes tabulas veidā.

Katra prognozēšanas modeļa rezultāti ir sasaistīti ar tabulu, kurā instruktors var redzēt studenta pašnovērtējumu par motivāciju, digitālo pamatprasmju līmeni, novērtējumu par instruktora vēlmi dalīties ar zināšanām, e-mācību vides izmantojamību, e-mācību materiālu piemērotību, kā arī redzama studenta prognoze par jauniegūto prasmju izmantošanu un studenta mācīties spēju pašnovērtējums, kas tiek aprēķināts, salīdzinot atbildes pirms un pēc konkrētas tēmas apguves. Vērtības tabulā ir no 1 līdz 5, jo augstāka vērtība, jo augstāk students ir novērtējis attiecīgo īpašību.

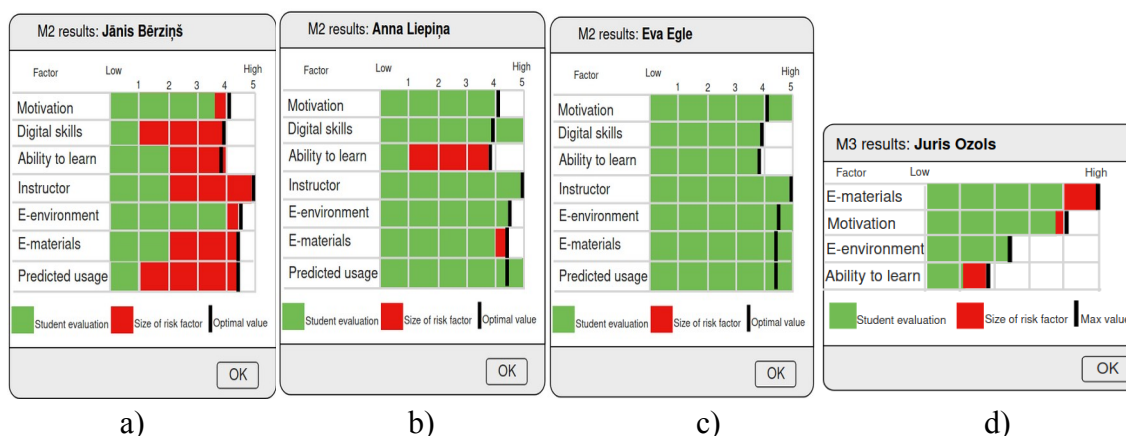
Pamatojoties uz šīm vērtībām, pasniedzējs var secināt, kas rada risku, ka students tiks digitāli izslēgts. Zemas vērtības norāda, ka šīs pazīmes nepietiekamība var būt iemesls tam, ka students pēc studiju beigām nevarēs pielietot kursā apgūtās prasmes.

Lai noteiktu, kuras pazīmes konkrētam studentam ir vissvarīgākās, prototips pasniedzējam piedāvā vizuālu skatu, pamatojoties uz apmācības posmā iegūtajiem algoritmiem. Studenta riska faktori ir iekrāsoti sarkanā krāsā.

4.14. attēlā (a), (b) un (c) attēlota prognozēšanas rezultātu vizualizācija, kas iegūta no M2 modeļa. Lai interpretētu M2 prognozēšanas rezultātus, tika izmantotas modeļa apmācības procesā aprēķinātās centroīdu vērtības divām klasēm: “e-iekļauts” un “nav e-iekļauts” (skatīt 3. nodaļu un 3.19. attēlu).

4.14. a) attēlā parādīta studenta datu vizualizācija, kurā tiek prognozēts, ka risks studentam tikt digitāli izslēgtam ir ar augstu ticamības pakāpi. Instruktoram var redzēt, ka šim

studentam galvenie riska faktori ir zems digitālo pamatprasmju līmenis un komunikācija starp instruktoru un studentu mācību procesā. Redzams, ka students uzskata, ka viņš drīzāk neizmantos jaunapgūtās prasmes nākotnē, piemēram, kā iemesls tam var būt, ka studentam nav prasmju izmantošanai nepieciešamā tehniskā aprīkojuma. Šim studentam ir problēmas ar spēju mācīties – zināšanu līmenis, salīdzinot ar to pirms un pēc tēmas apguves, nav būtiski uzlabojies. Iespējams, ka tas var būt saistīts ar grūti saprotamiem e-mācību materiāliem. Pamatojoties uz brīdinājumiem par studenta vāmajām vietām, instruktors var izlemt, kādas darbības veikt. Informācija šajā prototipa skatā tiek vizualizēta šādi: zaļās joslas parāda, cik lielā mērā studentam piemīt kāda no īpašajām iezīmēm, bet sarkanā – cik daudz tam trūkst, lai sasniegtu šīs iezīmes optimālo vērtību. Iezīme jeb faktors, kuram ir vizuāli garāka sarkanā josla, vairāk ietekmē studentu, un tie ir galvenie studenta riska faktori. Centroīdu vērtības, kuras nosaka *kMeans* algoritms, attēlo melna vertikāla josla. Tie iezīmē robežu, kas studenta iezīmei jāsasniedz, lai izvairītos no digitālās atstumtības riska.



4.14. att. M2 un M3 modeļa rezultātu detalizēts skats individuālam izglītojamam. a) modeļa M2 prognoze par riska studentu ar augstu precizitāti; b) modeļa M2 prognoze par riska studentu ar vidēju precizitāti; c) M2 modeļa prognoze par studentu bez riska ar augstu precizitāti; d) M3 modeļa prognoze par riska studentu ar zemu precizitāti.

4.14. b) attēlā parādīti M2 modeļa prognozēšanas rezultāti gadījumā, ja risks studentam tikt digitāli izslēgtam ir ar vidēju ticamības pakāpi. Instruktors var redzēt visas studenta iezīmju vērtības. Šajā gadījumā sarkanā krāsā ir divi faktori: spēja mācīties un e-mācību materiāli. Šie faktori varētu būt šķērslis šim studentam iegūtās prasmes tālāk izmantot savām profesionālajām vajadzībām. Tā kā studenta spēja mācīties tiek novērtēta atbilstoši zināšanu pieaugumam pēc tēmas apguves, tad iespējams, ka zema vērtība varētu būt saistīta ar zemu e-mācību materiāla novērtējumu. Šajā gadījumā kā viena no iespējamām instruktora aktivitātēm ir konkrētam studentam piemērotāko mācību materiālu veidu precizēšana un piedāvājuma papildināšana šim studentam. Salīdzinot M2 modeļa prognozēšanas rezultātus, ja prognozes rezultāts ir ar vidēju vai augstu ticamības pakāpi, tika novērots, ka vidējas ticamības pakāpes gadījumā studentiem ir mazāk riska faktoru nekā augstas ticamības pakāpes gadījumā. Ja studentam ir mazāk riska faktoru, tad tas tuvina studentu e-iekļauto studentu klasei, un tāpēc instruktors, ja resursi ir ierobežoti, var izvēlēties sazināties tikai ar tiem riska studentiem, kuriem prognoze ir ar augstu ticamības pakāpi.

4.14. c) attēlā parādītas iezīmes studentam, kuru prototips prognozē kā e-iekļauto. Instruktors var redzēt, ka visas iezīmes ir zaļas un tām ir salīdzinoši augstas vērtības.

M3 modelis ir balstīts uz lineārās regresijas algoritmu, tāpēc prototips vizualizē M3 modeļa rezultātus atbilstoši apmācītajam lineārās regresijas algoritmam (skat. 3. nodaļu un 3.20. att.). Modeļa apmācības procesā tika iegūts, ka lineārās regresijas modelī e-iekļaušanas pakāpes prognozēšanai tiek izmantoti tikai četri atribūti: Studenta motivācija, studenta spēja mācīties, e-mācību materiālu novērtējums un e-mācību vides novērtējums. Atbilstoši modelim studenta pazīmēm ir atšķirīga ietekme uz prognozi. E-mācību materiāliem un studenta motivācijai ir lielāka ietekme, e-mācību videi un studenta spējai mācīties - ir mazāka ietekme. Prototips vizualizē un informē instruktoru atbilstoši algoritma noteiktajiem koeficientiem par ietekmi uz prognozi. Piemēram, 4.14. attēlā (d) parādīts riska faktoru lielums saskaņā ar lineārās regresijas algoritmu, kur instruktors var redzēt, ka e-materiāli un spēja mācīties varētu būt studenta riska faktori. Ja pasniedzējs pārbauda studentu datus tabulas veidā, kā parādīts 4.11. attēlā, tiek norādīts, ka spējas mācīties vērtība ir 3.0 un e-materiālu novērtējuma vērtība ir 4.0, tas redzams arī vizuālā skatā, kur prototips parāda, ka e-materiālu novērtējums ir lielāks riska faktors nekā spēja mācīties.

4.3. E-iekļaušanu prognozējošā algoritmiskā modeļa un prototipa novērtējums

E-iekļaušanas prognozējošā algoritmiskā modeļa un prototipa novērtēšanai tika izmantota 160 stundu gara modernās interešu izglītības mācību programma (*www.mii.lv*), kuras mērķis ir palīdzēt pedagogiem apgūt digitālās prasmes, lai vadītu neformālās izglītības nodarbības. Programmas ietvaros 2014. un 2015. gadā pedagogi praktiski iepazinās ar jaunākajām tehnoloģijām, programmēja to elementus, kā arī meklēja tām jaunus pielietojumus skolēnu apmācības procesā. Pedagogi specializējās vienā no trim tēmām: robotikas tehnoloģijas, video izveide un apstrāde, mobilās tehnoloģijas. Apmācības notika, apvienojot klātienē semināru nodarbības, darbu interneta vidē Moodle platformā un praktisku dažādu ierīču paraugu programmēšanu un izmēģināšanu.

E-iekļaušanu prognozējošā modeļa un prototipa novērtēšanai sagatavota datu kopa no 65 studentu ierakstiem, kas iepriekš prognozējošā modeļa izveidei nav izmantoti. Kā datu avoti analīzei izmantotas izglītojamo aizpildītas aptaujas Moodle platformā, aptaujas pēc mācību programmas pabeigšanas, e-iekļaušanu prognozējošā modeļa aprēķinātās prognozes. Kā pazīmes, kas raksturo izglītojamās, atbilstoši 3. nodaļā aprakstītajam, ir izmantoti Moodle aptaujās iegūtie un prognozēšanai sagatavoti dati, kas satur šādu izglītojamā pašvērtējumu:

- pakāpe instruktora vēlmei dalīties ar zināšanām;
- studenta apmierinātības līmenis ar e-vidi;
- studenta apmierinātības līmenis ar e-materiāliem;
- studenta spējas mācīties pakāpe;
- studenta vēlmes mācīties pakāpe;
- studenta pamata digitālās prasmes;
- studenta prognoze par jaunapgūto prasmju lietošanu.

Lai pārbaudītu modeļa prognozes atbilstību reālajai situācijai, 4 līdz 6 mēnešus pēc programmas apguves no izglītojamajiem tika iegūta informācija, vai tie izmanto jaunapgūtās prasmes.

E-iekļaušanas pakāpes sliekšnis atbilstoši iepriekš autores veiktajiem pētījumiem e-iekļaušanu prognozējošā modeļa novērtēšanai ir 80 %.

E-iekļaušanu prognozējošā modeļa novērtējums

Pētījuma mērķis ir novērtēt e-iekļaušanu prognozējošo modeli, salīdzinot modeļa prognozi par digitālo prasmju lietojumu ar reālo jaunapgūto digitālo prasmju lietojumu profesionālo izglītības iestāžu pedagogiem, kuri apgūst digitālās prasmes kombinētās mācīšanāsursos.

Mašīnmācīšanās pieejā balstīta modeļa novērtējums ietver tā novērtējumu atbilstoši mašīnmācīšanās uzdevumam (veiktspējas un robustuma novērtējums) noteiktajām prasībām (skat. 2. nodaļu) un biznesa mērķiem (*Ashmore* u. c., 2019; *Studer* u. c., 2021; *Zhang* u. c., 2020).

Lai novērtētu e-iekļaušanu prognozējošā modeļa veikspēju un atbilstību biznesa mērķiem, noteikti trīs pētījuma jautājumi:

1) cik procentu no visiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos, modelis spēj prognozēt kā piederošus riska grupai;

2) cik procentu no modeļa prognozētajiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos, reāli pieder riska grupai;

3) cik lielā mērā ir iespējams ar modeli (būtiski nepazeminot modeļa veikspējas rādītājus) prognozēt e-iekļautību indivīdiem, kas apgūst digitālās prasmes kursus, kas atšķiras no tiem kursiem, ar kuru datiem ir apmācīts prognozējošais modelis.

Binārā klasifikācijas uzdevumā klasifikācijas modeļu veikspēju novērtē, izmantojot pārklājuma, precizitātes, F mēra vērtības (*Seliya* u. c., 2009). Autore izmantoja F2 mēru, lai uzsvērtu pārklājuma nozīmi. F2 mērs apvieno precizitāti un pārklājumu, liekot dubultu uzsvāru uz pārklājumu.


Modeļa prognoze par studentiem, kas lietos vai nelietos jaunapgūtās prasmes, un reālais prasmju lietojumu skaits ir parādīts pārpratumu matricā (4.3. tab.). Kā redzams tabulā modelis nav atpazinis tikai trīs studentus (no 31 studenta), kas ir riska grupā un nav lietojuši jaunapgūtās prasmes.

4.3. tabula

E-iekļaušanu prognozējošā modeļa pārpratumu matrica: modeļa prognozes un reāli novērotā situācija par jaunapgūto prasmju lietojumu.

<i>n</i> = 65	Prognoze, ka nelietos jaunapgūtās prasmes	Prognoze, ka lietos jaunapgūtās prasmes	
Reāli nelieto jaunapgūtās prasmes	28	3	31
Reāli lieto jaunapgūtās prasmes	13	21	34
	41	24	

No pārpratumu matricas iegūtie modeļa veikspējas rādītāji ir doti 4.15. attēlā.



4.15. att. E-iekļaušanu prognozējošā modeļa veikspējas rādītāji.

Kā galvenie veikspējas rādītāji modeļa novērtēšanai ir tā pārklājums un precizitāte. E-iekļaušanu prognozējošā modeļa pārklājums ir 0,903, tas nozīmē, ka modelis spēj prognozēt kā piederošus riska grupai 90,30 % procentus no visiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanās kursos. Modeļa precizitāte ir 0,683, tas nozīmē, ka reāli 68,3 % no modeļa prognozētajiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem pieder riska grupai. Tā kā modelis prognozē riska grupas studentus, tad var secināt, ka modelis izpilda tam paredzētos biznesa mērķus.

Modeļa F2 mēra vērtība ir 0,848 un modeļa akurātums ir 0,754. Modeļa veikspējas rādītāji atbilst iepriekš izvirzītajām prasībām un tos var uzskatīt par pietiekami augstiem, lai modeli izmantotu prognozēšanā. Modeļa veikspējas rādītāji atbilst zinātniskajā literatūrā norādītajiem studentu sasniegumu prognozēšanas modeļu rādītājiem dažādās mašīnmācīšanās tehnikās.

E-iekļaušanu prognozējošā modeļa novirzes novērtējums

Kad modelis ir izvietots sistēmā, būtiski ir veikt modeļa kvalitātes pārraudzību (*Schelter* u. c., 2018). Autore nolēma novērtēt modeļa kvalitāti, mērot prognozējošā modeļa novirzi no sākotnējiem, apmācības procesā iegūtajiem veikspējas rādītājiem. Vairāku neatkarīgu prognozēšanas modeļu izmantošana vienlaicīgi, kas balstās uz teoriju par n-versiju mašīnmācīšanās pieeju, rada lielāku iespējamību atklāt novirzes modeļu rezultātos, jo ir iespējams salīdzināt individuālo modeļu prognozes (*Gujarati* u. c., 2020; *Machida*, 2019). Tā kā e-iekļaušanu prognozējošā modeļa gala prognoze tiek veidota no trīs neatkarīgu modeļu prognozēm, autore novērtēja novirzi katram no šiem modeļiem, kā arī salīdzināja modeļu prognožu izmaiņas.

Pētījuma mērķis ir novērtēt e-iekļaušanu prognozējošā modeļa un to veidojošo modeļu novirzi, salīdzinot apmācības un testa datu kopu veikspējas rādītājus: F mēru, pārklājumu, precizitāti modeļa prognozei par studentiem, kas nelietos jaunapgūtās digitālās prasmes.

Lai novērtētu e-iekļaušanu prognozējošā modeļa novirzi, noteikti šādi pētījuma jautājumi:


1) par cik procentiem izmainās modeļa un to veidojošo modeļu prognozes pārklājums, tas

ir skaits, cik no visiem riska grupas studentiem – profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos, modelis spēj atklāt;

2) par cik procentiem izmainās modeļa un to veidojošo modeļu prognozes precizitāte, tas ir skaits, cik no visiem prognozētajiem riska grupas studentiem – profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos, tiešām nelietos jaunapgūtās prasmes.

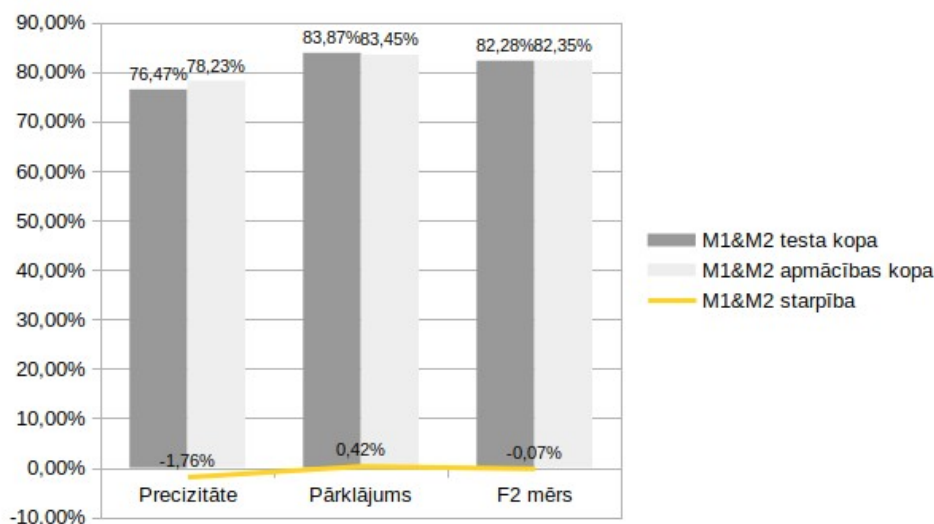
3) Par cik procentiem izmainās modeļa un to veidojošo modeļu F mēra vērtība, kas raksturo kopējo modeļa kvalitāti.

Tika salīdzināti F2 mēri apmācības un testa datu kopām (4.16. att.). F2 mērs bija lielāks apmācības datu kopai, taču atšķirība bija neliela – mazāks par 1,47 %. Apmācības kopas F2 mērs ir 86,31 %, testa kopas – 84,83 %. Pārklājumiem atšķirība ir šāda – apmācības kopai pārklājuma vērtība ir 95,63 %, testa kopai – 90,30 %. Pārklājums testa kopai ir samazinājies par 5,33 %. Precizitāte testa kopai ir 68,30 %, bet apmācību datu kopai – 62,09 %. Atšķirībā no pārklājuma precizitāte, prognozējot ar testa kopu, ir palielinājusies, precizitātes rādītājs ir pieaudzis par 6,21 %.

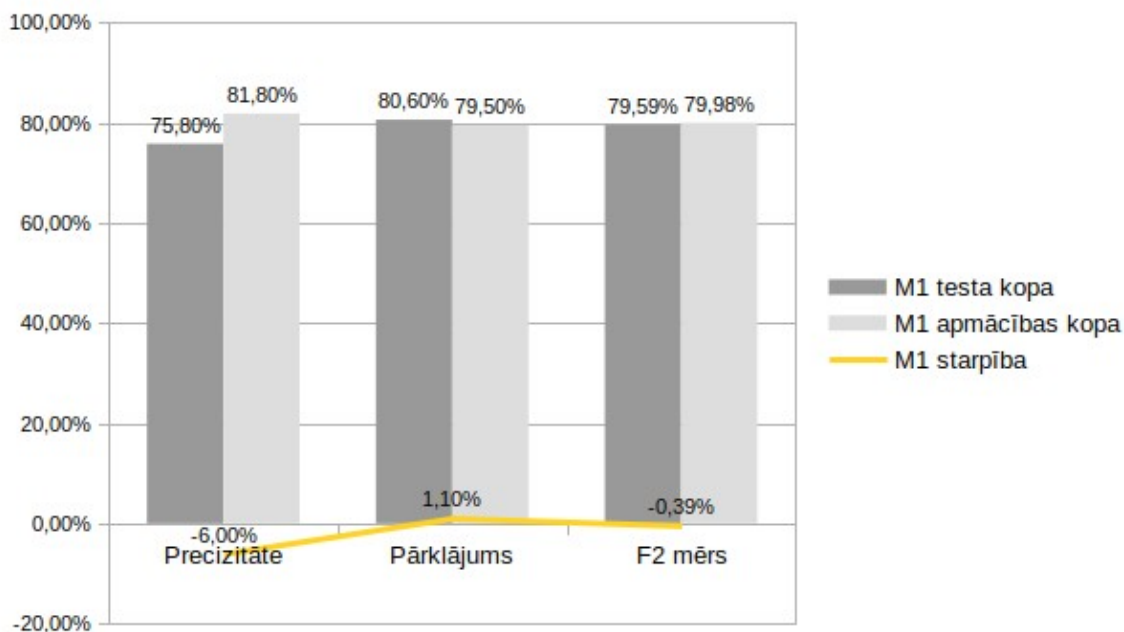


4.16. att. Prognozējošā modeļa novirzes mērījumi ar veikspējas metrikām, ja prognozēšanā izmantota trīs modeļu kombinācija.

M1 un M2 modeļu kombinācijas gadījumā apmācību kopai F2 mērs ir 82,35 %, bet testa kopai – 82,28 % (4.17. att.). M1 un M2 modeļu kombinācijai apmācības kopas pārklājuma vērtība ir 83,45 %, bet testa kopai – 83,87 %. Pārklājums ir pieaudzis testa kopas gadījumā par 0,42 %. M1 un M2 modeļu kombinācijai precizitāte testa kopai ir 76,47 %, bet apmācību kopai precizitāte ir 78,23 %, precizitātes vērtība testa kopai ir samazinājusies par 1,76 %.



4.17. att. Prognozējošā modeļa novirzes mērījumi ar veikspējas metrikām, ja prognozēšanā izmantota divu modeļu kombinācija.



4.18. att. Prognozējošā modeļa novirzes mērījumi ar veikspējas metrikām, ja prognozēšanā izmantots viens modelis.

M1 modeļa gadījumā apmācību kopai F2 mērs ir 79,98 %, bet testa kopai – 79,59 % (4.18. att.). Salīdzinoši F2 mērs ir samazinājies par 0,39 %. Pārklājumiem atšķirība ir šāda: M1 modelim apmācības kopai pārklājums ir 79,50 %, bet testa kopai pārklājuma vērtība ir augstāka – 80,60 %. Pārklājuma vērtība testa kopai ir palielinājusies par 1,10 %. M1 modeļa precizitāte testa kopai ir 75,80 %, bet apmācību kopai precizitāte ir 81,80 %, precizitātes vērtība testa kopai ir samazinājusies par 6,00 %.

Aprēķinātās izmaiņas modeļu veikspējas rādītājiem, atklāj ka veikspējas rādītāju atšķirības ir nelielas. Ar testa datiem iegūti gan augstāki, gan zemāki veikspējas rādītāji, salīdzinot ar apmācības datiem. Kopējais modeļa kvalitātes rādītājs F2 mērs savu vērtību modeļiem ir samazinājis par 0,07 %, 0,39 % vai 1,47 %. Tās ir nelielas un pieļaujamas izmaiņas, kas būtiski neietekmē modeļa rezultātu. Tādējādi var secināt, ka modelis ir

saglabājis savu kvalitāti.

Lai noteiktu, vai modeļa kvalitāte saglabājas, prognozējot ar testa kopu, tika aprēķināts, kā mainās gadījumu skaits, kad visi trīs modeļi prognozē dod vienādu rezultātu. 4.4. tabulā redzams, ka ar testa kopu 72,31 % prognozes sakrīt visiem trīs – M1, M2 un M3 modeļiem, bet ar apmācības kopu prognozes ir vienādas 65,63% gadījumos. Par 6,68 % ir palielinājies vienādi prognozēto gadījumu skaits, un tas liecina, ka e-iekļaušanu prognozējošā modeļa kvalitāte ar testa datu kopu nav samazinājusies.

4.4. tabula

M1, M2 un M3 modeļu prognožu salīdzinājums apmācības un testa kopām.

	Testa kopa	Apmācības kopa
Vienāda prognoze	72,31 %	65,63 %
Atšķirīga prognoze	27,69 %	34,38 %

E-iekļaušanas prognozēšanas prototipa novērtējums

E-iekļaušanu prognozējošā prototipa atbilstība funkcionālajām prasībām dota 4.5. tabulā.

4.5. tabula

E-iekļaušanu prognozējošā prototipa atbilstība funkcionālajām prasībām.

Prasība	Novērtējums
Prognozēt studentus, kuriem ir digitālās atstumtības risks.	Prognozes rezultātu novērtējums apstiprina modeļa veiktspēju, tas ir, spēju prognozēt riska studentus.
Nodrošināt prognozes rezultātu kvalitāti, lai tie saglabātu veiktspējas rādītājus.	Modeļa novirzes novērtējums apstiprina modeļa veiktspējas rādītāju kvalitāti.
Saskarnei jābūt vienkāršai un ērti lietojamai.	Atbilstību pamato tas, ka prototipa saskarne nodrošina instrukcijas, vienkāršu navigāciju starp izvēlnēm (prognozes lapu u. c. lapām) un prognozes vizualizācijā izmantotas krāsas, lai uzsvērtu risku.

Novērtējot prototipa funkcionalitāti, var secināt, ka tā atbilst izvirzītajām prasībām.

4.4. Kopsavilkums un secinājumi par e-iekļaušanu prognozējošo tehnoloģisko modeli un tā novērtējumu

Šajā promocijas darba nodaļā atbilstoši *CRISP-DM* un *CRISP-ML (Q)* metodēm ir atspoguļots prognozējošā algoritmiskā modeļa novērtēšanas posms, ieskaitot modeļa izvietošanas programmatūras prototipā un modeļa pārraudzības posmu. Nodaļā paveiktais:

1) noteiktas e-iekļaušanu prognozējošas sistēmas programmatūras prasības un galvenie darbības principi, izveidojot sistēmas mērķu modeli, lietošanas gadījumu modeli, prezentējot sistēmas darbības pamatprocesus un algoritmus;

2) atbilstoši noteiktajām prasībām izstrādāts un prezentēts e-iekļaušanu prognozējošas sistēmas prototips, skaidrojot prototipā instruktoram pieejamos indivīda prognozes skatus (vispārējo un padziļināto) un citu prototipa funkcionalitāti;

3) novērtēts e-iekļaušanu prognozējošā modeļa veiktspējas rādītāji, modeļa novirze ar

produkcijas datiem un izveidotā prototipa atbilstība izvīzītajai funkcionalitātei.

Galvenie secinājumi ir sekojoši.

1) Izstrādātais sistēmas prototips, kas iekļauj prognozējošo modeli, ļauj prognozēt riska studentus, kam draud digitālā atstumtība.

E-iekļaušanu prognozējošā modeļa pārklājums ir 0,903, tas nozīmē, ka modelis spēj prognozēt kā piederošus riska grupai 90,30 % procentus no visiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanāsursos. Modeļa precizitāte ir 0,683, tas nozīmē, ka reāli 68,3 % no modeļa prognozētajiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem pieder riska grupai.

2) Izstrādātais sistēmas prototips nodrošina, ka instruktoram ir pieejami konkrēta studenta riska faktori, kas ietekmē studenta mācību rezultātu.

Studenta riska faktori ir sekojoši:

- studenta ieinteresētība mācīties;
- studenta spējas mācīties (tiek noteiktas, izmantojot studenta pašvērtējumu zināšanu līmenim pirms un pēc tēmas apguves);
- instruktora vēlme dalīties ar zināšanām;
- e-vides piemērotība;
- e-mācību materiālu piemērotība;

3) Izstrādātais sistēmas prototips, uzrādot studenta riska faktorus, ļauj savlaicīgi instruktoram pieņemt lēmumus, kā organizēt apmācību konkrētam studentam un novērst iespējamus riskus.

4) E-iekļaušanu prognozējošais tehnoloģiskais modelis nodrošina prognozējošā modeļa kvalitātes pārraudzību, izmantojot veikspējas metriku salīdzinājumu.

5) Tā kā modelis prognozē riska grupas studentus un nosaka atbilstošos riska faktorus, tad var secināt, ka modelis izpilda tam paredzētos biznesa mērķus.

6) Tā kā modeļa F2 mēra vērtība ir 0,848, modeļa pārklājums ir 0,903, precizitāte ir 0,683 var secināt, ka veikspējas rādītāji ir atbilstoši zinātniskā literatūrā pieejamajiem prognozējošo modeļu veikspējas rādītājiem.

SECINĀJUMI

Promocijas darbā tika definēts **mērķis** izstrādāt indivīda e-iekļaušanas prognozes modeli e-studiju videi.

Mērķa sasniegšanai tika veikti vairāki **uzdevumi**.

1. Izstrādāts e-iekļaušanu prognozējošs algoritmiskais modelis.
 - 1.1. Veikts pieejamo literatūras un citu avotu izvērtējums e-iekļaušanas procesu jomā.
 - 1.2. Veikts pieejamo literatūras un citu avotu izvērtējums e-iekļaušanas prognozēšanas tehnoloģijām un metodēm.
 - 1.3. Izveidots e-iekļaušanu prognozējošs algoritmiskais modelis.
2. Izveidots e-iekļaušanu prognozējošs tehnoloģiskais modelis (prototips).
3. Novērtēts e-iekļaušanu prognozējošais tehnoloģiskais modeli profesionālās izglītības iestāžu pedagogu e-iekļaušanas pakāpes noteikšanai.

Īstenojot minētos uzdevumus, tika iegūti šādi **teorētiskie rezultāti**:

- izstrādāts teorētiskais pamatojums indivīda e-iekļaušanas prognozējošā modeļa izveidei;
- izveidots indivīda e-iekļaušanu un to ietekmējošo riska faktoros prognozējošs algoritms un modelis;
- izstrādāts e-iekļaušanas tehnoloģiskais modelis indivīda e-iekļaušanas riska prognozei, ņemot vērā indivīdu raksturojošos datus.

Īstenojot noteiktos uzdevumus, tika iegūts šāds **praktiskais rezultāts**:

izstrādāts un novērtēts indivīda e-iekļaušanu prognozējošs modelis, kas dod iespēju to izmantot turpmākiem pētījumiem e-iekļaušanas jomā.

Īstenojot promocijas darba uzdevumus un aprobējot iegūtos rezultātus, ir radušies vairāki **secinājumi**.

- Digitālās prasmes ir būtisks priekšnosacījums indivīda e-iekļaušanai. Uzlabojot indivīdu digitālās prasmes, tiek sekmēta arī citu e-iekļaušanas politikas mērķu sasniegšana. Tomēr fiziska pieejamība tehnoloģijām un digitālo prasmju esamība indivīdam negarantē, ka indivīds šīs tehnoloģijas izmantos. Tikai jēgpilna digitālo prasmju izmantošana liecina par indivīda e-iekļautību.
- E-iekļaušana attiecas uz ikvienu iedzīvotāju, tai skaitā, jauniešiem, topošajiem nodarbinātajiem, cilvēkiem, kuri plāno mainīt nodarbošanos, un izglītības darbiniekiem, kam tehnoloģijas ir nepieciešamas pedagoģiskajā darbībā.
- Mācību analītikas iespējas sekmē digitālo izglītību un indivīda e-iekļaušanas nodrošināšanu digitālo prasmju apguves kontekstā.
- Indivīda e-iekļautību digitālo prasmju apguves kontekstā ietekmē šādi faktori:
 - studenta ieinteresētība mācīties;
 - studenta spējas mācīties;
 - instruktora vēlme dalīties ar zināšanām;
 - e-vides piemērotība;

- e-mācību materiālu piemērotība.
- Individīda e-iekļautību var prognozēt ar lineārās regresijas modeli, klasifikatoru ansambli un, izmantojot klasteranalīzi, grupēt klasteros „e-iekļautie” un „ne e-iekļautie”. E-iekļautības prognozēšanas modeļu apvienošana uzlabo modeļa veiktspējas rādītājus.
- Ja, prognozējot indivīda e-iekļautību, mērķis ir prognozēt aptvert pēc iespējas vairāk riska studentu, tad ir piemērota klasifikatoru ansambļa metode ar vairākuma balsošanas pieeju, kas kombinēta ar lineārās regresijas modeli vai ar klasteranalīzes un lineārās regresijas modeli. Šāds modelis spēj atpazīt 98,40 % no digitāli atstumtajiem, taču tajā pašā laikā tikai 58,20 % no tiem, kas tiek prognozēti kā digitāli atstumti, patiesi ir riska studenti. Testējot prognozējošo modeli e-iekļaušanas tehnoloģiskā modeļa prototipā, modelis kā piederošus riska grupai spēja prognozēt 90,30 % no visiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem, kas apguva digitālās prasmes kombinētās mācīšanāsursos. Modeļa precizitāte bija 68,3 %, tas ir, tik no modeļa prognozētajiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem piederēja riska grupai.
- Ja, prognozējot indivīda e-iekļautību, precizitāte un pārklājums ir vienlīdz svarīgi, tad augstākos veiktspējas rādītājus var iegūt, apvienojot klasifikatoru ansambļa modeli un klasteranalīzes modeli. Šis prognozēšanas modelis atpazīst 82,80 % digitāli atstumto studentu un spēj pareizi prognozēt 79,60 % no tiem studentiem, kas prognozēti kā riska studenti.
- Individīda e-iekļautības pakāpe ietekmē prognozēšanas modeļa pārklājuma un precizitātes vērtības. E-iekļautības pakāpes sliedzīga izmaiņas lineārās regresijas modelī ietekmē pārklājuma un precizitātes vērtības. Jo augstāks e-iekļautības pakāpes sliedzsnis, jo vairāk riska studentu modelis spēs atpazīt. Tajā pašā laikā modelis kļūs neprecīzāks, nosakot riska studentus.
- Izmantojot klasteranalīzes un lineārās regresijas modeli, ir iespējams noteikt konkrēta studenta e-iekļautību ietekmējošos riska faktorus un to vērtības, kas atbilst e-iekļauto indivīdu klasei.
- Ir izveidots indivīda e-iekļautību prognozējošs modelis, kas apmācīts ar datu kopu, kas satur datus no dažādiem digitālo prasmju kursiem. Modeli iespējams izmantot prognozēšanai no apmācības datu kopas atšķirīgiem kursiem.

Iegūtie secinājumi **apstiprina izvirzītās tēzes.**

1. Individīda e-iekļaušanu var prognozēt, izmantojot lineārās regresijas, klasteranalīzi, klasifikatorus un mākslīgā intelekta metodes.

Iegūtie rezultāti rāda, ka e-iekļautības prognozēšanas modeļu, kas veidoti ar lineārās regresijas, klasteranalīzes, klasifikatoru algoritmiem, apvienošana uzlabo modeļa veiktspējas rādītājus.

2. Tehnoloģiski prognozēt e-iekļaušanas pakāpi ļauj šādi faktori: indivīda apmierinātības līmenis ar e-vidi un e-mācību materiāliem, ko indivīds izmanto jaunu digitālo prasmju apguvē; indivīda spēja un ieinteresētība apgūt jaunas digitālās prasmes; instruktora vēlme dalīties ar zināšanām.

Iegūtie rezultāti rāda, ka prognozēšanas modeļiem faktori atšķiras. Lineārās regresijas modelis izmanto šādus faktorus:

- studenta ieinteresētība mācīties;
- studenta spējas mācīties;
- e-vides piemērotība;
- e-mācību materiālu piemērotība.

Lineārās regresijas modeļa korelācijas koeficienti liecina, ka studenta pazīmēm ir atšķirīga ietekme uz prognozi. E-mācību materiāliem un studenta motivācijai ir lielāka ietekme, e-mācību videi un studenta spējai mācīties – mazāka.

Prognozēšanas modelis, kas balstīts klasteranalīzē vai veidots ar klasifikatoru ansambli, izmanto šādus faktoros:

- studenta ieinteresētība mācīties;
- studenta spējas mācīties (tiek noteiktas, izmantojot studenta zināšanu līmeņa pašvērtējumu pirms un pēc tēmas apguves);
- instruktora vēlme dalīties ar zināšanām;
- e-vides piemērotība;
- e-mācību materiālu piemērotība;
- digitālās vispārējās prasmes.

3. Individīda e-iekļaušanu prognozējošais modelis ir lietojams digitālo prasmju apguves laikā e-iekļaušanas pakāpes prognozēšanai profesionālās izglītības pedagogiem Latvijā ar modeļa pārklājumu 90,3 % un F mēra vērtību 84,8 %.

Turpmāko pētījumu iespējamie virzieni:

- Individīda e-iekļaušanas prognozēšanas modeļa pilnveide, prognozei nepieciešamos datus iegūstot no e-studiju sistēmu žurnālfailiem.
- Iespējami ātras prognozes veikšana, balstoties uz indivīda iepriekšējiem mācību rezultātiem digitālo prasmju apguvesursos.
- Individīda e-iekļaušanas prognozēšanas prototipa pilnveide tā robustuma nodrošināšanai.

Promocijas darba pētījuma novitāte, teorētiskais un praktiskais nozīmīgums

1. Izpētīti teorētiskie un praktiskie aspekti e-iekļaušanas prognozēšanas tehnoloģiskā modeļa izstrādei.

2. Izstrādāts e-iekļaušanas tehnoloģiskais modelis indivīda e-iekļaušanas riska prognozei, ņemot vērā indivīdu raksturojošos datus digitālo prasmju apguves procesā.

3. Izstrādāts modelis indivīda e-iekļaušanas prognozēšanai, kas ietver jaunu tehnoloģiju (algoritmu), kura izveidē izmantotas lineārās regresijas, klasteranalīzes, klasificēšanas metodes, lai noteiktu indivīda e-iekļaušanas risku un to ietekmējošos faktoros.

4. Darba rezultāts ir praktiski izmantojams instruktoriem digitālo prasmju apguves kombinētās mācīšanās kursā.

5. Darba rezultāts ir praktiski izmantojams informācijas sistēmu izstrādātājiem e-studiju sistēmu izstrādē, studentu uzvedības analīzes rīku izveidē, mācību analītikas rīku izstrādē.

IZMANTOTĀ LITERATŪRA

1. Abad, L. (2014). Media Literacy for Older People facing the Digital Divide: The e-inclusion Programmes Design. *Comunicar*, 21(42).
2. Abraham, B., & Ledolter, J. (2009). *Statistical methods for forecasting* (Vol. 234). John Wiley & Sons.
3. Abrantes, J. L., Seabra, C., & Lages, L. F. (2007). Pedagogical affect, student interest, and learning performance. *Journal of business research*, 60(9), 960–964.
4. Achituv, N., Raban, Y., & Soffer, T. (2008). D6.1 & D6.2 Policy recommendations for e-inclusion of low socioeconomic status groups (LSG) in e-government services. Retrieved March 10, 2009, from E-government for low socio-economic status groups project website: www.elost.org/D6-2.pdf
5. Aerschot, L. V., & Rodousakis, N. (2008). The link between socio-economic background and Internet use: Barriers faced by low socio-economic status groups and possible solutions. *Innovation: the European journal of social science research*, 21(4), 317–351.
6. AGE Platform Europe (2020). AGE responds to EU consultation on digital education: It is more urgent than ever to reach out to older persons. Retrieved April 7, 2021 from <https://www.age-platform.eu/policy-work/news/age-responds-eu-consultation-digital-education-it-more-urgent-ever-reach-out-older>
7. Agrawal, K. et al, A Comparison of Class Imbalance Techniques for Real-World Landslide Predictions, *2017 International Conference on Machine Learning and Data Science (MLDS)*, Noida, 2017, pp. 1–8.
8. Akhtar, S., Warburton, S., & Xu, W. (2017). The use of an online learning and teaching system for monitoring computer aided design student participation and predicting student success. *International Journal of Technology and Design Education*, 27(2), 251–270.
9. Alamri A. et al. (2019) Predicting MOOCs Dropout Using Only Two Easily Obtainable Features from the First Week's Activities. In: Coy A., Hayashi Y., Chang M. (eds) Intelligent Tutoring Systems. ITS 2019. Lecture Notes in Computer Science, vol 11528. Springer,
10. Ala-Mutka, K. (2011). Mapping Digital Competence: Towards a Conceptual Understanding.
11. Ala-Mutka, K., Malanowski, N., Punie, Y., & Cabrera, M. (2008). Active Ageing and the Potential of ICT for Learning. Institute for Prospective Technological Studies (IPTS) y European Commission. (<http://ftp.jrc.es/EURdoc/JRC45209.pdf>)
12. Altun, D. (2019). Investigating Pre-Service Early Childhood Education Teachers' Technological Pedagogical Content Knowledge (TPACK) Competencies Regarding Digital Literacy Skills and Their Technology Attitudes and Usage. *Journal of Education and Learning*, 8(1), 249–263.
13. Amancio, D. R., Comin, C. H., Casanova, D., Travieso, G., Bruno, O. M., Rodrigues, F. A., & da Fontoura Costa, L. (2014). A systematic comparison of supervised classifiers. *PloS one*, 9(4), e94137.
14. Ambient Assisted Living Joint programme (2014).

<http://www.aal-europe.eu/about/objectives/>

15. Amershi, S., Begel, A., Bird, C., DeLine, R., Gall, H., Kamar, E., ... & Zimmermann, T. (2019, May). Software engineering for machine learning: A case study. In *2019 IEEE/ACM 41st International Conference on Software Engineering: Software Engineering in Practice (ICSE-SEIP)* (pp. 291–300). IEEE.
16. Amy, H. (2011). The Rural Digital Divide: Exploring Differences in the Health Information Seeking Behaviors of Internet Users. *Franklin Business & Law Journal*, (2), 65–77
17. Anderson, D., Sweeney, D., Williams, T., Camm, J., & Cochran, J. (2012). *Quantitative methods for business*. Cengage Learning.
18. Arlot, S., & Celisse, A. (2010). A survey of cross-validation procedures for model selection. *Statistics surveys*, 4, 40–79.
19. Armenta, A., Serrano, A., Cabrera, M., & Conte, R. (2012). The new digital divide: the confluence of broadband penetration, sustainable development, technology adoption and community participation. *Information Technology For Development*, 18(4), 345–353. doi:10.1080/02681102.2011.625925
20. Arnold, K. 2010. Signals: Applying Academic Analytics, <http://www.educause.edu/ero/article/signals-applying-academic-analytics>
21. Ashmore, R., Calinescu, R., & Paterson, C. (2019). Assuring the machine learning lifecycle: Desiderata, methods, and challenges. *arXiv preprint arXiv:1905.04223*.
22. Ashraf, A., Anwer, S., & Khan, M. G. (2018). A Comparative study of predicting student's performance by use of data mining techniques. *American Scientific Research Journal for Engineering, Technology, and Sciences (ASRJETS)*, 44(1), 122–136.
23. Atallah, R., & Al-Mousa, A. (2019, October). Heart Disease Detection Using Machine Learning Majority Voting Ensemble Method. In *2019 2nd International Conference on new Trends in Computing Sciences (ICTCS)* (pp. 1–6). IEEE.
24. Atkeson, C. G., Moore, A. W., & Schaal, S. (1997). Locally weighted learning. *Lazy learning*, 11–73.
25. Azcona, D., Hsiao, I. H., & Smeaton, A. F. (2019). Detecting students-at-risk in computer programming classes with learning analytics from students' digital footprints. *User Modeling and User-Adapted Interaction*, 29(4), 759–788.
26. Baepler, 2010. Baepler, P., Murdoch, C., J. Academic Analytics and Data Mining in Higher Education . *International Journal for the Scholarship of Teaching and Learning*, 4(2), , 2010.
27. Baird, J. E., Zelin II, R. C., & Booker, Q. (2012). Is There a "Digital Divide" in the Provision of E-government Services at the County Level in the United States?. *Journal Of Legal, Ethical & Regulatory Issues*, 15(1), 93–104
28. Baksa-Haskó G., Baranyai B. (2018). Data-Mining Possibilities in Blended Learning. In: Auer M., Guralnick D., Simonics I. (eds) *Teaching and Learning in a Digital World*. ICL 2017. *Advances in Intelligent Systems and Computing*, vol 716.
29. Basili, C. (2013). Information Literacy Policies from the Perspective of the European Commission. In *Worldwide Commonalities and Challenges in Information Literacy Research and Practice* (pp. 61–69). Springer International Publishing.
30. Battista M., T. (2011). *Conceptualizations and Issues Related to Learning*

- Progressions, Learning Trajectories, and Levels of Sophistication, *TME*, 8(3), pp. 507–570
31. Becker, J., Niehaves, B., Bergener B., Räckers, M. (2008). Digital divide in eGovernment: the eInclusion gap model. *EGOV 2008. LNCS 5184*; 2008. p. 231–242.
 32. Beetham, H. (2010). Review and Scoping Study for a cross-JISC Learning and Digital Literacies Programme: Sept 2010. Bristol, JISC.
 33. Bélanger, F., & Carter, L. (2008). Trust and risk in e-government adoption. *The Journal of Strategic Information Systems*, 17(2), 165–176.
 34. Benda, P. P., Havlíček, Z. Z., Lohr, V. V., & Havránek, M. M. (2011). ICT helps to overcome disabilities. *Agris On-Line Papers In Economics & Informatics*, 3(4), 63–69.
 35. Berkowsky, R. W., Sharit, J., & Czaja, S. J. (2017). Factors predicting decisions about technology adoption among older adults. *Innovation in aging*, 1(3), igy002.
 36. Berral, J. L., Goiri, Í., Nou, R., Julià, F., Guitart, J., Gavaldà, R., & Torres, J. (2010, April). Towards energy-aware scheduling in data centers using machine learning. In *Proceedings of the 1st International Conference on energy-Efficient Computing and Networking* (pp. 215–224).
 37. Birzniece, Ilze. Interaktīvas uz induktīvo apmācību balstītas klasifikācijas sistēmas modeļa izstrāde. Promocijas darbs. Rīga: [RTU], 2013. 160 lpp.
 38. Brodersen, K. H., Ong, C. S., Stephan, K. E., & Buhmann, J. M.: The balanced accuracy and its posterior distribution. In: *2010 20th International Conference on Pattern Recognition*, pp. 3121–3124. IEEE, (2010, August).
 39. Brooks, C.A. (2012). Data-Assisted Approach to Supporting Instructional Interventions in Technology Enhanced Learning Environments. PhD Dissertation. University of Saskatchewan, 2012
 40. Bubenko J (1992) On the evolution of information systems modelling—a Scandinavian perspective, SYSLAB Report No. 92-023-DSV, SYSLAB. Department of Systems and Computer Science, Royal Institute of Technology, Kista, Sweden
 41. Bubenko J.A. (2007) From Information Algebra to Enterprise Modelling and Ontologies — a Historical Perspective on Modelling for Information Systems. In: Krogstie J., Opdahl A.L., Brinkkemper S. (eds) *Conceptual Modelling in Information Systems Engineering*. Springer, Berlin, Heidelberg
 42. Bubenko, J. A., jr. Brash, D., & Stirna, J. (1998). EKD userguide. Retrieved March 10, 2009, from enterprise knowledge development website: http://people.dsv.su.se/~js/ekd_user_guide.html
 43. Bubenko, J.A., jr., Persson A., Stirna, J. (2001). D3 appendix B: EKD user guide. Retrieved March 10, 2009, from Enterprise knowledge development website: http://people.dsv.su.se/~js/ekd_user_guide.html
 44. Buraimoh, E., Ajoodha, R., & Padayachee, K. (2021, April). Application of Machine Learning Techniques to the Prediction of Student Success. In *2021 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS)* (pp. 1–6). IEEE.
 45. Burkhard, R. A., & Eppler, M. (2005). Knowledge Visualization. *Knowledge and Information Visualisation*. Springer, Germany.
 46. Cachia, R., Ferrari, A., Ala-Mutka, K., & Punie, Y. (2010). Creative learning and

innovative teaching: Final report on the study on creativity and innovation in education in EU member states. *JRC Working Papers*, (JRC62370).

47. Camposa A.,M., Alvarez-Gonzalez, L., A., Livingstone, D., E. (2012). Effectiveness of Web Pedagogical Scenarios: A Learning Path Data Model, *Inicio*, Vol 3, No 1 (2012), <http://lacllo.org/papers/index.php/lacllo/article/view/21>
48. Caraciolo, M. (2011). Machine Learning with Python - Linear Regression, <http://aimotion.blogspot.com/2011/10/machine-learning-with-python-linear.html>
49. Casacuberta, D. (2007). Digital inclusion: best practices from eLearning. eLearning papers, 6. Retrieved March 15, 2009, from eLearning papers website: <http://www.elearningeuropa.info/files/media/media14197.pdf>
50. CSP. Centrālās statistikas pārvalde. 2014. Profesionālo izglītības iestāžu pedagoģiskie darbinieki (pamatdarbā), <http://data.csb.gov.lv>
51. Chatti, M. A., Lukarov, V., Thüs, H., Muslim, A., Yousef, A. M. F., Wahid, U., ... & Schroeder, U. (2014). Learning analytics: Challenges and future research directions. *eled*, 10(1).
52. Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16, 321–357.
53. Chen, Y., Chen, Q., Zhao, M., Boyer, S., Veeramachaneni, K., & Qu, H. (2016, October). DropoutSeer: Visualizing learning patterns in Massive Open Online Courses for dropout reasoning and prediction. In *Visual Analytics Science and Technology (VAST), 2016 IEEE Conference on* (pp. 111–120). IEEE.
54. Chena, R.-S., Liu, I.-F. (2013). Research on the effectiveness of information technology in reducing the Rural–Urban Knowledge Divide. *Computers & Education*, Volume 63, April 2013, Pages 437–445
55. Choudrie, J., Ghinea, G., & Songonuga, V. (2013). Silver Surfers, E-government and the Digital Divide: An Exploratory Study of UK Local Authority Websites and Older Citizens. *Interacting With Computers*, 25(6), 417–442.
56. Cios K.J., Kurgan L.A., Hybrid Inductive Machine Learning: An Overview of CLIP Algorithms, *In New Learning Paradigms in Soft Computing*. 2002, Physica – Verlag GmbH: Heidelberg, Germany. pp. 276 –321
57. Cluster-Based Prediction of Mathematical Learning Patterns, AIED 2013, LNAI 7926, pp. 389–399, 2013, <http://graphics.ethz.ch/Downloads/Publications/Papers/2013/Kae13b/Kae13b.pdf>
58. Cobos, R., & Olmos, L. (2018, December). A learning analytics tool for predictive modeling of dropout and certificate acquisition on MOOCs for professional learning. In *2018 IEEE international conference on industrial engineering and engineering management (IEEM)* (pp. 1533–1537). IEEE.
59. Cochrane, L. J., Olson, C. A., Murray, S., Dupuis, M., Tooman, T., Hayes, S. (2007). Gaps between knowing and doing: Understanding and assessing the barriers to optimal health care. *Journal of Continuing Education in The Health Professions*. 27(2); 2007. p. 94–102.
60. Codagnone, C., Kluzer, S. (2011). ICT for the Social and Economic Integration of Migrants into Europe JRC Scientific & Technical Report: EUR 24719 EN. <http://ipts.jrc.ec.europa.eu/publications/pub.cfm?id=4019>

61. Colucci, E., Smidt, H., Devaux, A., Vrasidas, C., Safarjalani, M., and Muñoz, C., J. (2017). Free Digital Learning Opportunities for Migrants and Refugees. An Analysis of Current Initiatives and Recommendations for their Further Use; Luxembourg: Publications Office of the European Union, 2017
62. Conijn, R., Snijders, C., Kleingeld, A., & Matzat, U. (2017). Predicting Student Performance from LMS Data: A Comparison of 17 Blended Courses Using Moodle LMS, in *IEEE Transactions on Learning Technologies*, vol. 10, no. 1, pp. 17–29, 1 Jan.–March 2017, doi: 10.1109/TLT.2016.2616312.
63. Coria, S. R., Mondragón-Becerra, R., Pérez-Meza, M., Ramírez-Vásquez, S. K., Martínez-Peláez, R., Barragán-López, D., Ávila-Barrón, O. R. (2013). CT4RDD: Classification trees for research on digital divide. *Expert systems with applications*, 40(14), 5779–5786.
64. Cort, P., Härkönen, A., & Volmari, K. (2004). *PROFF-professionalisation of VET Teachers for the Future* (Vol. 104). Office for Official Publications of the European Communities.
65. Costa, L., Souza, M., Salvador, L., & Amorim, R. (2019, July). Monitoring students performance in e-learning based on learning analytics and learning educational objectives. In *2019 IEEE 19th International Conference on Advanced Learning Technologies (ICALT)* (Vol. 2161, pp. 192-193). IEEE.
66. Cotten, S. R., Hale, T. M., Moroney, M., O'Neal, L., & Borch, C. (2011). USING AFFORDABLE TECHNOLOGY TO DECREASE DIGITAL INEQUALITY. *Information, Communication & Society*, 14(4), 424–444. doi:10.1080/1369118X.2011.559266
67. Creswell, J. W. (2013). *Research design: Qualitative, quantitative, and mixed methods approaches*. Sage.
68. Csordás, A. (2020). Diversifying Effect of Digital Competence. *AGRIS on-line Papers in Economics and Informatics*, 12(665-2020-1220), 3–13.
69. Cullen, J., Hadjivassiliou, K., & Junge, K. (2007). Status of e-inclusion measurement, analysis and approaches for improvement. Retrieved March 15, 2009, from European Commission website: http://ec.europa.eu/information_society/eeurope/i2010/docs/studies/e_inclusion_handbook_0307.pdf
70. Darudiato, S., & Anindito. (2013). Retaining and Increasing Customer Profitability Using K-means and Apriori Algorithm. *Journal Of Theoretical & Applied Information Technology*, 56(1), 118–125.
71. Dasgupta, A., Sun, Y. V., König, I. R., Bailey-Wilson, J. E., & Malley, J. D. (2011). Brief review of regression-based and machine learning methods in genetic epidemiology: the Genetic Analysis Workshop 17 experience. *Genetic epidemiology*, 35(S1), S5–S11.
72. Dearden, A., Lauener, A., Frances, S., Chris R., & Steve C. (2006). Make it so! Jean-Luc Picard, Bart Simpson and the design of E-public services. In *Proceedings of the ninth conference on participatory design: expanding boundaries in design*: Vol. 1.(pp. 67 –76). Retrieved March 15, 2009, from Science direct website: <http://www.sciencedirect.com>
73. De Haan, J. (2004). A multifaceted dynamic model of the digital divide. *It & Society*, 1(7), 66–88.

74. de Hoyos, M., Green, A. E., Barnes, S. A., Behle, H., Baldauf, B., & Owen, D. (2013). Literature Review on Employability, Inclusion and ICT, Report 2.
75. Deepa, S. N., & Devi, B. A. (2011). A survey on artificial intelligence approaches for medical image classification. *Indian Journal of Science & Technology*, 4(11).
76. Dekker, G. W., Pechenizkiy, M., & Vleeshouwers, J. M. (2009). Predicting Students Drop Out: A Case Study. *International Working Group on Educational Data Mining*.
77. Demoussis, M., & Giannakopoulos, N. (2006). Facets of the digital divide in Europe: Determination and extent of internet use. *Economics of Innovation and New Technology*, 15(03), 235–246.
78. Dewan, M. A. A., Lin, F., & Wen, D. (2015, August). Predicting Dropout-Prone Students in E-Learning Education System. In *Ubiquitous Intelligence and Computing and 2015 IEEE 12th Intl Conf on Autonomic and Trusted Computing and 2015 IEEE 15th Intl Conf on Scalable Computing and Communications and Its Associated Workshops (UIC-ATC-ScalCom), 2015 IEEE 12th Intl Conf on* (pp. 1735–1740). IEEE.
79. Dewey, J. Interest and effort in education. Houghton Mifflin. Boston; 1913. p. 102. Retrieved: 12.12.2012, URL: http://openlibrary.org/books/OL7141097M/Interest_and_effort_in_education.
80. DLHLEG (2008). Digital literacy. European Commission working paper and recommendations from digital literacy high-level expert group. Retrieved March 18, 2009, from European Commission website: http://ec.europa.eu/information_society/eeurope/i2010/docs/digital_literacy/digital_literacy_hlg_recommendations.pdf
81. DiMaggio, P., & Bonikowski, B. (2008). Make money surfing the web? The impact of Internet use on the earnings of US workers. *American Sociological Review*, 73(2), 227–250.
82. Diminescu, D., Jacomy, M., and Renault. M. (2010). Study on Social Computing and Immigrants and Ethnic Minorities: Usage Trends and Implications. <http://ipts.jrc.ec.europa.eu/publications/pub.cfm?id=3119>
83. Dimopoulos, I., Petropoulou, O., Boloudakis, M., Retalis, S. (2013). Using Learning Analytics in Moodle for assessing students' performance. *Proceedings of the 2nd Moodle Research Conference (MRC2013)*, pp. 40–46
84. DISC Initiative (2020). The Power of Digitalization in the Age of Physical Distancing: Strengthening social connections and community cohesion through the digital inclusion and connectivity of migrants. DISC Digest 4th Edition, IOM, https://www.iom.int/sites/default/files/documents/disc_digest_4th_edition_digitalization_and_migrant_inclusion_final.pdf
85. Dominguez, A., Hernandez I., & Beltran-Sanchez, J. (2019). High School Students' Perceptions about Biology, Related Influence of Factors and Players, IEEE Integrated STEM Education Conference (ISEC), 2019, pp. 392-397, doi: 10.1109/ISECon.2019.8882025.
86. Drabowicz, T. (2014). Gender and digital usage inequality among adolescents: A comparative study of 39 countries. *Computers & Education*, 98–111. doi:10.1016/j.compedu.2014.01.016
87. Driessen, M., van Emmerik, J., Fuhri, K., Nygren-Junkin, L., Spotti, M. (2011). ICT Use in L2 Education for Adult Migrants - A qualitative study in the Netherlands and

- Sweden. Technical Note: JRC59774, <http://ipts.jrc.ec.europa.eu/publications/pub.cfm?id=4539>
88. Dyckhoff, A., Zielke, D., Bültmann, M., Chatti, M., & Schroeder, U. (2012). Design and Implementation of a Learning Analytics Toolkit for Teachers. *Journal Of Educational Technology & Society*, 15(3), 58–76.
 89. ECAR-ANALYTICS Working Group. The Predictive Learning Analytics Revolution: Leveraging Learning Data for Student Success. ECAR working group paper. Louisville, CO: ECAR, October 7, 2015.
 90. ECDL Foundation (2007). Survey on e-inclusion policy evaluation. Retrieved March 18, 2009, from ECDL website: <http://www.ecdl.com/publisher/index.jsp?p=781&n=789>
 91. Efrati, V., Limongelli, C., & Sciarrone, F. (2014). A Data Mining Approach to the Analysis of Students' Learning Styles in an e-Learning Community: A Case Study. In *Universal Access in Human-Computer Interaction. Universal Access to Information and Knowledge* (pp. 289–300). Springer International Publishing.
 92. Eiropas Komisija (2014). Documents 2013. Data tables. <http://ec.europa.eu/digital-agenda/en/fast-and-ultra-fast-internet-access-analysis-and-data>
 93. Eiropas Komisija. (2014a). Scoreboard. <http://ec.europa.eu/digital-agenda/en/scoreboard>
 94. Eiropas Padome (2006). Eiropas Parlamenta un Padomes Ieteikums (2006. gada 18. decembris) par pamatprasmēm mūžizglītībā, OV L 394, 30.12.2006., 10.–18. lpp.
 95. Eiropas Padome (2018). Padomes Ieteikums (2018. gada 22. maijs) par pamatkompetencēm mūžizglītībā, OV C 189, 04.06.2018., 1.–13. lpp.
 96. Eiropas Parlamenta un Padomes ieteikums (2006. gada 18. decembris) par pamatprasmēm mūžizglītībā, (2006/962/EK). Skatīts 15.04.2021. Pieejams: <https://eur-lex.europa.eu/legal-content/LV/TXT/HTML/?uri=CELEX:32006H0962&from=LV>
 97. Eiropas Revīzijas palāta (2021). ES rīcība nolūkā palielināt digitālās prasmes.
 98. Ekubo, E. A. (2020). Predictive system for characterizing low performance of Undergraduate students using machine learning techniques (Doctoral dissertation, North-West University (South Africa)).
 99. Englert, P. Locally weighted learning. In: *Seminar Class on Autonomous Learning Systems*. (2012).
 100. Eppler, M. J., & Burkhard, R. A. (2004). *Knowledge visualization: towards a new discipline and its fields of application*. Università della Svizzera italiana.
 101. Erguven, M., "Comparison of the efficiency of principal component analysis and multiple linear regression to determine students' academic achievement," *Application of Information and Communication Technologies (AICT)*, 2012 6th International Conference on , vol., no., pp.1,5, 17–19 Oct. 2012, doi: 10.1109/ICAICT.2012.6398537
 102. Erstad, O. (2010). Educating the Digital Generation. *Nordic Journal of Digital Literacy*, 1, 56–70.
 103. European Commission (2006). Riga Ministerial Declaration on e-inclusion. Riga: European Commission. Retrieved April 7, 2021 from https://ec.europa.eu/information_society/activities/ict_psp/documents/

[declaration_riga.pdf](#)

104. European Commission (2010). A Digital Agenda for Europe: European Commission. Retrieved April 7, 2021 from
105. European Commission. (2012). Digital Agenda Scoreboard 2011, Pillar 6: Digital Competence in the Digital Agenda <https://ec.europa.eu/digital-agenda/sites/digital-agenda/files/digitalliteracy.pdf>
106. European Commission. (2013). Survey of schools: ICT in Education. <https://ec.europa.eu/digital-agenda/sites/digital-agenda/files/KK-31-13-401-EN-N.pdf>
107. European Commission. (2013a). Communication from the Commission to the European Parliament, the Council, the European Economic and Social Committee and the Committee of the Regions, Opening up Education: Innovative teaching and learning for all through new Technologies and Open Educational Resources, <http://eur-lex.europa.eu/legal-content/EN/TXT/?qid=1389115469384&uri=CELEX:52013DC0654>
108. European Commission (2014). Eurostat. <https://ec.europa.eu/eurostat>
109. European Commission (2017). Eurostat. <https://ec.europa.eu/eurostat>
110. European Commission (2018). Digital Education Action Plan (2018–2020): European Commission. Retrieved April 7, 2021 from <https://eur-lex.europa.eu/legal-content/LV/TXT/PDF/?uri=CELEX:52018DC0022&from=EN>
111. European Commission. (2018a). Keynote speech by Commissioner Mariya Gabriel on 2nd Regional Digital Summit: Towards the competitive and future proof digital Europe, https://ec.europa.eu/commission/commissioners/2014–2019/gabriel/announcements/keynote-speech-commissioner-mariya-gabriel-2nd-regional-digital-summit-towards-competitive-and_en
112. *European Commission/EACEA/Eurydice, 2019. Digitālā izglītība Eiropas skolās. Eurydice ziņojums. Luksemburga: Eiropas Savienības Publikāciju birojs.* https://www.viaa.gov.lv/library/files/original/Eurydice_Digital_education_Report_LV.pdf
113. European Commission (2020). Europe Fit Digital Age: European Commission. Retrieved April 7, 2021 from https://ec.europa.eu/info/strategy/priorities-2019-2024/europe-fit-digital-age/shaping-europe-digital-future_en
114. European Commission (2020a). Report on the impact of demographic change: European Commission. Retrieved April 7, 2021 from <https://eur-lex.europa.eu/legal-content/LV/TXT/?uri=CELEX%3A52020DC0241>
115. European Commission (2020b). Digital Education Action Plan (2021-2027): European Commission. Retrieved April 7, 2021 from https://ec.europa.eu/education/education-in-the-eu/digital-education-action-plan_lv
116. European Commission (2020c). Eurostat. <https://ec.europa.eu/eurostat>
117. European Commission (2021). 2030 Digital Compass: the European way for the Digital Decade: European Commission. Retrieved April 7, 2021 from <https://eur-lex.europa.eu/legal-content/en/TXT/?uri=CELEX%3A52021DC0118>
118. European Commission (2021a). Green paper on ageing. Fostering solidarity and responsibility between generations . Retrieved April 7, 2021 from https://ec.europa.eu/info/sites/info/files/1_en_act_part1_v8_0.pdf

119. European Commission (2021b). Eurostat. <https://ec.europa.eu/eurostat>
120. European Parliament and Council. (2006). Recommendation 2006/962/EC of the European Parliament and of the Council of 18 December 2006 on key competences for lifelong learning [Official Journal L 394 of 30.12.2006].
121. Farbeh-Tabrizi, K. (2012). Effective Computer Training for People with Disability. *Journal Of Applied Computing & Information Technology*, 16(1), 1–5.
122. Ferguson, R., Brasher, A., Clow, D., Cooper, A., Hillaire, G., Mittelmeier, J., Rienties, B., Ullmann, T., Vuorikari, R. (2016). Research Evidence on the Use of Learning Analytics – Implications for Education Policy. R. Vuorikari, J. Castaño Muñoz(Eds.). Joint Research Centre Science for Policy Report; EUR 28294 EN; doi:10.2791/955210.
123. Fernández-Delgado, M., Cernadas, E., Barro, S., & Amorim, D. (2014). Do we need hundreds of classifiers to solve real world classification problems?. *The journal of machine learning research*, 15(1), 3133–3181.
124. Ferrari, A. (2012). Digital Competence in practice: An analysis of frameworks. Institute for Prospective Technological Studies. Available at: <http://ipts.jrc.ec.europa.eu/publications/pub.Cfm>.
125. Ferrari, A. (2013): *DIGCOMP: A Framework for Developing and Understanding Digital Competence in Europe*. EC JRC IPTS, Seville, Spain. (<http://ftp.jrc.es/EURdoc/JRC83167.pdf>)
126. Fortenbacher, A.; Beuster, L.; Elkina, M.; Kappe, L.; Merceron, A.; Pursian, A.; Schwarzrock, S.; Wenzlaff, B., "LeMo: A learning analytics application focussing on user path analysis and interactive visualization," *Intelligent Data Acquisition and Advanced Computing Systems (IDAACS)*, 2013 IEEE 7th International Conference on , vol.02, no., pp.748,753, 12–14 Sept. 2013
127. Frank, E., Hall, M., Holmes, G., Kirkby, R., Pfahringer, B., Witten, I. H., & Trigg, L. (2009). Weka-a machine learning workbench for data mining. In *Data mining and knowledge discovery handbook* (pp. 1269–1277). Springer, Boston, MA.
128. Freedman, R. (2000). What is an intelligent tutoring system? *Intelligence*, 11(3), 15–16.
129. FreshMinds, & UK Online Centres. (2007). Digital inclusion. A discussion of the evidencebase. Retrieved October 31, 2015, from <http://www.tinderfoundation.org>
130. FreshMinds, & UK Online Centres. (2008). Economic benefits of digital inclusion: building the evidence. Retrieved October 31, 2015, from <http://www.tinderfoundation.org>
131. Fu, J.-H.; Chang, J.-H.; Huang, J.-M.; Chao, H.-C. "A Support Vector Regression-Based Prediction of Students' School Performance," *Computer, Consumer and Control (IS3C)*, 2012 International Symposium on , vol., no., pp. 84,87, 4–6 June 2012
132. Future Learn. Using Open Data for Digital Business, 2020 <https://www.futurelearn.com/courses/open-data-business/4/steps/659724>
133. Galván, I. M., Valls, J. M., García, M., & Isasi, P. (2011). A lazy learning approach for building classification models. *International journal of intelligent systems*, 26(8), 773–786.
134. Ganganwar, V. (2012). An overview of classification algorithms for imbalanced datasets. *International Journal of Emerging Technology and Advanced Engineering*,

2(4), 42–47.

135. Geiger, B., Evans, R. R., Cellitti, M. A., Smith, K., O'Neal, M. R., Firsing, S., & Chandan, P. P. (2011). The Healthy Web-Access to Online Health Information for Individuals with Disabilities. *International Electronic Journal Of Health Education*, 1493–100.
136. Gitinabard, N., Xu, Y., Heckman, S., Barnes, T. and Lynch, C. F. (2019). How Widely Can Prediction Models Be Generalized? Performance Prediction in Blended Courses, in *IEEE Transactions on Learning Technologies*, vol. 12, no. 2, pp. 184–197, 1 April-June 2019, doi: 10.1109/TLT.2019.2911832.
137. Greene J.A., Yu, S.B, Copeland, D. Z. 2014. Measuring critical components of digital literacy and their relationships with learning Original Research Article. *Computers & Education*, Volume 76, July 2014, Pages 55–69
138. Gryczka, M. (2011). The Effects of Delays in the Dissemination and Usage of Broadband Internet. *Folia Oeconomica Stetinensia*, 10(2), 186–201. doi:10.2478/v10031-011-0011-4
139. Gudmundsdottir, G. B., & Vasbø, K. B. (2017, March). Toward improved professional digital competence: The use of blended learning in teacher education in Norway. In *Society for Information Technology & Teacher Education International Conference* (pp. 499–509). Association for the Advancement of Computing in Education (AACE).
140. Guerrieri, P., & Bentivegna, S. (Eds.). (2011). *The economic impact of digital technologies: Measuring inclusion and diffusion in Europe*. Edward Elgar Publishing.
141. Guillén-Gámez, F. D., Mayorga-Fernández, M. J., Bravo-Agapito, J., & Escribano-Ortiz, D. (2020a). Analysis of teachers' pedagogical digital competence: Identification of factors predicting their acquisition. *Technology, Knowledge and Learning*, 1–18.
142. Guillen-Gamez, F. D., Mayorga-Fernández, M. J., & Del Moral, M. T. (2020). Comparative research in the digital competence of the pre-service education teacher: face-to-face vs blended education and gender. *Journal of e-Learning and Knowledge Society*, 16(3), 1–9.
143. Gujarati, A., Gopalakrishnan, S., & Pattabiraman, K. (2020, October). New Wine in an Old Bottle: N-Version Programming for Machine Learning Components. In *2020 IEEE International Symposium on Software Reliability Engineering Workshops (ISSREW)* (pp. 283–286). IEEE.
144. Gurstein, M. (2003). Effective use: A community informatics strategy beyond the digital divide. *First Monday*.
145. Haddon, L. (2004). Information and communication technologies in everyday life: A concise introduction and research guide (pp. 62-63). Oxford: Berg.
146. Haight, M., Quan-Haase, A., & Corbett, B. (2014). Revisiting the digital divide in Canada: the impact of demographic factors on access to the internet, level of online activity, and social networking site usage. *Information, Communication & Society*, 17(4), 503–519. doi:10.1080/1369118X.2014.891633
147. Haixiang, G., Yijing, L., Shang, J., Mingyun, G., Yuanyue, H., & Bing, G. (2017). Learning from class-imbalanced data: Review of methods and applications. *Expert Systems with Applications*, 73, 220–239.
148. Halkidi, M., Batistakis, Y., & Vazirgiannis, M. (2001). On clustering validation

- techniques. *Journal of Intelligent Information Systems*, 17(2-3), 107–145.
149. Hamerly, G., & Elkan, C. (2003). Learning the k in k-means. In *NIPS* (Vol. 3, pp. 281–288).
 150. Hammoud, D., & Sahnoun, Z. (2009). Suitable machine learning methods for agent-based systems. In *Proceedings of the International Conference on Electronic, Technologies of Information and Telecommunication*, March (pp. 22–26).
 151. Hammoud, D., Maamri, R., & Sahnoun, Z. (2011). Machine Learning in an Agent: A Generic Model and an Intelligent Agent based on Inductive Decision Learning. *Journal of Artificial Intelligence*, 4(1).
 152. Han, H., Wang, W. Y., & Mao, B. H. (2005, August). Borderline-SMOTE: a new over-sampling method in imbalanced data sets learning. In *International conference on intelligent computing* (pp. 878–887). Springer, Berlin, Heidelberg.
 153. Hargittai, E. (2010). Digital natives? Variation in internet skills and uses among members of the “net generation”. *Sociological inquiry*, 80(1), 92–113.
 154. Hargittai, E., & Hinnant, A. (2008). Digital Inequality: Differences in Young Adults' Use of the Internet. *Communication Research*, 35(5), 602–621
 155. Haseeb, A. & Mohd, S., Rd, S., Kashif, H., Muhammad, M. (2019). Imbalance class problems in data mining: A review. *Indonesian Journal of Electrical Engineering and Computer Science*. 14. 10.11591/ijeecs.v14.i3.pp. 1552–1563.
 156. Hatlevik, O. E., Guðmundsdóttir, G. B., & Loi, M. (2015). Examining factors predicting students' digital competence. *Journal of Information Technology Education: Research*, 14(14), 123–137.
 157. Hatlevik, O. E., Ottestad, G., & Throndsen, I. (2015). Predictors of digital competence in 7th grade: a multilevel analysis. *Journal of Computer Assisted Learning*, 31(3), 220–231.
 158. Hawkins, D. M. (2004). The problem of overfitting. *Journal of chemical information and computer sciences*, 44(1), 1–12.
 159. Helmane, I. (2019). Platjoslas internets reģionos nodrošināts, pakalpojumu saņēmēju – maz. Latvijas Vēstnesis. 2019. Retrieved April 7, 2021 from <https://lvportals.lv/norises/302919-platjoslas-internets-regionos-nodrosinats-pakalpojumu-sanemeju-maz-2019>
 160. Herodotou, C., Hlosta, M., Boroowa, A., Rienties, B., Zdrahal, Z., & Mangafa, C. (2019). Empowering online teachers through predictive learning analytics. *British Journal of Educational Technology*, 50(6), 3064–3079.
 161. Herrera, F. A. S., Crespo, R. G., Baena, L. R., & Burgos, D. (2019). A solution to manage the full life cycle of learning analytics in a learning management system: Analytic. *IEEE Revista Iberoamericana de Tecnologías del Aprendizaje*, 14(4), 127–134.
 162. Herrmannova, A. W. Z. Z. D., & Hlosta, J. K. M. 2014. Developing predictive models for early detection of at-risk students on distance learning modules.
 163. Herrnson, P. S., Stokes-Brown, A. K., & Hindman, M. (2007). Campaign Politics and the Digital Divide Constituency Characteristics, Strategic Considerations, and Candidate Internet Use in State Legislative Elections. *Political Research Quarterly*, 60(1), 31–42.

164. Hidalgo, A., Gabaly, S., Morales-Alonso, G., & Urueña, A. (2020). The digital divide in light of sustainable development: An approach through advanced machine learning techniques. *Technological Forecasting and Social Change*, 150, 119754.
165. Hilbert, M. (2010). When is cheap, cheap enough to bridge the digital divide? Modeling income related structural challenges of technology diffusion in Latin America. *World Development*, 38(5), 756–770.
166. Hilbert, M. (2011). Digital gender divide or technologically empowered women in developing countries? A typical case of lies, damned lies, and statistics. *In Women's Studies International Forum* (Vol. 34, No. 6, pp. 479–489). Pergamon.
167. Holte, R.C.: Very simple classification rules perform well on most commonly used datasets. *In: Machine Learning*, 11:63–91, (1993).
168. Hsieh, J., Rai, A., & Keil, M. (2008). Understanding digital inequality: Comparing continued use behavioral models of the socio-economically advantaged and disadvantaged. *MIS quarterly*, 97–126
169. Huang, S., & Fang, N. (2013). Predicting Student Academic Performance in an Engineering Dynamics Course: A Comparison of Four Types of Predictive Mathematical Models. *Computers & Education*, 61, 133–145.
170. Huđek, I., Širec, K., & Tominc, P. (2019). Digital Skills in Enterprises According to the European Digital Entrepreneurship Sub-Indices: Cross-Country Empirical Evidence. *Management: Journal of Contemporary Management Issues*, 24(2), 107–119.
171. Hung, J. L., Shelton, B. E., Yang, J., & Du, X. (2019). Improving predictive modeling for at-risk student identification: a multistage approach. *IEEE Transactions on Learning Technologies*, 12(2), 148–157.
172. Instefjord, E. J., & Munthe, E. (2017). Educating digitally competent teachers: A study of integration of professional digital competence in teacher education. *Teaching and teacher education*, 67, 37–45.
173. Ilic, M., Spalevic, P., Veinovic, M., & Alatresh, W. S. (2016). Students' success prediction using Weka tool. *Infoteh-Jahorina*, 15, 684–688.
174. ITU. (2006). World Telecommunication/ICT Development Report 2006: Measuring ICT for social and economic development, <https://www.itu.int/pub/D-IND-WTDR-2006>
175. Izglītības un zinātnes ministrija. (2006). Informācijas un komunikācijas tehnoloģijas izglītības kvalitātei” Programma 2007. – 2013. gadam, polsis.mk.gov.lv/LoadAtt/file44587.doc
176. IZM (Izglītības un zinātnes ministrija). (2014). Izglītības attīstības pamatnostādnes 2014.–2020.gadam, <http://www.mk.gov.lv/lv/mk/tap/?pid=40305684>
177. Izglītības un zinātnes ministrija. (2014). Reģistri un statistika: statistika par profesionālo izglītību, <http://izm.izm.gov.lv/registri-statistika/statistika-profesionala/8597.html>
178. IZM (2021). Digitālās prasības uzlabošanā svarīgi ieguldīt līdzekļus vismaz trīs virzienos <https://www.izm.gov.lv/lv/jaunums/isuplinska-digitalas-pratibas-uzlabosanai-svarigi-ieguldit-lidzeklus-vismaz-tris-virzienos>.
179. IZM (2021a). I.Šuplinska: digitālās prasības uzlabošanai svarīgi ieguldīt līdzekļus vismaz trīs virzienos: Izglītības un zinātnes ministrija. Retrieved April 15, 2021 from

<https://www.izm.gov.lv/lv/jaunums/isuplinska-digitalas-pratibas-uzlabosana-svarigi-ieguldit-lidzeklus-vismaz-tris-virzienos>

180. Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern Recognition Letters*, 31(8), 651–666.
181. James, J. (2008). The digital divide across all citizens of the world: A new concept. *Social Indicators Research*, 89(2), 275–282.
182. James, J. (2011). Are Changes in the Digital Divide Consistent with Global Equality or Inequality?. *Information Society*, 27(2), 121–128. doi:10.1080/01972243.2011.548705
183. Jenkins, H. (2009). *Confronting the challenges of participatory culture: Media education for the 21st century*. MIT Press.
184. Jerrim, J., & Sims, S. (2019). *The Teaching and Learning International Survey (TALIS) 2018: June 2019*.
185. Johansson, L., & Tjäder, C. (2013). IT-Support Direct from Project to a National Service. *Assistive Technology: From Research to Practice: AAATE 2013*, 33, 399.
186. John, G.H., Langley, P. Estimating continuous distributions in Bayesian classifiers. In: Eleventh Conference on Uncertainty in Artificial Intelligence, San Mateo, 338–345, (1995).
187. Jung, Y., Peng, W., Moran, M., Jin, S., McLaughlin, M., Cody, M., & ... Silverstein, M. (2010). Low-Income Minority Seniors' Enrollment in a Cybercafe: Psychological Barriers to Crossing the Digital Divide. *Educational Gerontology*, 36(3), 193–212. doi:10.1080/03601270903183313
188. Kaaser, T., Busetto, A., G., Solenthaler, B., Kohn, J., Aster, M. von, and Gross, M., Kang, S.-J., Kim Y., B., Park, T., Kim, C.-H., (2012). Automatic player behavior analysis system using trajectory data in a massive multiplayer online game, *Multimed Tools Appl*, http://kucg.korea.ac.kr/publication/papers/inter_journal_2012_02.pdf
189. Kapenieks, A., Zuga, B., Vitolina, I., Kapenieks Jr, J., Gorbunovs, A., Jirgensons, M., ... & Balode, A. (2014, April). Piloting the eBig3. In *Proceedings of the 6th International Conference on Computer Supported Education-Volume 1* (pp. 325–329).
190. Kaplan, R. S., & Norton, D. P. (2004). The strategy map: guide to aligning intangible assets. *Strategy & leadership*.
191. Khalil Moghaddam, B., & Khatoon-Abadi, A. (2013). Factors affecting ICT adoption among rural users: A case study of ICT Center in Iran. *Telecommunications Policy*, 37(11), 1083–1094.
192. Klüsener, M., & Fortenbacher, A. (2015, September). Predicting students' success based on forum activities in MOOCs. In *Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS), 2015 IEEE 8th International Conference on* (Vol. 2, pp. 925–928). IEEE.
193. Kotsiantis, S., Patriarcheas, K., & Xenos, M. (2010). A combinational incremental ensemble of classifiers as a technique for predicting students' performance in distance education. *Knowledge-Based Systems*, 23(6), 529–535.
194. Kyung Hoon, Y., Sei Kwon, P., Seong No, Y., & Jaekyung, K. (2010). Measurement of the digital inequality in remote rural areas: case of South Korea. *International Journal Of Information Technology & Management*, 9(2), 142–161. doi:10.1504/IJITM.2010.030458

195. Klassen, R. D., & Flores, B. E. (2001). Forecasting practices of Canadian firms: Survey results and comparisons. *International Journal of Production Economics*, 70(2), 163–174.
196. Kluzer, S., Ferrari, A., Centeno, C. (2011). Language Learning by Adult Migrants: Policy Challenges and ICT Responses. Technical Note: JRC63889,5/2011, <http://ipts.jrc.ec.europa.eu/publications/pub.cfm?id=4159>
197. Kluzer, S., & Rissola, G. (2009). E-inclusion policies and initiatives in support of employability of migrants and ethnic minorities in Europe. *Information technologies & International Development*, 5(2), pp–67.
198. Knight, A.T. u. c. Knowing but not doing: selecting priority conservation areas and the research–implementation gap. *Conservation Biology*. Vol. 22(3); 2008. p. 610–617
199. Komarasamy, G. G., & Wahi, A. (2013). A New Algorithm for Selection of Better K Value Using Modified Hill Climbing in K-means Algorithm. *Journal Of Theoretical & Applied Information Technology*, 55(3), 307–314.
200. Korņijenko, J. 2007. Klasifikācijas likumu automātiskās ģenerācijas metožu izstrāde un izpēte.
201. Krastiņš, O. 1998. Statistika un ekonometrija: Mācību grāmata augstskolām. Rīga, Latvijas Republikas Centrālā statistikas pārvalde, 1988.
202. Kreijns, K., Vermeulen, M., Van Acker, F., & Van Buuren, H. (2014). Predicting teachers' use of digital learning materials: combining self-determination theory and the integrative model of behaviour prediction. *European Journal of Teacher Education*, 37(4), 465–478.
203. Kuhn, M., & Johnson, K. (2013). *Applied predictive modeling* (Vol. 26). New York: Springer.
204. Kumari, P., Jain, P. K., and Pamula, R. (2018). An efficient use of ensemble methods to predict students academic performance, *2018 4th International Conference on Recent Advances in Information Technology (RAIT)*, Dhanbad, 2018, pp. 1–6, doi: 10.1109/RAIT.2018.8389056.
205. Kwok-Kee, W., Hock-Hai, T., Hock Chuan, C., & Tan, B. Y. (2011). Conceptualizing and Testing a Social Cognitive Model of the Digital Divide. *Information Systems Research*, 22(1), 170–187. doi:10.1287/isre.1090.0273
206. LAK. 1st International Conference on Learning Analytics , 2011, <https://tekri.athabascau.ca/analytics/>
207. Lan, Y., Soh, Y. C., & Huang, G. B. (2010). Constructive hidden nodes selection of extreme learning machine for regression. *Neurocomputing*, 73(16), 3191–3199.
208. Landwehr, N., Hall, M., Frank, E.: Logistic model trees. In: *Machine Learning*. 95(1–2):161–205. (2005).
209. Latvia e-inclusion report (2008). Retrieved March 10, 2009, from EU ePractice website: http://www.epractice.eu/files/Latvia_e-Inclusion%202008.pdf
210. Latvijas Nacionālais terminoloģijas portāls (2021)., <https://termini.gov.lv/>
211. Lankhorst, M. M., Proper, H. A., & Jonkers, H. (2009). The architecture of the archimate language. In *Enterprise, Business-Process and Information Systems Modeling* (pp. 367–380). Springer, Berlin, Heidelberg.
212. Learnnovators. 2014. Top 9 e-Learning Predictions for 2014,

<http://learnnovators.com/top-9-e-learning-predictions-2014/>

213. Lenar, G., Jamila, M., Egor, P., & Rustem, V. (2019, October). Application of Learning Analytics Tools in Learning Management Systems. In *2019 12th International Conference on Developments in eSystems Engineering (DeSE)* (pp. 221–224). IEEE.
214. Leonardi, B.; Ajjarapu, V.; Djukanovic, M.; Pei Zhang, "Application of multi-linear regression models and machine learning techniques for online voltage stability margin estimation," *Bulk Power System Dynamics and Control (iREP) - VIII (iREP)*, 2010 iREP Symposium, vol., no., pp.1,10, 1–6 Aug. 2010 doi: 10.1109/IREP.2010.5563288
215. Lerchner, A., La Camera, G., & Richmond, B. (2007). Knowing without doing. *Nature neuroscience*, *10*(1), 15–17.
216. Li, Y., & Ranieri, M. (2013). Educational and Social Correlates of the Digital Divide for Rural and Urban Children: A Study on Primary School Students in a Provincial City of China. *Computers & Education*, *60*(1), 197–209.
217. Li, Q., & Chen, Y. L. (2009). Data flow diagram. In *Modeling and Analysis of Enterprise and Information Systems* (pp. 85–97). Springer, Berlin, Heidelberg.
218. Lichy, J. (2011). Internet user behaviour in France and Britain: exploring socio-spatial disparity among adolescents. *International Journal Of Consumer Studies*, *35*(4), 470–475. doi:10.1111/j.1470–6431.2010.00955.x
219. Lillehagen, F., & Krogstie, J. (2008). *Active knowledge modeling of enterprises*. Springer Science & Business Media.
220. Lin, C. I., Tang, W. H., & Kuo, F. Y. (2012). “Mommy Wants to Learn the Computer” How Middle-Aged and Elderly Women in Taiwan Learn ICT Through Social Support. *Adult Education Quarterly*, *62*(1), 73–90.
221. Ling C. X., Sheng V. S. (2011) Class Imbalance Problem. In: Sammut C., Webb G.I. (eds) *Encyclopedia of Machine Learning*. Springer, Boston, MA
222. Livingstone, S., & Helsper, E. (2007). Gradations in digital inclusion: Children, young people and the digital divide. *New media & society*, *9*(4), 671–696.
223. LR Izglītības un zinātnes ministrija (2021). DigComp 2.1: iedzīvotāju digitālo kompetenču ietvars. Ar astoņiem apguves līmeņiem un lietošanas piemēriem, e-publikācija: LR Izglītības un zinātnes ministrija.
224. Lu, J., Liu, A., Dong, F., Gu, F., Gama J., and Zhang, G. (2019). Learning under Concept Drift: A Review, in *IEEE Transactions on Knowledge and Data Engineering*, vol. 31, no. 12, pp. 2346–2363, 1 Dec. 2019, doi: 10.1109/TKDE.2018.2876857.
225. Lucas, M., Bem-Haja, P., Siddiq, F., Moreira, A., & Redecker, C. (2021). The relation between in-service teachers' digital competence and personal and contextual factors: What matters most?. *Computers & Education*, *160*, 104052.
226. Luo, Y., Chen, N., & Han, X. (2020, December). Students' Online Behavior Patterns Impact on Final Grades Prediction in Blended Courses. In *2020 Ninth International Conference of Educational Innovation through Technology (EITT)* (pp. 154–158). IEEE.
227. Lupiañez, F., Codagnone, C., Dalet, R. (2015). *ICT for the Employability and Integration of Immigrants in the European Union. Results from a Survey in Three Member States*, Luxembourg: Publications Office of the European Union, 2015–237pp.

228. Lykourantzou, I., Giannoukos, I., Nikolopoulos, V., Mpardis, G., & Loumos, V. (2009). Dropout prediction in e-learning courses through the combination of machine learning techniques. *Computers & Education*, 53(3), 950–965.
229. Machida, F. (2019, June). N-version machine learning models for safety critical systems. In *2019 49th Annual IEEE/IFIP International Conference on Dependable Systems and Networks Workshops (DSN-W)* (pp. 48–51). IEEE.
230. Machine Learning and Learning Analytics Workshop. 2014. Learning Analytics & Machine Learning, <http://machineanalytics.org/>
231. Maennel, K. (2020, September). Learning Analytics Perspective: Evidencing Learning from Digital Datasets in Cybersecurity Exercises. In *2020 IEEE European Symposium on Security and Privacy Workshops (EuroS&PW)* (pp. 27–36). IEEE.
232. Mahboob, T., Irfan, S., & Karamat, A. (2016, December). A machine learning approach for student assessment in E-learning using Quinlan's C4. 5, Naive Bayes and Random Forest algorithms. In *Multi-Topic Conference (INMIC), 2016 19th International* (pp. 1–8). IEEE.
233. Mariën, I., & Van Audenhove, L. (2010, September). Embedding e-inclusion initiatives in people's daily reality: The role of social networks in tackling the digital divide. In *Digitas Conference'Digital Natives, Digital Immigrants, Digital Asylum seekers: The clash of cultures*.
234. Márquez-Vera, C., Cano, A., Romero, C., & Ventura, S. (2013). Predicting student failure at school using genetic programming and different data mining approaches with high dimensional and imbalanced data. *Applied intelligence*, 38(3), 315–330.
235. Martínez-Alcalá, C. I., Rosales-Lagarde, A., Alonso-Lavernia, M. D. L. Á., Ramírez-Salvador, J. Á., Jiménez-Rodríguez, B., Cepeda-Rebollar, R. M., ... & Agis-Juárez, R. A. (2018). Digital inclusion in older adults: a comparison between face-to-face and blended digital literacy workshops. *Frontiers in ICT*, 5, 21.
236. Mārtinsonē, K. 2011. Ievads pētniecībā: stratēģijas, dizaini, metodes. Rīga: Raka, 2011, 284 lpp.
237. Maskey, M., Ramachandran, R., Gurung, I., Freitag, B., Miller, J. J., Ramasubramanian, M., ... & Hain, C. (2019, July). Machine learning lifecycle for earth science application: A practical insight into production deployment. In *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium* (pp. 10043–10046). IEEE
238. Mason, R., Rennie, F. e-Learning and social networking handbook: resources for higher education; 2008.
239. Mathew, M., Morrow Jr, J. R., Frierson, G. M., & Bain, T. M. (2011). Assessing digital literacy in web-based physical activity surveillance: the WIN study. *American Journal of Health Promotion*, 26(2), 90–95.
240. Matzat, U., & Sadowski, B. (2012). Does the “Do-It-Yourself Approach” Reduce Digital Inequality? Evidence of Self-Learning of Digital Skills. *Information Society*, 28(1), 1-12. doi:10.1080/01972243.2011.62902
241. Medvidovic, N., Rosenblum, D. S., Redmiles, D. F., & Robbins, J. E. (2002). Modeling software architectures in the unified modeling language. *ACM Transactions on Software Engineering and Methodology (TOSEM)*, 11(1), 2–57.
242. Meedeck P., Iam-On N., Boongoen T. (2016) Prediction of Student Dropout Using

- Personal Profile and Data Mining Approach. In: Lavangnananda K., Phon-Amnuaisuk S., Engchuan W., Chan J. (eds) *Intelligent and Evolutionary Systems. Proceedings in Adaptation, Learning and Optimization*, vol 5.
243. Mirkin, B. (2012). *Clustering: A Data Recovery Approach*. CRC Press.
244. Miteva, D., & Stefanova, E. (2020). Design of Learning Analytics Tool: The Experts' Eyes View. In *CSEDU (2)* (pp. 307–314).
245. Moncada, I. L. R. Data Literacy and Confidence for Building Learning Analytics Solutions in Higher Education Institutions. A review. *CEUR Workshop Proc.* 2018, 2218, 293–299.
246. Mulyani, E., Hidayah, I., & Fauziati, S. (2019, December). Dropout Prediction Optimization through SMOTE and Ensemble Learning. In *2019 International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)* (pp. 516–521). IEEE.
247. Mustafa, M. N., Chowdhury, L., & Kamal, M. S. (2012, May). Students dropout prediction for intelligent system from tertiary level in developing country. In *2012 International Conference on Informatics, Electronics & Vision (ICIEV)* (pp. 113–118). IEEE.
248. Nakijama, S., (2018). Quality Assurance of Machine Learning Software, *2018 IEEE 7th Global Conference on Consumer Electronics (GCCE)*, Nara, 2018, pp. 601–604, doi: 10.1109/GCCE.2018.8574766.
249. Nath, R. P. D., Lee, H. J., Chowdhury, N. K., & Chang, J. W. (2010). Modified K-means clustering for travel time prediction based on historical traffic data. In *Knowledge-Based and Intelligent Information and Engineering Systems* (pp. 511–521). Springer Berlin Heidelberg.
250. Nelson, K., Corbin, G., Anania, M., Kovacs, M., Tobias J., and Blowers, M. (2015). Evaluating model drift in machine learning algorithms, *2015 IEEE Symposium on Computational Intelligence for Security and Defense Applications (CISDA)*, Verona, NY, 2015, pp. 1–8, doi: 10.1109/CISDA.2015.7208643.
251. Ng, W. (2012). Can we teach digital natives digital literacy?. *Computers & Education*, 59(3), 1065–1078.
252. Niet, Y. V., Díaz, V. G., & Montenegro, C. E. (2016, September). Academic decision making model for higher education institutions using learning analytics. In *2016 4th International Symposium on Computational and Business Intelligence (ISCBI)* (pp. 27–32). IEEE.
253. Ning Chen; Hoi, S.C.H.; Xiaokui Xiao, "Software process evaluation: A machine learning approach," *Automated Software Engineering (ASE)*, 2011 *26th IEEE/ACM International Conference on* , vol., no., pp.333,342, 6–10 Nov. 2011
254. Nissen, M., E. Harnessing knowledge dynamics: Principled organizational knowing & learning; 2006. p. 278.
255. Nistor, N., M. Dertnl, and R. Klamma, *Learning analytics: trends and issues of the empirical research of the years 2011–2014*, in *Design for Teaching and Learning in a Networked World*, G. Conole, u. c., Editors. 2015, Springer International Publishing. p. 453–459.
256. Nkambou, R., Mizoguchi, R., & Bourdeau, J. (2010). *Advances in intelligent tutoring systems*. Heidelberg: Springer.

257. Norman, G. (2010). Likert scales, levels of measurement and the “laws” of statistics. *Advances in health sciences education*, 15(5), 625-632.
258. Novaković, J. D., Veljović, A., Ilić, S. S., Papić, Ž., & Milica, T. (2017). Evaluation of classification models in machine learning. *Theory and Applications of Mathematics & Computer Science*, 7(1), 39–46.
259. Nwana, H. S. (1990). Intelligent tutoring systems: An overview. *Artificial Intelligence Review*, 4, 251–277.
260. Nyce, C., & Cpcu, A. (2007). Predictive analytics white paper. *American Institute for CPCU. Insurance Institute of America*, 9–10.
261. OECD. (2010) Are the new millennium learners making the grade? Retrieved October 31, 2015, from <http://www.oecd.org/edu/cefi/45000441.pdf>
262. Oye, N. D., Salleh, M. M., Iahad, N. A. E-Learning Barriers and Solutions to Knowledge Management and Transfer. *Information Management & Business Review*. 3(6); 2011. p. 366–372.
263. Olphert, C.W., Damodaran, L., May, A. (2005). Towards digital inclusion - Engaging older people in the digital world. *Proceedings of the Conference for Accessible Design in the Digital World*, Dundee, August.
264. Olphert, W., & Damodaran, L. (2013). Older people and digital disengagement: a fourth digital divide. *Gerontology*, 59(6), 564–570.
265. Ono, H. (2005). Digital Inequality in East Asia: Evidence from Japan, South Korea, and Singapore. *Asian Economic Papers*, 4(3), 116–139.
266. Ono, H., & Zavodny, M. (2008). Immigrants, English ability and the digital divide. *Social forces*, 86(4), 1455–1479.
267. Ortiz-Rojas, M., Maya, R., Jimenez, A., Hilliger, I., & Chiluzia, K. (2019, October). A step by step methodology for software design of a learning analytics tool in Latin America: A case study in Ecuador. In *2019 XIV Latin American Conference on Learning Technologies (LACLO)* (pp. 116–122). IEEE.
268. Osamor, V., Adebisi, E., Oyelade, J., & Doumbia, S. (2012). Reducing the time requirement of k-means algorithm. *Plos One*, 7(12), e49946. doi:10.1371/journal.pone.0049946
269. Oxford, R. M., & Daniel, L. G. (2001). Basic Cross-Validation: Using the " Holdout" Method To Assess the Generalizability of Results. *Research in the Schools*, 8(1), 83–89.
270. Oyedemi, T. (2012). Digital inequalities and implications for social inequalities: A study of Internet penetration amongst university students in South Africa. *Telematics & Informatics*, 29(3), 302–313. doi:10.1016/j.tele.2011.12.001
271. Oyelade, O. J., Oladipupo, O. O., & Obagbuwa, I. C. (2010). Application of k Means Clustering algorithm for prediction of Students Academic Performance. arXiv preprint arXiv:1002.2425.
272. Park, O. C., & Lee, J. (2003). Adaptive instructional systems. *Educational Technology Research and Development*, 25, 651–684.
273. Paterson, C., Calinescu, R., & Ashmore, R. (2021). Assuring the Machine Learning Lifecycle: Desiderata, Methods, and Challenges. *ACM Computing Surveys*.
274. Patmanthara, S., & Hidayat, W. N. (2018, June). Improving vocational high school

- students digital literacy skill through blended learning model. In *Journal of Physics: Conference Series* (Vol. 1028, No. 1, p. 012076). IOP Publishing.
275. Pearson Education. 2008. Introduction to SPSS in Psychology: For Version 16 and earlier, Fourth Edition, http://wps.pearsoned.co.uk/ema_uk_he_howitt_spsspsych_4/82/21003/5376999.cw/index.html
276. Penney, M. (2011). Enterprise Learning Intelligence Suite for Moodle Released, <https://moodle.org/mod/forum/discuss.php?d=178185>
277. Pereira F.D. u. c. (2019) Early Dropout Prediction for Programming Courses Supported by Online Judges. In: Isotani S., Millán E., Ogan A., Hastings P., McLaren B., Luckin R. (eds) Artificial Intelligence in Education. AIED 2019. *Lecture Notes in Computer Science*, vol 11626. Springer, Cham
278. Perera, D., Kay, J., Koprinska, I., Yacef, K., & Zaïane, O. R. (2009). Clustering and Sequential Pattern Mining of Online Collaborative Learning Data. *IEEE Transactions On Knowledge & Data Engineering*, 21(6), 759–772. doi:10.1109/TKDE.2008.138
279. Peronard, J. P., & Just, F. (2011). User motivation for broadband: A rural Danish study. *Telecommunications Policy*, 35(8), 691–701.
280. Petkovic, D.; Okada, K.; Sosnick, M.; Iyer, A.; Shenhaochen Zhu; Todtenhoefer, R.; Shihong Huang, "Work in progress: A machine learning approach for assessment and prediction of teamwork effectiveness in software engineering education," *Frontiers in Education Conference (FIE)*, 2012 , vol., no., pp.1,3, 3–6 Oct. 2012
281. Pfeffer, J., & Sutton, R. I. (1999). Knowing “what” to do is not enough: Turning knowledge into action. *California management review*, 42(1), 83–108.
282. Phillips Associates. (2018). Predictive Learning Analytics, <https://phillipsassociates.com/free-resources>
283. Pietrass, M. (2007). Digital literacy research from an international and comparative point of view. *Research in Comparative and International Education*, 1.
284. Pike B. (2018). Want to Eliminate Scrap Learning? *Training*. 2018;55(4):61
285. Podnieks, K. (2020). Datizrases algoritmi: lēmumu koki. <http://podnieks.id.lv/slides/mining/metodes1%20DT.pdf>
286. Powell, K. C., Kalina, C. J. Cognitive and Social Constructivism: Developing Tools for an Effective Classroom. *Education*. 130(2); 2009. p. 241–250.
287. Prieger, J. E., & Hu, W. M. (2008). The broadband digital divide and the nexus of race, competition, and quality. *Information economics and Policy*, 20(2), 150–167.
288. Prokofyeva, N., Zavjalova, O., & Boltunova, V. (2019, May). Feedback Method in Lecturer-Student Interaction. In *Proceedings of the International Scientific Conference. Volume I* (Vol. 442, p. 448).
289. Psootka, J., Mutter, S., M. (1988). *Intelligent Tutoring Systems: Lessons Learned*. Lawrence Erlbaum Associates
290. Quintana, M. G. B., & Zambrano, E. P. (2014). E-mentoring: The effects on pedagogical training of rural teachers with complex geographical accesses. *Computers in Human Behavior*, 30, 629–636.
291. Quo, L., and Boukir, S. (2017). Building an ensemble classifier using ensemble margin. Application to image classification, *IEEE International Conference on Image*

- Processing (ICIP)*, Beijing, 2017, pp. 4492–4496, doi: 10.1109/ICIP.2017.8297132.
292. Ray, S., & Turi, R. H. (1999). Determination of number of clusters in k-means clustering and application in colour image segmentation. In *Proceedings of the 4th international conference on advances in pattern recognition and digital techniques* (pp. 137–143).
293. Rana, N. P., Dwivedi, Y. K., & Williams, M. D. (2013). Analysing challenges, barriers and CSF of egov adoption. *Transforming Government: People, Process and Policy*, 7(2), 177–198. Retrieved from www.scopus.com
294. Rapaport, R. (2009). The new literacy: Scenes from the digital divide 2.0. Retrieved October 31, 2015, from <http://www.edutopia.org/digital-generation-divide-literacy>
295. Redecker, C. *European Framework for the Digital Competence of Educators: DigCompEdu*. Punie, Y. (ed). EUR 28775 EN. Publications Office of the European Union, Luxembourg, 2017, ISBN 978-92-79-73494-6, doi:10.2760/159770, JRC107466
296. Rexer Analytics. (2013). Data Miner Survey. <http://www.rexeranalytics.com/Data-Miner-Survey-Results-2013.html>
297. Ribeiro De Carvalho Martinho, V.; Nunes, C.; Minussi, C.R., "An Intelligent System for Prediction of School Dropout Risk Group in Higher Education Classroom Based on Artificial Neural Networks," *Tools with Artificial Intelligence (ICTAI)*, 2013 IEEE 25th International Conference on , vol., no., pp.159,166, 4–6 Nov. 2013
298. Riga dashboard. Measuring progress in e-Inclusion. (2007). Retrieved March 10, 2009, from European Commission website: http://ec.europa.eu/information_society/activities/einclusion/docs/i2010_initiative/rigadashboard.d
299. Rīgas Tehniskā universitāte un nozares ekspertu grupa (2010). *Vidzemes reģiona alternatīvo sociālo pakalpojumu sistēma*. Retrieved March 15, 2018, from website:
300. Rintamäki, K., & Lehto, A. (2018). A digital information literacy course for university teachers: challenges and possibilities.
301. Rissola, G., & Garrido, M. (2013). Survey on eInclusion Actors in the EU27. European Commission Joint Research Centre Institute for Prospective Technological Studies.
302. Rissola, G., Centeno, C. (2011). The Role of Information and Communication Technologies in the Integration of Immigrants and Ethnic Minorities, http://ftp.jrc.es/EURdoc/JRC66147_TN.pdf
303. Robles, J. M., & Torres-Albero, C. (2012). Digital Divide and the Information and Communication Society in Spain. *Sociologija i prostor/Sociology & Space*, 50(3).
304. Rodousakis, N., & Mendes dos Santos, A. (2008). The development of inclusive e-Government in Austria and Portugal: a comparison of two success stories. *Innovation: The European Journal of Social Science Research*, 21(4), 283–316.
305. Romero, C., & Ventura, S. (2019). Guest Editorial: Special Issue on Early Prediction and Supporting of Learning Performance, in *IEEE Transactions on Learning Technologies*, vol. 12, no. 2, pp. 145–147, 1 April–June 2019, doi: 10.1109/TLT.2019.2908106
306. 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.

307. Roulston, S., Cowan, P., Brown, M., Austin, R., & O'Hara, J. (2019). All aboard or still at check-in? Teacher educators' use of digital technologies: Lessons from a small island. *Education and information technologies*, 24(6), 3785–3802.
308. Rowe, G., & Wright, G. (1999). The Delphi technique as a forecasting tool: issues and analysis. *International journal of forecasting*, 15(4), 353–375.
309. Rudin, C. (2014). *Prediction: Machine Learning and Statistics*, Spring 2012. (MIT OpenCourseWare: Massachusetts Institute of Technology), <http://ocw.mit.edu/courses/sloan-school-of-management/15-097-prediction-machine-learning-and-statistics-spring-2012> (Accessed 2 Jun, 2014). License: Creative Commons BY-NC-SA
310. Samuelson, P. (2003). Mapping the digital public domain: Threats and opportunities. *Law & Contemp. Probs.*, 66, 147.
311. Sánchez, J. (2010). Digital inclusion in Chilean in rural schools. In *Proceedings of the 9th International Conference on Interaction Design and Children* (pp. 364–367). ACM.
312. Sandkuhl K., Stirna J., Persson A., Wißotzki M. (2014) Overview of the 4EM Method. In: *Enterprise Modeling. The Enterprise Engineering Series*. Springer, Berlin, Heidelberg
313. Santos, R., Azevedo, J., & Pedro, L. (2013). Digital Divide in Higher Education Students' Digital Literacy. In *Worldwide Commonalities and Challenges in Information Literacy Research and Practice* (pp. 178–183). Springer International Publishing.
314. Sanz, E., & Turlea, G. (2012). Downloading inclusion: a statistical analysis of young people's digital communication inequalities. *Innovation: The European Journal Of Social Sciences*, 25(3), 337–353. doi:10.1080/13511610.2012.699652
315. Sardinha, J. A. R. P., Noya, R. C., Milidui, R. L., & de Lucena, C. J. P. (2004). Engineering machine learning techniques into multi-agent systems. PUC.
316. Sclater, N. (2017). *Learning analytics explained*. Taylor & Francis.
317. Scheer, A. W., & Nüttgens, M. (2000). ARIS architecture and reference models for business process management. In *Business process management* (pp. 376–389). Springer, Berlin, Heidelberg.
318. Scheerder, A., van Deursen, A., & van Dijk, J. (2017). Determinants of Internet skills, uses and outcomes. A systematic review of the second-and third-level digital divide. *Telematics and informatics*, 34(8), 1607–1624.
319. Schuh, G., Scholz, P., Leich, T., & May, R. (2020, October). Identifying and Analyzing Data Model Requirements and Technology Potentials of Machine Learning Systems in the Manufacturing Industry of the Future. In *2020 61st International Scientific Conference on Information Technology and Management Science of Riga Technical University (ITMS)* (pp. 1–10). IEEE.
320. Sculley, D., Holt, G., Golovin, D., Davydov, E., Phillips, T., Ebner, D., ... & Dennison, D. (2015). Hidden technical debt in machine learning systems. *Advances in neural information processing systems*, 28, 2503–2511.
321. Seliya, N., Khoshgoftaar, T.M., and Hulse, J. V. (2009): A study on the relationships of classifier performance metrics. In: *21st IEEE International Conference on Tools with Artificial Intelligence*, pp. 59–66. Newark, NJ, Seville: JRC-IPTS. Retrieved

from <http://ipts.jrc.ec.europa.eu/publications/pub.cfm?id=4699>.

322. Selwyn, N. (2004). Reconsidering political and popular understandings of the digital divide. *New Media & Society*, 6(3), 341–362
323. Selwyn, N., Gorard, S., & Furlong, J. (2005). Whose Internet is it anyway? Exploring adults' (non) use of the Internet in everyday life. *European Journal of Communication*, 20(1), 5–26.
324. Senkbeil, M., & Ihme, J. M. (2017). Motivational factors predicting ICT literacy: First evidence on the structure of an ICT motivation inventory. *Computers & Education*, 108, 145–158.
325. Shearer C., *The CRISP-DM model: the new blueprint for data mining*, J Data Warehousing (2000); 5:13–22
326. Siemens, G., Gasevic, D., Haythornthwaite, C., Dawson, S., Shum, S., B., Ferguson, D., Duval, E., Verbert, K., and Baker, R., S., J., D., Open Learning Analytics: an integrated & modularized platform, 2011.
327. Siemens, G. (2013). Learning analytics: The emergence of a discipline. *American Behavioral Scientist*, 57(10), 1380–1400.
328. Silic, M., & Cyr, D. (2016, July). Colour arousal effect on users' decision-making processes in the warning message context. In *International Conference on HCI in Business, Government, and Organizations* (pp. 99–109). Springer, Cham.
329. Skujiņa, V. Pedagoģijas terminu skaidrojošā vārdnīca. Termini latviešu, angļu, vācu, krievu valodā. Sast. I. Beļickis, D. Blūma, T. Koķe, D. Markus, V. Skujiņa (vad.), A. Šalme. — Rīga: “Zvaigzne ABC”, 2000. — 248 lpp.
330. Smith, S. (2014). Supporting digital literacy across the curriculum through blended support: A pilot project report. *Journal of Educational Technology Systems*, 43(2), 189–198.
331. Smith, V. C., Lange, A., & Huston, D. R. (2012). Predictive Modeling to Forecast Student Outcomes and Drive Effective Interventions in Online Community College Courses. *Journal Of Asynchronous Learning Networks*, 16(3), 51–61.
332. Snee, R. D. (1977). Validation of regression models: methods and examples. *Technometrics*, 19(4), 415–428.
333. Society for Learning Analytics Research. 2014. Website. <http://www.solaresearch.org>
334. Soja, E., Soja, P., Kolkowska, E., & Kirikova, M. (2019, September). Supporting active and healthy ageing by ICT solutions: preliminary lessons learned from Polish, Swedish and Latvian older adults. In *EuroSymposium on Systems Analysis and Design* (pp. 48–61). Springer, Cham.
335. Soobramoney, S., & Heukelman, D. (2019, March). The Four Is of E-skills. In *2019 Conference on Information Communications Technology and Society (ICTAS)* (pp. 1–6). IEEE.
336. Sorour, S. E., Mine, T., Goda, K., & Hirokawa, S. (2014, April). Efficiency of LSA and K-means in Predicting Students' Academic Performance Based on Their Comments Data. In *CSEU (1)* (pp. 63–74).
337. Stale, G. (2006). Social and motivating knowledge society solutions for e-inclusion of disabled. Retrieved March 15, 2009,

from http://www.balticit.com/ist4balt/ppt/Presentations2006/4%20%20eInclusion/Ginta_Stale/Presentation_Ginta_Stale_Final.ppt

338. Stecjuka, J., & Kirikova, M. ([200X]). EKD metodoloģijas pārskats. Retrieved March 10, 2009, from Riga Technical University website: <http://stpk.cs.rtu.lv>
339. Steeneveldt, R., Berger, B., Torp, T.A. CO2 Capture and Storage: Closing the Knowing–Doing Gap. *Chemical Engineering Research and Design*. Vol. 84(9); 2006. p. 739–763
340. Steinbach, M., Karypis, G., & Kumar, V. (2000, August). A comparison of document clustering techniques. In *KDD workshop on text mining* (Vol. 400, No. 1, pp. 525–526).
341. Stimpson, A.J.; Cummings, M.L., "Assessing Intervention Timing in Computer-Based Education Using Machine Learning Algorithms," *Access, IEEE*, vol.2, no., pp.78,87, 2014
342. Stirna, J., & Persson, A. (2018). *Enterprise modeling*. Cham: Springer.
343. Studer, S., Bui, T. B., Drescher, C., Hanuschkin, A., Winkler, L., Peters, S., & Müller, K. R. (2021). Towards CRISP-ML (Q): a machine learning process model with quality assurance methodology. *Machine Learning and Knowledge Extraction*, 3(2), 392–413.
344. Subramaniam, P., R. Motivational Effects of Interest on Student Engagement and Learning in Physical Education: *A Review. Int. Journal Phys Educ*. Vol. 46(2); 2009. p. 11–19. Retrieved: 12.12.2012, URL: http://www.unco.edu/cebs/psychology/kevinpugh/motivation_project/resources/subramaniam.pdf.
345. Sundqvist, K., Korhonen, J., & Eklund, G. (2020). Predicting Finnish subject-teachers' ICT use in Home Economics based on teacher-and school-level factors. *Education Inquiry*, 1–21.
346. Suresh A., Sushma Rao H.S., Hegde V. (2017) Academic Dashboard—Prediction of Institutional Student Dropout Numbers Using a Naïve Bayesian Algorithm. In: Vishwakarma H., Akashe S. (eds) *Computing and Network Sustainability. Lecture Notes in Networks and Systems*, vol 12. Springer, Singapore
347. Tamada, M. M., de Magalhães Netto, J. F., & de Lima, D. P. R. (2019, October). Predicting and Reducing Dropout in Virtual Learning using Machine Learning Techniques: A Systematic Review. In *2019 IEEE Frontiers in Education Conference (FIE)* (pp. 1–9). IEEE.
348. Technosite (2011). Monitoring eAccessibility in Europe. <http://www.eaccessibility-monitoring.eu/researchResult.aspx>
349. Tilde. (2014). Letonika, letonika.lv
350. Townsend, L., Sathiaselan, A., Fairhurst, G., & Wallace, C. (2013). Enhanced broadband access as a solution to the social and economic problems of the rural digital divide. *Local Economy*, 28(6), 580–595.
351. Tsai, Y. S., & Gasevic, D. (2017, March). Learning analytics in higher education-challenges and policies: a review of eight learning analytics policies. In *Proceedings of the seventh international learning analytics & knowledge conference* (pp. 233–242).
352. Tucker, J. S., McGilvray, D. H., Leibrecht, B. C., Strauss, C. B., Perrault, A., & Gesselman, A. N. (2009). *Training digital skills in distributed classroom*

environments: A blended learning approach. NORTHROP GRUMMAN CORP
COLUMBUS GA

353. Uzunboylu, H., & Tuncay, N. (2010). Divergence of digital world of teachers. *Journal of Educational Technology & Society*, 13(1), 186–194.
354. Vagale, V. (2011). Uz lietotāja modeli balstīta personalizēta adaptīva e-studiju sistēma, http://www.df.lu.lv/fileadmin/user_upload/lu_portal/projekti/df/dokumenti/Doktorantura/Dokt_seminara_prezentacijas/23_11_2011_vvagale.pdf
355. Van Deursen, A. J., & Van Dijk, J. A. (2009). Using the Internet: Skill related problems in users' online behavior. *Interacting with computers*, 21(5–6), 393–402.
356. Van Deursen, A., & Van Dijk, J. (2014). The digital divide shifts to differences in usage. *New Media & Society*, 16(3), 507–526. doi:10.1177/1461444813487959
357. Van Deursen, A. J., & van Dijk, J. A. (2015). Internet skill levels increase, but gaps widen: A longitudinal cross-sectional analysis (2010–2013) among the Dutch population. *Information, Communication & Society*, 18(7), 782–797.
358. Van Dijk, J. A. (2006). Digital divide research, achievements and shortcomings. *Poetics*, 34(4–5), 221–235.
359. Vedins, I. Macīšanās māksla. In Latvian. Riga: Avots; 2011
360. Verhoeven, J. C., Heerwegh, D., & De Wit, K. (2020). Predicting ICT skills and ICT use of University students. *Encyclopedia of Education and Information Technologies*, 1286–1304.
361. Viberg, O., Hatakka, M., Bälter, O., & Mavroudi, A. (2018). The current landscape of learning analytics in higher education. *Computers in Human Behavior*, 89, 98–110.
362. Vicente, M. R., & Lopez, A. J. (2010). A multidimensional analysis of the disability digital divide: some evidence for Internet use. *The Information Society*, 26(1), 48–64.
363. Wakelam, E., Jefferies, A., Davey, N., & Sun, Y. (2020). The potential for student performance prediction in small cohorts with minimal available attributes. *British Journal of Educational Technology*, 51(2), 347–370.
364. Wang Hua; Ma Cuiqin; Zhou Lijuan, "A Brief Review of Machine Learning and Its Application," Information Engineering and Computer Science, 2009. ICIECS 2009. *International Conference on* , vol., no., pp.1,4, 19–20 Dec. 2009
365. Warren, M. (2007). The digital vicious cycle: Links between social disadvantage and digital exclusion in rural areas. *Telecommunications Policy*, 31 (6) (2007), pp. 374–388
366. Williams, Jim; Rosenbaum, Steve (2004). Learning Paths Increase Profits by Reducing the Time it Takes Employees to Get Up-To-Speed. San Francisco: Pfeiffer.
367. Wirastuti, N. D., Luckin, R., Sheriff, R. E., Walker, K., Underwood, J., & Dunckley, L. (2008, March). Development of a knowledge management system integrated with local communication channels and knowledge management initiatives for Kenyan rural farming communities. In *Fifth IEEE international conference on wireless, mobile, and ubiquitous technology in education (wmute 2008)* (pp. 135–142). IEEE.
368. Wirth, R., & Hipp, J. (2000, April). CRISP-DM: Towards a standard process model for data mining. In *Proceedings of the 4th international conference on the practical applications of knowledge discovery and data mining* (Vol. 1). London, UK: Springer-Verlag.

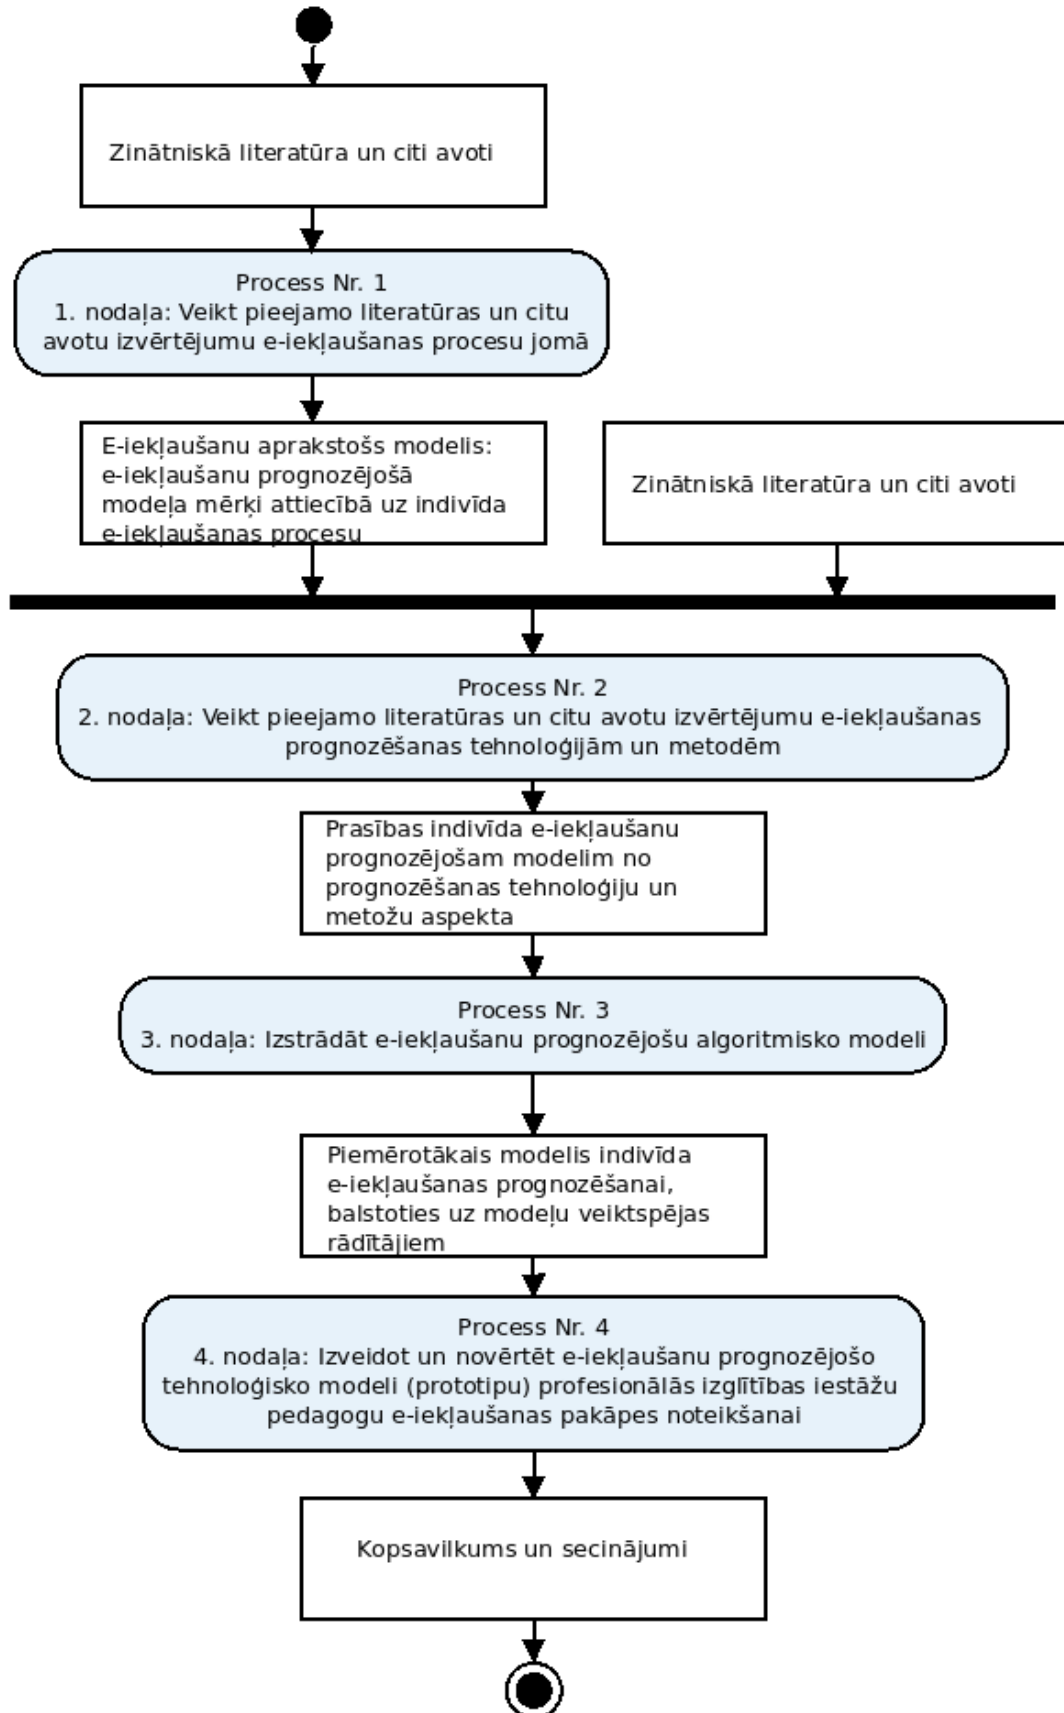
369. Witten, I. H., & Frank, E. (2005). *Data Mining: Practical Machine Learning Tools and Techniques* (Second Edition). *Morgan Kaufmann*. ISBN 0-12-088407-0
370. Wortman, B. *Value-changing behavior: getting the habit*. *Journal Of Business Strategy*. 26(4); 2005. p. 38–45.
371. Yabo, Z., & Yuelong, Z. (1999). Qualitative Forecast Methods. *Journal of JILIN Architectural and Civil Engineering Institute*, 1, 011.
372. Xu, Z., Yuan, H., & Liu, Q. (2020). Student Performance Prediction Based on Blended Learning. *IEEE Transactions on Education*.
373. Xue, L., & Lu, X. (2021). Research on the Integrated Innovative Teaching Model of Art and Technology Based on Pearson Correlation Analysis, *2021 2nd International Conference on Artificial Intelligence and Education (ICAIE)*, 2021, pp. 245-251, doi: 10.1109/ICAIE53562.2021.00058.
374. Yadav, S., & Shukla, S. (2016, February). Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification. In *2016 IEEE 6th International conference on advanced computing (IACC)* (pp. 78–83). IEEE.
375. Yan, H., Zhou, W., & Han, S. (2013). Social Capital, Digital Inequality, and a "Glocal" Community Informatics Project in Tianzhu Tibetan Autonomous County, Gansu Province. *Library Trends*, 62(1), 234–260
376. Yu, B., Ndumu, A., Mon, L. M., & Fan, Z. (2018). E-inclusion or digital divide: an integrated model of digital inequality. *Journal of Documentation*.
377. Yu, T. K., Lin, M. L., & Liao, Y. K. (2017). Understanding factors influencing information communication technology adoption behavior: The moderators of information literacy and digital skills. *Computers in Human Behavior*, 71, 196–208.
378. Zaharia, M., Chen, A., Davidson, A., Ghodsi, A., Hong, S. A., Konwinski, A., ... & Xie, F. (2018). Accelerating the Machine Learning Lifecycle with MLflow. *IEEE Data Eng. Bull.*, 41(4), 39–45.
379. Záhorec, J., Hašková, A., & Munk, M. (2019). Teachers' Professional Digital Literacy Skills and Their Upgrade. *European Journal of Contemporary Education*, 8(2), 378–393.
380. Zhang, J. M., Harman, M., Ma, L., & Liu, Y. (2020). Machine learning testing: Survey, landscapes and horizons. *IEEE Transactions on Software Engineering*.
381. Zhao, S., & Elesh, D. (2007). The second digital divide: unequal access to social capital in the online world. *International Review of Modern Sociology*, 33(2), 171–192.
382. Zhu, S., & Chen, J. (2013). The digital divide in individual e-commerce utilization in China: results from a national survey. *Information Development*, 29(1), 69-80. doi:10.1177/0266666912450168
383. Zhuge, H. *The Knowledge Grid*; 2004.
384. Zillien, N., & Hargittai, E. (2009). Digital distinction: Status-specific types of internet usage. *Social Science Quarterly*, 90 (2), 274–291.
385. Ziņojums par demogrāfisko pārmaiņu ietekmi Eiropā (COM(2020)241 final, 17.6.2020.).
386. Zorrilla, M., García, D., & Álvarez, E. (2010). A decision support system to improve e-learning environments. In *Proceedings of the 2010 EDBT/ICDT Workshops* (p. 11). ACM.

387. Žuga, B., Kapenieks, K., Vītoliņa, I., Mangusa, L., & Kapenieks, A. (2014). Elearning approach eBIG3: Development, Delivery, and Evaluation. In *Society. Integration. Education. Proceedings of the International Scientific Conference* (Vol. 2, pp. 379–387).

PIELIKUMI

1. pielikums

Promocijas darba nodaļu izveides procesa shematisks attēlojums atbilstoši pētījuma darba uzdevumiem



2. pielikums

Promocijas darbā izmantotās definīcijas, akronīmi un saīsinājumi

Akurātums (angļu val. – *accuracy*) – binārā klasifikācijas modelī tiek definēts kā abu klašu pareizi klasificētu gadījumu attiecība pret kopējo gadījumu skaitu.

Apmācības dati (angļu val. – *training data*) – dati, ko izmanto mašīnmācīšanās procesā. Apmācības dati tiek nodoti algoritmam, lai noteiktu, kādas sakarības pastāv starp datiem.

Datizrace ir datu bāzes datu analīze, kas paredzēta apslēptu sakarību meklēšanai kādā datu grupā, piemēram, atrast lietotājus ar kopīgām interesēm (Latvijas Nacionālais terminoloģijas portāls, 2021).

Digitālā kompetence ietver digitālo tehnoloģiju pārlicinātu, kritisku un atbildīgu izmantošanu un darbošanos ar šīm tehnoloģijām mācību un darba vajadzībām un nolūkā piedalīties sabiedrības dzīvē (Eiropas Padome, 2018). Kompetences definē kā zināšanu, prasmju un attieksmju kombināciju, kur: zināšanas ir fakti un skaitļi, jēdzieni, idejas un teorijas, kas jau ir atzītas un pamato izpratni par konkrētu jomu vai tematu; **prasmes** definē kā spēju un iespēju īstenot procesus un izmantot pastāvošās zināšanas, lai sasniegtu rezultātus; ar attieksmēm saprot ievirzi un domāšanas veidus, kas izpaužas kā gatavība rīkoties vai reaģēt uz idejām, cilvēkiem vai situācijām (Eiropas Padome, 2018).

E-iekļaušana (angļu val. – *e-inclusion*) ir ikviena indivīda un sabiedrības kopumā iesaistīšana jebkurās valsts un sabiedrības aktivitātēs ar informācijas un komunikācijas tehnoloģiju (IKT) pielietojumu starpniecību (E-iekļaušanas deklarācija, 2006). Saistītie termini: digitālā iekļaušana, digitālā nevienlīdzība, digitālā plaisa.

E-iekļaušanas pakāpe norāda, cik lielā mērā indivīds izmanto jaunapgūtās digitālās prasmes jēgpilni.

E-iekļaušanas politikas mērķis ir samazināt atšķirības, kādas pastāv dažādiem indivīdiem IKT lietošanā un sekmēt to, ka ikviens indivīds IKT izmanto efektīvi izglītībai, personības pilnveidei un profesionālajai izaugsmei, tādējādi veicinot tautsaimniecības izaugsmi un indivīdu pilnvērtīgu iekļaušanos informācijas sabiedrības norisēs (adaptēts no E-iekļaušanas deklarācijas, 2006).

E-iekļaušanas process ir aktivitātes e-iekļaušanas mērķu sasniegšanā.

E-iekļaušanu aprakstošs modelis ir modelis, kas promocijas darbā veidots ar *4EM* metodi un tas satur e-iekļaušanas procesu stratēģiskos mērķus, problēmas, kas kavē sasniegt mērķus, iesaistītās mērķgrupas un resursus, likumus vai noteikumus, kas jāņem vērā e-iekļaušanas procesā, kā arī galvenos e-iekļaušanas jēdzienus. E-iekļaušanu aprakstošs modelis ir dots promocijas darba 1. nodaļā.

E-iekļaušanu prognozējošs modelis jeb **e-iekļaušanu prognozējošs algoritmiskais modelis** ir modelis, kas ir veidots, izmantojot apmācības datus, mašīnmācīšanās un citus algoritmus, un ar kuru ir iespējams prognozēt indivīda e-iekļautību.

E-iekļaušanu prognozējošs tehnoloģiskais modelis ir prototips indivīda e-iekļautību prognozējošai informācijas sistēmai, kurā ir izvietots e-iekļaušanu prognozējošais algoritmiskais modelis.

E-iekļauts (arī digitāli iekļauts) – promocijas darba kontekstā indivīds ir e-iekļauts, ja jēgpilni izmanto jaunapgūtās digitālās prasmes. Indivīds nav e-iekļauts (digitāli izslēgts), ja neizmanto jēgpilni jaunapgūtās digitālās prasmes.

IKT – Informācijas un komunikācijas tehnoloģijas.

Instruktors – promocijas darba kontekstā ar instruktoru tiek saprasts kombinētās mācīšanās veida mācītspēks, kurš studentiem ir gids, mentors un atbalsts digitālo prasmju kursa satura apguvē.

Klasifikators, klasifikatoru ģenerators jeb klasifikatora ģenerēšanas algoritms – algoritms, ar kuru risina klasifikācijas uzdevumu. Algoritms, kas jebkuru doto apmācības kopu pārveido par klasifikācijas modeli. Piemēram, klasifikatoru ģenerēšanas algoritmi ir C4.5, CART.

Klasifikācijas modelis - Dotajai apmācību kopai konkrētam klasifikācijas uzdevumam uzbūvētais algoritms.

Klasifikācijas metode (skat. klasifikators) – piemēram, lēmumu koki.

Kombinētā mācīšanās (angļu val. – *blended learning*) – mācīšanās veids, kurā studenti mācās, izmantojot elektroniskos un tiešsaistes līdzekļus, kā arī tradicionālās mācības klātienē.

Mācību analītika ir ar izglītojamajiem saistītu datu mērījumi, kolekcijas, analīze un pārskati, lai izprastu un optimizētu mācīšanās procesu un vidi, kurā notiek apmācība (LAK, 2011).

Mašīnmācīšanās – (angļu val. – *machine learning*) ir mākslīgā intelekta apakšnozare, kurā nodarbojas ar tādu algoritmu izstrādi, kuri ļauj datoriem uzlabot lēmumu pieņemšanu, pamatojoties uz empīriskiem datiem. Mašīnmācīšanās procesa mērķis ir nodrošināt datorprogrammai apmācību, balstoties uz pagātnes pieredzi.

Mašīnmācīšanās algoritms ir mērķtiecīgs darbību izpildes priekšraksts, ar kuru no dotajiem datiem ar galīgu elementāru darbību jeb soļu skaitu iegūst mašīnmācīšanās modeli. Mašīnmācīšanās algoritmu piemēri ir lineārās regresijas algoritms, klasteranalīzes algoritms *kMeans*, klasifikatori – lēmumu koki, Naivais Beijess, loģistiskā regresija.

Mašīnmācīšanās modelis ir mašīnmācīšanās algoritma rezultāts, izmantojot apmācības datu kopu. Modelis attēlo ar mašīnmācīšanās algoritmu iemācīto. Modelis atspoguļo likumus, skaitļus un citu algoritmam specifisku informāciju, kas nepieciešama, lai veiktu prognozes. Piemēram, lineārās regresijas algoritmam mašīnmācīšanās modeli veido lineārās regresijas vienādojuma koeficientu vērtības.

Nelīdzsvarotas datu kopas klases - datu kopas klases ir nelīdzsvarotas, ja kādā no klasēm ir daudz vairāk klašu gadījumu (piemēru) nekā citā klasē. Attiecība starp mazākajām un lielākajām klasēm var būt 1: 100, 1: 1000 vai pat 1: 10 000 atkarībā no lietojumiem.

Pārklājums (angļu val. – *recall*) – binārās klasifikācijas modelī parāda, cik daudz no pozitīvās klases gadījumiem ir atklāti.

Pārlika pielāgotība (angļu val. – *overfitting*) – pārpielāgotība.

Precizitāte (angļu val. – *precision*) – binārā klasifikācijas modelī norāda, cik procentu no tiem, kas prognozēti kā pozitīvā klase, ir pareizi prognozēti.

Prognozēšana (angļu val. – *forecasting*) - uz faktiem, novērojumiem vai pieņēmumiem balstīta paredzēšana, nākotnes tēla veidošana ar noteiktu varbūtības pakāpi.

Prognozējošā modelēšana (angļu val. – *predictive modeling*) ir modeļa izstrādes process, kas ģenerē akurātu (korektu) prognozi.

Prognozējošā analītika (angļu val. – *predictive analytic*) ietver dažādas datizraces, prognozējošās modelēšanas, mašīnmācīšanās statistikas metodes, lai balstoties uz pašreizējo un vēsturisko faktu analīzi, prognozētu nākotnes notikumus.

Students – promocijas darba kontekstā students ir profesionālās izglītības iestādes pedagogs, kurš apgūst digitālās prasmes kombinētās mācīšanāsursos.

3. pielikums

Promocijas darbā ievietoto attēlu saraksts

1.1. att. 4EM modeļa struktūra un apakšmodeļu savstarpējā saistība (tulkots no (Bubenko, 2001a)).....	19
1.2. att. E-iekļaušanas modeļa veidošanas process.....	21
1.3. att. E-iekļaušanas stratēģisko mērķu modelis.....	24
1.4. att. E-iekļaušanas stratēģiskā mērķa Risināt gados vecāko strādājošo un gados vecāku cilvēku vajadzības, izmantojot IKT iespējas problēmas un īstenošanas pamatlikumi.....	25
1.5. att. Stratēģiskā mērķa Samazināt ģeogrāfiskās digitālās robežšķirtnes problēmas, resursi un īstenošanas pamatlikums.....	27
1.6. att. Stratēģiskā mērķa Uzlabot e-pieejamību un lietojamību īstenošanas problēma, pamatlikumi, resursi.....	28
1.7. att. Stratēģiskā mērķa Uzlabot digitālās prasmes problēmas un īstenošanas pamatlikumi, resursi.....	29
1.8. att. Mērķa Attīstīt augstas veiktspējas digitālās izglītības ekosistēmu apakšmērķi, problēmas, saistītie likumi un jēdzieni digitālo prasmju uzlabošanas kontekstā.....	31
1.9. att. Stratēģiskā mērķa Veicināt kultūras daudzveidību saistībā ar e-iekļaušanu problēmas un īstenošanas pamatlikumi, resursi.....	32
1.10. att. Stratēģiskā mērķa Veicināt iekļaujošas e-pārvaldes attīstību problēmas, resursi un īstenošanas pamatlikumi.....	34
1.11. att. Individā e-iekļaušanas procesa modelis.....	37
1.12. att. E-iekļaušanas mērķgrupas un procesa virzītāji.....	38
2.1. att. Prognozējošu informācijas sistēmu galvenās funkcijas: modeļa apmācība, prognozēšana, uzturēšana.....	61
2.2. att. E-iekļaušanu prognozējošā modeļa izveides process.....	69
3.1. att. Respondentu skaits atbilstoši dzimumam.....	76
3.2. att. Respondentu skaits atbilstoši vecumu diapazonam.....	76
3.3. att. Vidējās vērtības rezultātvai pazīmei – e-iekļautības pakāpei.....	93
3.4. att. Biežāk izmantotie prediktori lineārās regresija modelī studenta prognozētai digitālo prasmju lietošanai un iespējamai lietošanai.....	104
3.5. att. Prognozētās un iespējamās lietošanas lineārās regresijas modeļos izmantotie indivīda e-iekļautību ietekmējošie faktori.....	104
3.6. att. Profesionālo izglītības iestāžu pedagogus raksturojoši klasteri (<i>kMeans</i> algoritms, $k=4$, normalizētas vērtības).....	108
3.7. att. 5 klasifikācijas algoritmu veiktspējas rādītāji Video tehnoloģiju un dizaina kursam.....	115
3.8. att. 5 klasifikācijas algoritmu veiktspējas rādītāji Mobilo tehnoloģiju kursam.....	116
3.9. att. 5 klasifikācijas algoritmu veiktspējas rādītāji Robotikas kursam.....	117

3.10. att. Izmaiņas F1 mēra vērtībām 5 klasifikācijas algoritmiem pēc visu studentu datu kopas līdzsvarošanas 3 dažādiem mācību kursiem.....	118
3.11. att. Izmaiņas F1 mēra vērtībām 5 klasifikācijas algoritmiem pēc studentu, kam ir piekļuve tehnoloģijām, datu kopas līdzsvarošanas 3 dažādiem mācību kursiem.....	118
3.12. att. 3 dažādu mācību kursu vidējo F1 mēru salīdzinājums 5 klasifikācijas algoritmiem līdzsvarotām un nelīdzsvarotām datu kopām.....	119
3.13. att. Veiktspējas metrikas izmaiņas atkarībā no prognozētās e-iekļautības pakāpes. E-iekļautības pakāpes sliekšņa noteikšana.....	124
3.14. att. Noteikumi jaunu prognozēšanas modeļu izveidošanai, apvienojot M1, M2 un M3 modeļus, un, mainot prognozes vērtības no e-iekļauts uz nav e-iekļauts ar mērķi palielināt pārklājumu.....	125
3.15. att. Rezultāti. F1 mēra, precizitātes, pārklājuma vērtības e-iekļautības prognozēšanas modeļiem, ja pieņem, ka pārklājumam un precizitātei ir vienlīdz svarīgi.....	126
3.16. att. Rezultāti. F2 mēra, precizitātes, pārklājuma vērtības e-iekļautības prognozēšanas modeļiem, ja pieņem, ka pārklājums ir svarīgāks nekā precizitāte.....	127
3.17. att. E-iekļautības pakāpes un atbilstošās pārklājuma un precizitātes vērtību izmaiņas M5 un M6 modeļiem (F2 mērs).....	128
3.18. att. Augstas, vidējas un zemas prognozēšanas precizitātes līmeņi un atbilstoši tiem prognozēto riska studentu sadalījums.....	129
3.19. att. M2 modeļa e-iekļauto un e-neiekļauto studentu kopu centroīdi. Klasteris “0” ir paredzēts e-iekļautai klasei, klasteris “1” ir paredzēts e-neiekļautai klasei. Atribūti ir studentu pašnovērtējumi. SWL - studenta motivācija, DS - digitālās prasmes, SAL - studenta spēja mācīties, ELM - e-mācību materiāli, IWS - instruktora vēlme dalīties zināšanās, ELE - e-mācību vide, PU – studenta prognoze tam, ka students izmantos jauniegūtās prasmes.....	129
3.20. att. M3 modeļa lineārās regresijas vērtības. Atribūti ir studentu pašnovērtējumi. SWL - studentu motivācija, SAL - studentu spēja mācīties, ELM - e-mācību materiāli, ELE- e-mācību vide. PUOU - paredzamā e-iekļaušanas pakāpes vērtība.....	130
4.1. att. Individā e-iekļautības prognozēšanas sistēmas mērķu diagramma.....	134
4.2. att. Individā e-iekļaušanu prognozējošās sistēmas lietošanas gadījumu diagramma.....	136
4.3. att. Konteksta līmeņa datu plūsmas diagramma, kas parāda saikni starp e-iekļautību prognozēšanas sistēmu, instruktoru, MVS (mācīšanās vadības sistēma) un SMS sistēmu....	137
4.4. att. Datu plūsmas diagramma, kas parāda pamatprocesus un datu plūsmu starp procesiem e-iekļaušanas prognozēšanas sistēmā.....	138
4.5. att. E-iekļaušanu prognozējošā algoritma shēma.....	140
4.6. att. Apmācības process individuā e-iekļautības prognozēšanas algoritmam, izmantojot trīs modeļu apmācību un PROG funkcijas aprēķinu.....	141
4.7. att. Fināla prognozes noteikšanas process, pamatojoties uz M1, M2, M3 modeļu prognozēm.....	142
4.8. att. Prognozēšanas procesa algoritms konkrētam studentam.....	143
4.9. att. Prognozēšanas precizitātes līmeņa noteikšanas algoritms konkrētam studentam.....	144
4.10. att. Prognozēšanas modeļa veiktspējas uzraudzības process.....	145
4.11. att. E-iekļautības prognozēšanas prototipa galvenās izvēles.....	146

4.12. att. Prognozēšanas rezultātu skats un precizitātes līmenis tabulas formā.....	146
4.13. att. Studentu datu skats un atbilstošās prognozes tabulas veidā.....	147
4.14. attēls: M2 un M3 modeļa rezultātu detalizēts skats individuālam izglītojamam. a) M2 modeļa prognoze par riska studentu ar augstu precizitāti; b) M2 modeļa prognoze par riska studentu ar vidēju precizitāti; c) M2 modeļa prognoze par studentu bez riska ar augstu precizitāti; d) M3 modeļa prognoze par riska studentu ar zemu precizitāti.....	148
4.15. att. E-iekļaušanu prognozējošā modeļa veikspējas rādītāji.....	151
4.16. att. Prognozējošā modeļa novirzes mērījumi ar veikspējas metrikām, ja prognozēšanā izmantota trīs modeļu kombinācija.....	152
4.17. att. Prognozējošā modeļa novirzes mērījumi ar veikspējas metrikām, ja prognozēšanā izmantota divu modeļu kombinācija.....	153
4.18. att. Prognozējošā modeļa novirzes mērījumi ar veikspējas metrikām, ja prognozēšanā izmantots viens modelis.....	153

4. pielikums

Promocijas darbā ievietoto tabulu saraksts

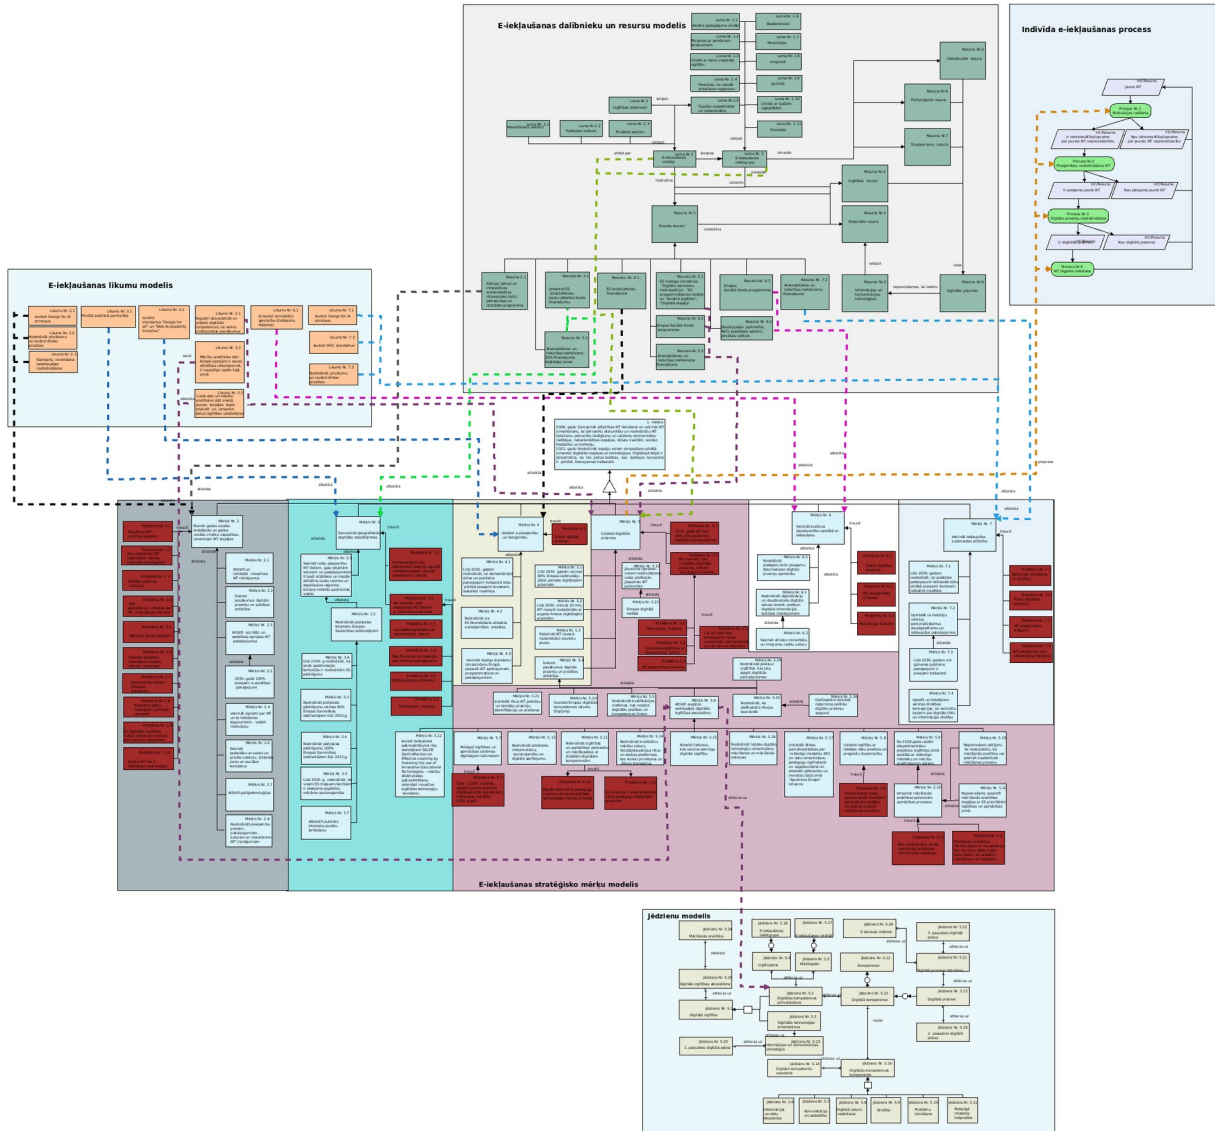
2.1. tabula. Pārpratumu matrica binārā klasifikatorā.....	50
2.2. tabula. Prognozējoša modeļa izveides procesa posmi.....	62
2.3. tabula. Problēmsfēras izpratnes posma uzdevumi un rezultāti.....	63
2.4. tabula. Datu izpratnes posma uzdevumi un rezultāti.....	64
2.5. tabula. Datu sagatavošanas posma uzdevumi un rezultāti.....	65
2.6. tabula. Modeļa izveidošanas posma uzdevumi un rezultāti.....	66
2.7. tabula. Modeļa izvietošanas posma uzdevumi un rezultāti.....	67
2.8. tabula. Modeļa izvietošanas posma uzdevumi un rezultāti.....	67
2.9. tabula. Modeļa pārraudzības un uzturēšanas posma uzdevumi un rezultāti.....	68
3.1. tabula. Respondentu skaits aptaujas anketām.....	78
3.2. tabula. Aptaujas anketu veidi, norises laiks, skaits, iegūtie dati un atbilstošā mērījumu skala.....	80
3.3. tabula. E-iekļaušanas procesu raksturojošie faktori un tiem atbilstošie neatkarīgie mainīgie.....	82
3.4. tabula. Atkarīgo mainīgo raksturojums.....	83
3.5. tabula. Datu kopas atbilstoši tēmai korelāciju meklēšanai un lineārās regresijas modeļu veidošanai.....	84
3.6. tabula. Korelāciju un lineārās regresijas pētījumu datu kopas mainīgie un to iespējamo vērtību raksturojums.....	84
3.7. tabula. Klasificēšanas algoritmiem izmantotās datu kopas.....	85
3.8. tabula. Izglītojamo sadalījums klasēs <i>e-iekļauts</i> un <i>nav e-iekļauts</i>	86
3.9. tabula. Aritmētiskais vidējais un standartnovirze prediktoriem (faktoriālai pazīmei).....	90
3.10. tabula. Aritmētiskais vidējais un standartnovirze rezultatīvai pazīmei.....	92
3.11. tabula. Pīrsona korelāciju koeficienti studenta prasmju prognozētajai lietošanai un identificētajiem prediktoriem (e-iekļaušanas faktoriem).....	94
3.12. tabula. Pīrsona korelāciju koeficienti novērotai jaunapgūto digitālo prasmju lietošanai un prediktoriem (e-iekļaušanas faktoriem).....	96
3.13. tabula. Pīrsona korelāciju koeficienti iespējamai jaunapgūto digitālo prasmju lietošanai un prediktoriem (e-iekļaušanas faktoriem).....	97
3.14. tabula. Determinācijas koeficienti R^2 un tā nozīmīgums studenta prognozētās lietošanas lineārās regresijas modelim.....	100
3.15. tabula. Determinācijas koeficienti R^2 un tā nozīmīgums iespējamās lietošanas lineārās regresijas modelim.....	101
3.16. tabula. Prediktori un lineārās regresijas vienādojumi studenta prognozētai digitālo prasmju lietošanai.....	101
3.17. tabula. Prediktori un lineārās regresijas vienādojumi iespējamai digitālo prasmju	

lietošanai.....	102
3.18. tabula. Prediktoru biežums tēmās prognozētai lietošanai un iespējamai lietošanai.....	103
3.19. tabula. Profesionālo izglītības iestāžu pedagogus raksturojoši klasteri (<i>kMeans</i> algoritms, $k=4$, absolūtās vērtības).....	108
3.20. tabula. Individīda e-iekļautības prognozēšanai izmantotie klasifikācijas algoritmi.....	114
3.21. tabula. Ansambļa klasifikatora veikspējas rādītāji dažādām modeļu kombinācijām.....	123
4.1. tabula. E-iekļaušanu prognozējošās sistēmas mērķi, nosacījumi mērķa sasniegšanai.....	135
4.2. tabula. E-iekļaušanu prognozējošās sistēmas lietošanas gadījumi.....	137
4.3. tabula. E-iekļaušanu prognozējošā modeļa pārpratumu matrica: modeļa prognozes un reāli novērotā situācija par jaunapgūto prasmju lietojumu.....	150
4.4. tabula. M1, M2 un M3 modeļu prognožu salīdzinājums apmācības un testa kopām.....	154
4.5. tabula. E-iekļaušanu prognozējošā prototipa atbilstība funkcionālajām prasībām.....	154

5. pielikums

E-iekļaušanas procesus aprakstošs modelis


Kopskats

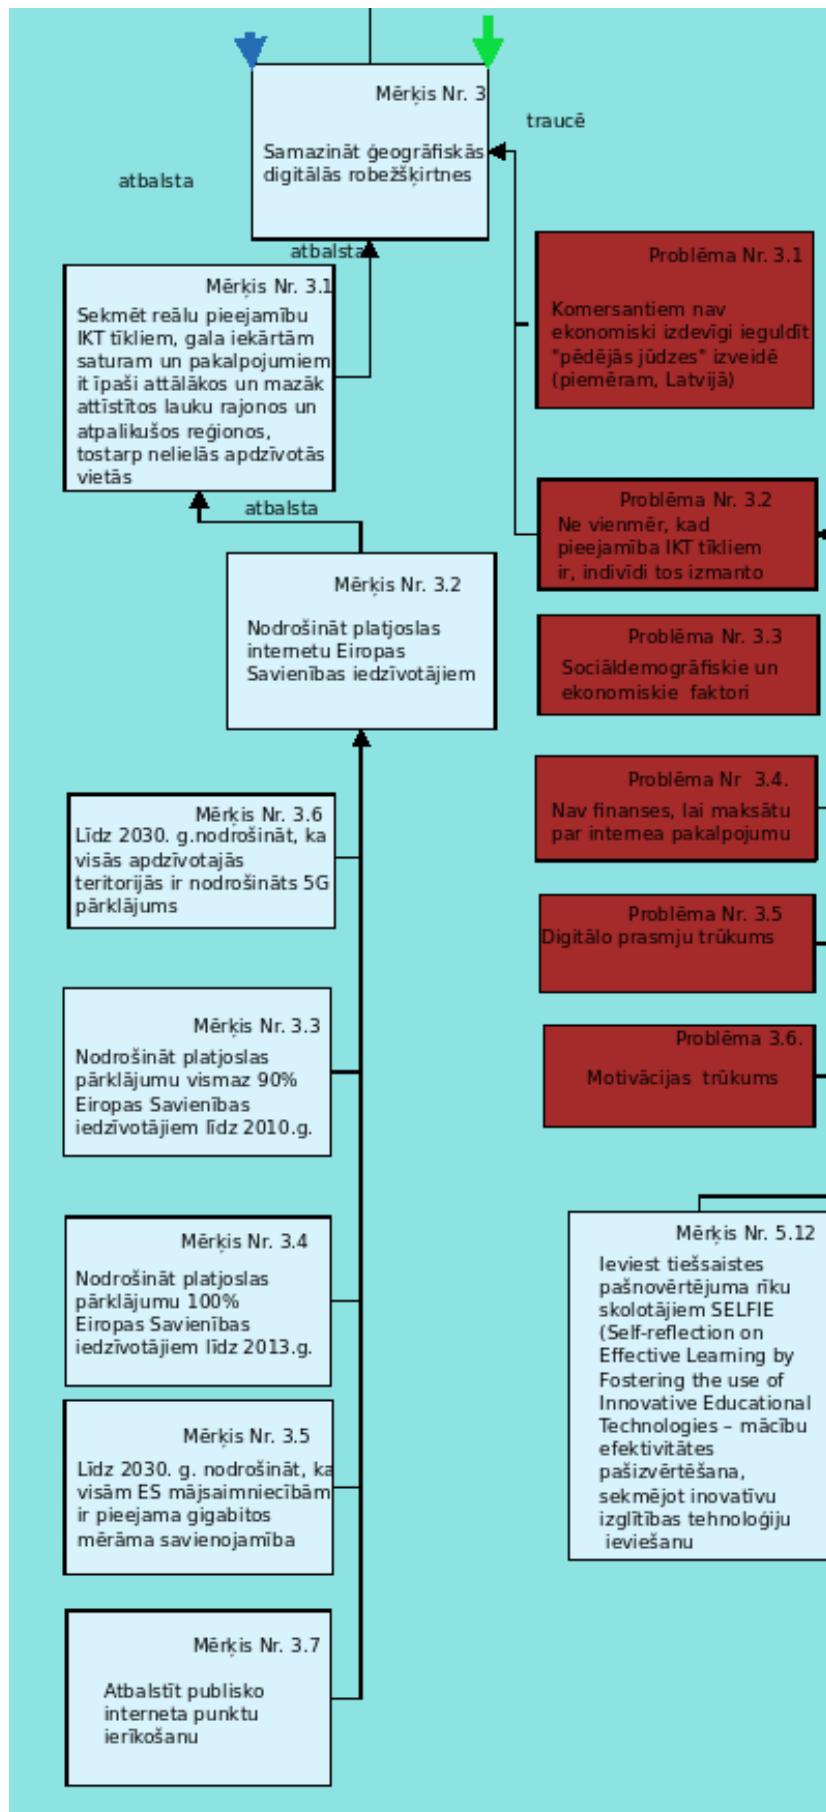



1. mērķis

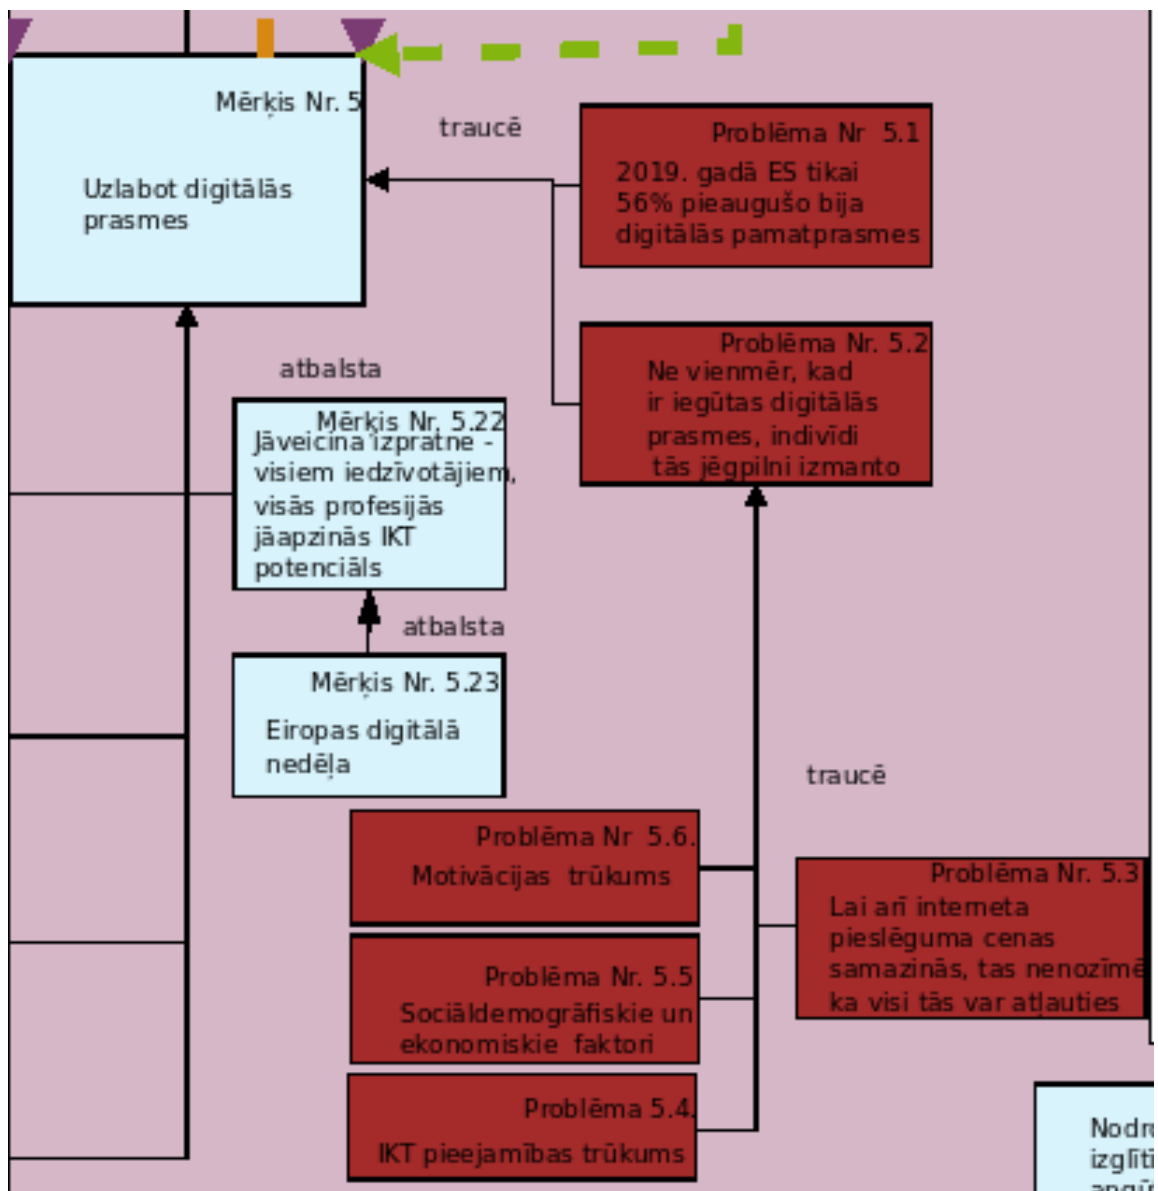
2006. gads: Samazināt atšķirības IKT lietošanā un veicināt IKT izmantošanu, lai pārvarētu atstumtību un nodrošinātu IKT lietošanu, pārvarētu izslēgšanu un uzlabotu ekonomiskos rādītājus, nodarbinātības iespējas, dzīves kvalitāti, sociālo līdzdalību un kohēziju.

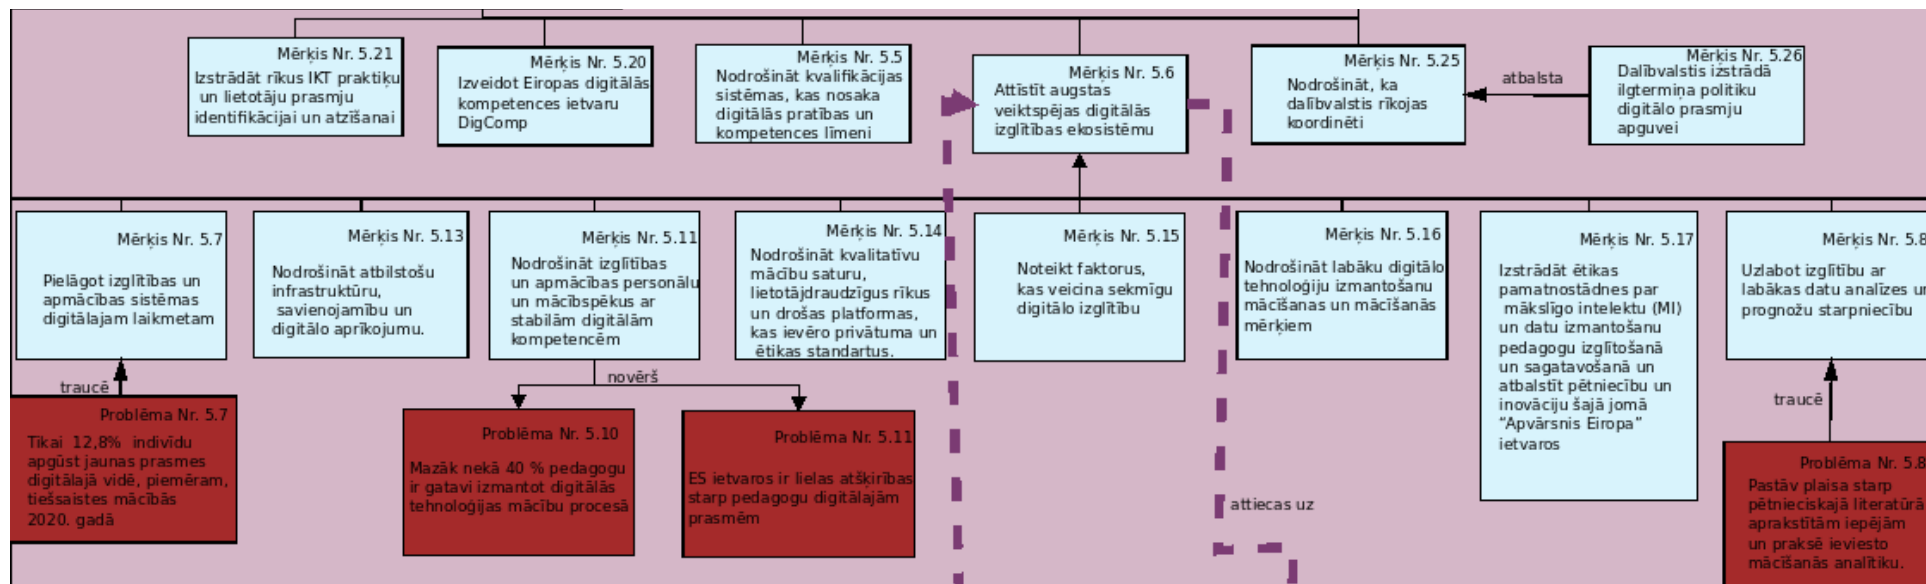
2021. gads: Nodrošināt iespēju visiem eiropiešiem pilnībā izmantot digitālās iespējas un tehnoloģijas. Digitālajā telpā ir jānodrošina, ka tās pašas tiesības, kas darbojas bezsaistē, ir pilnībā īstenojamas tiešsaistē.

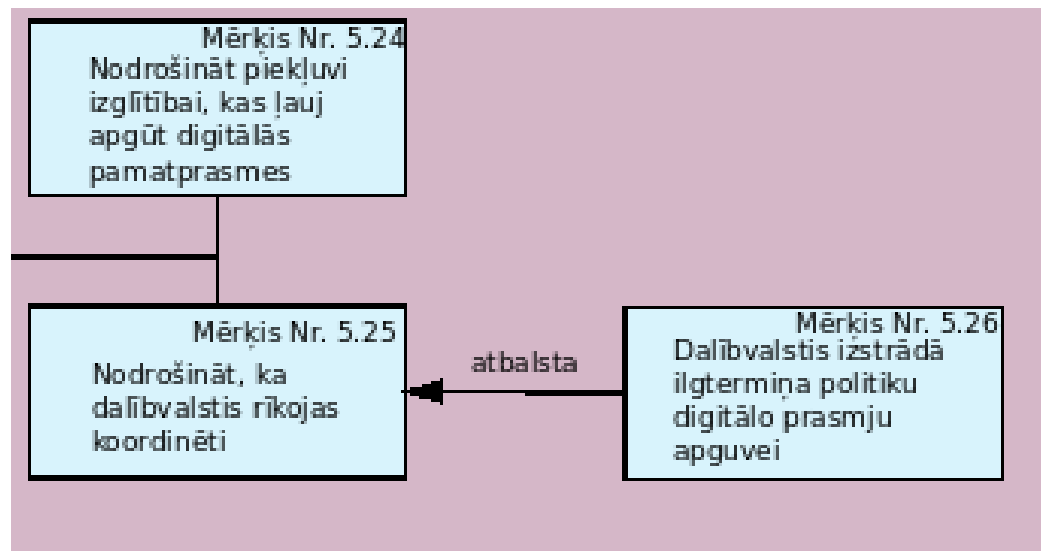
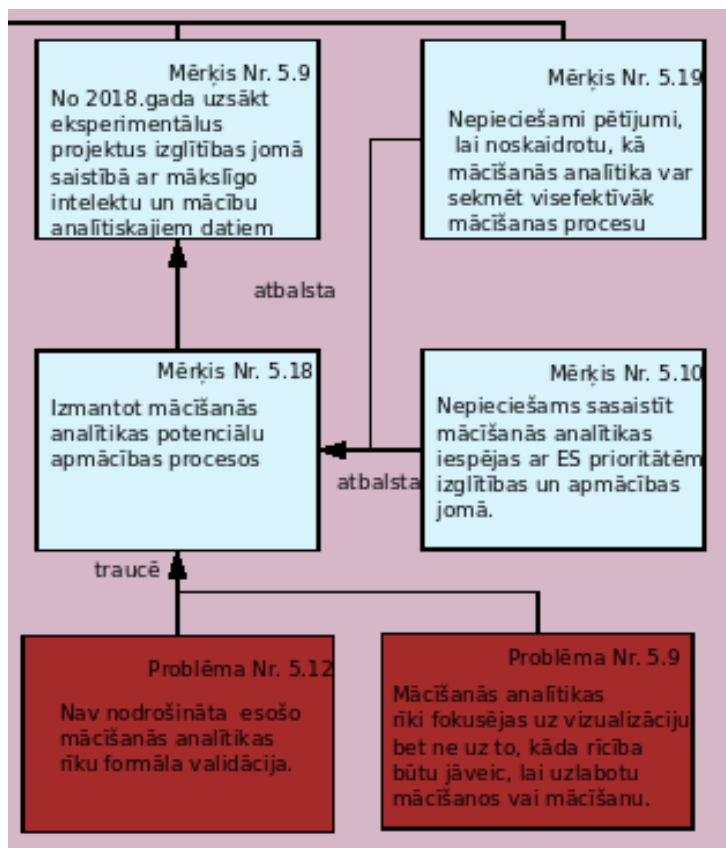


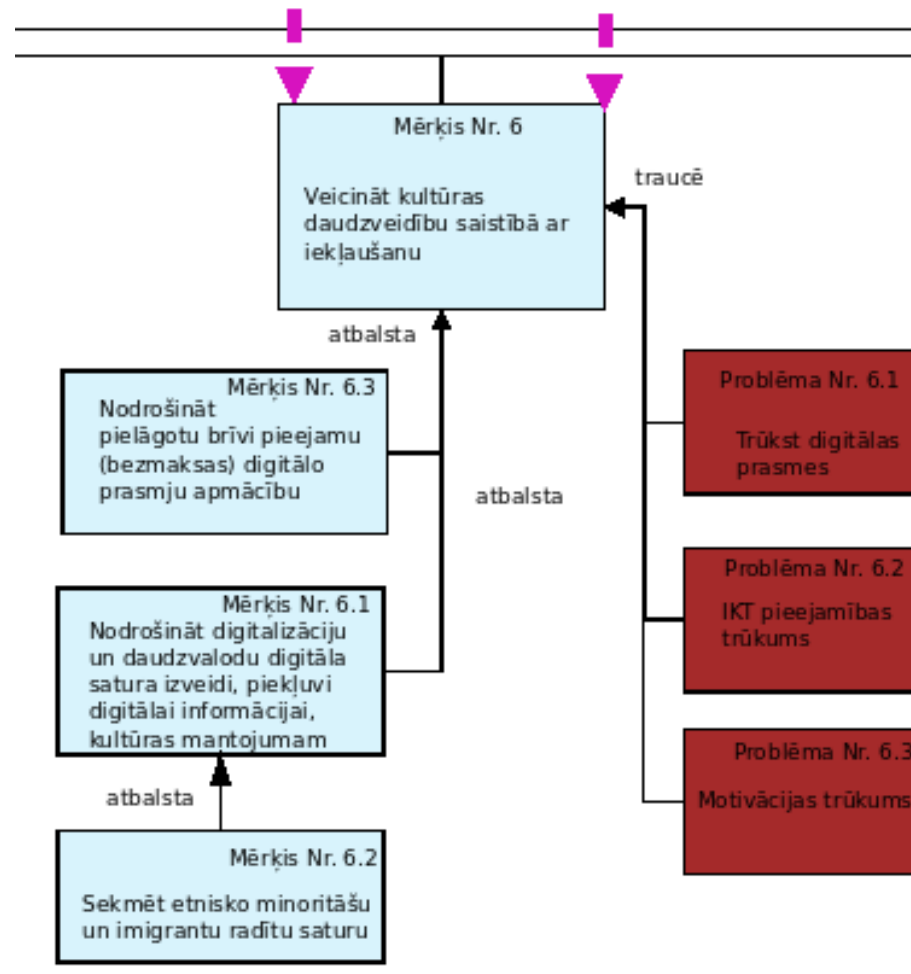


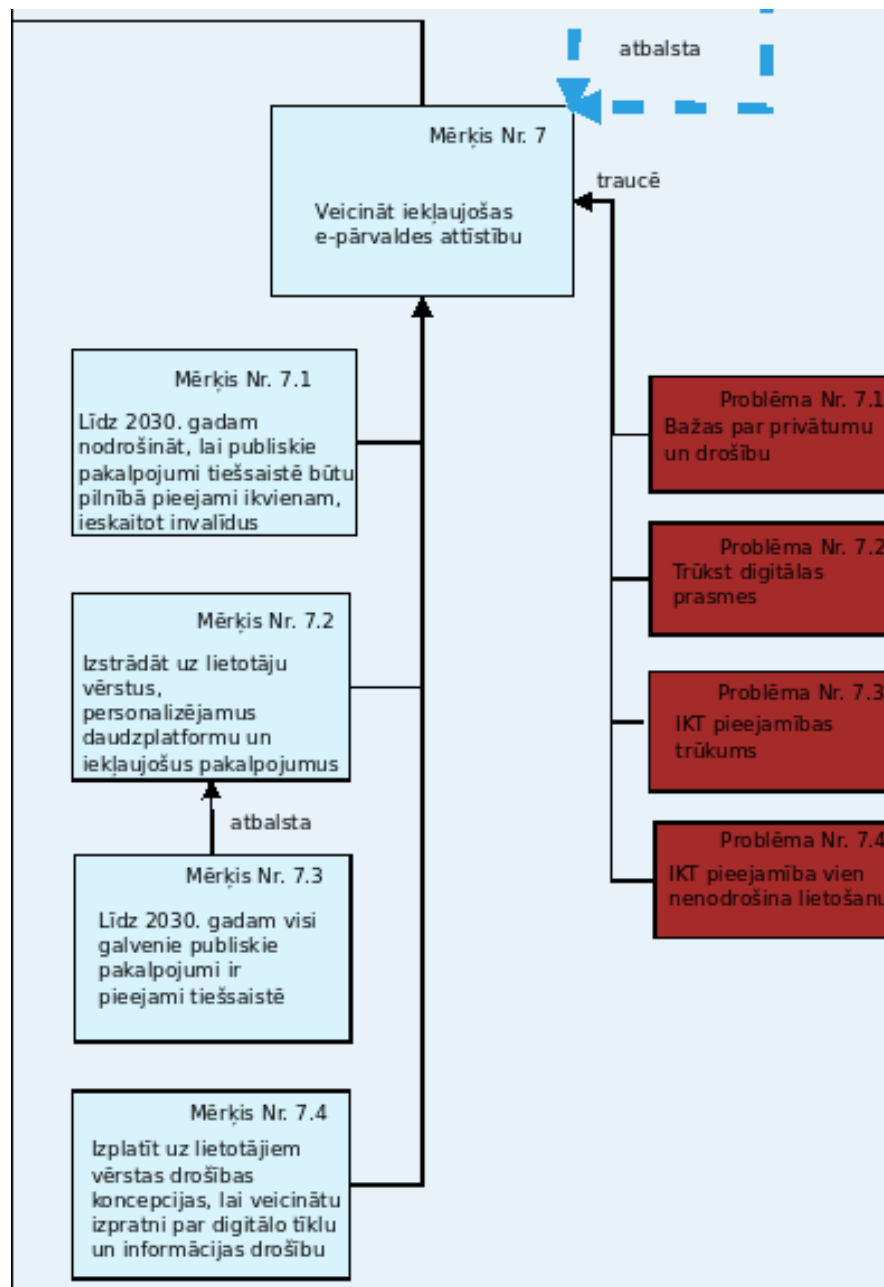




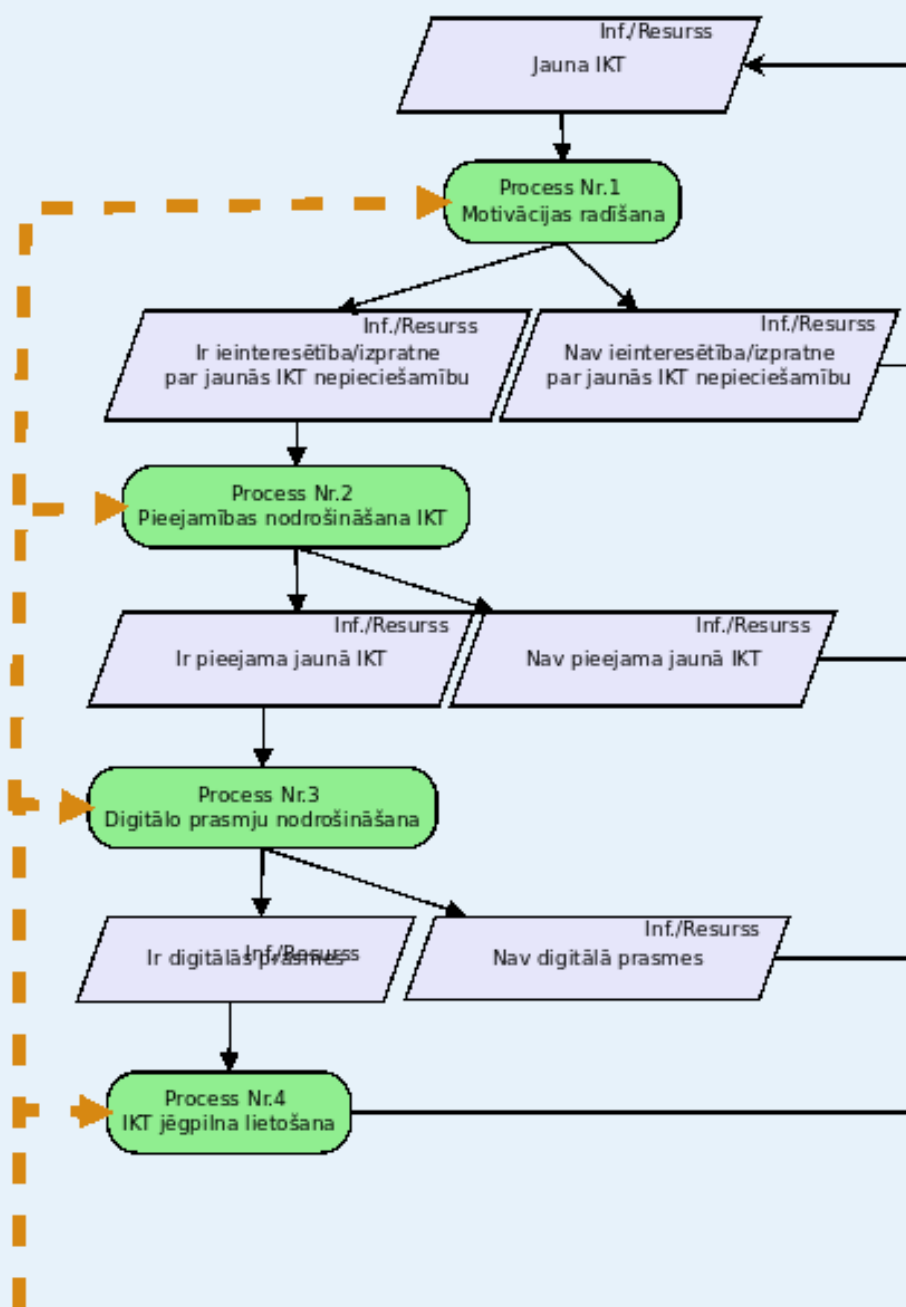




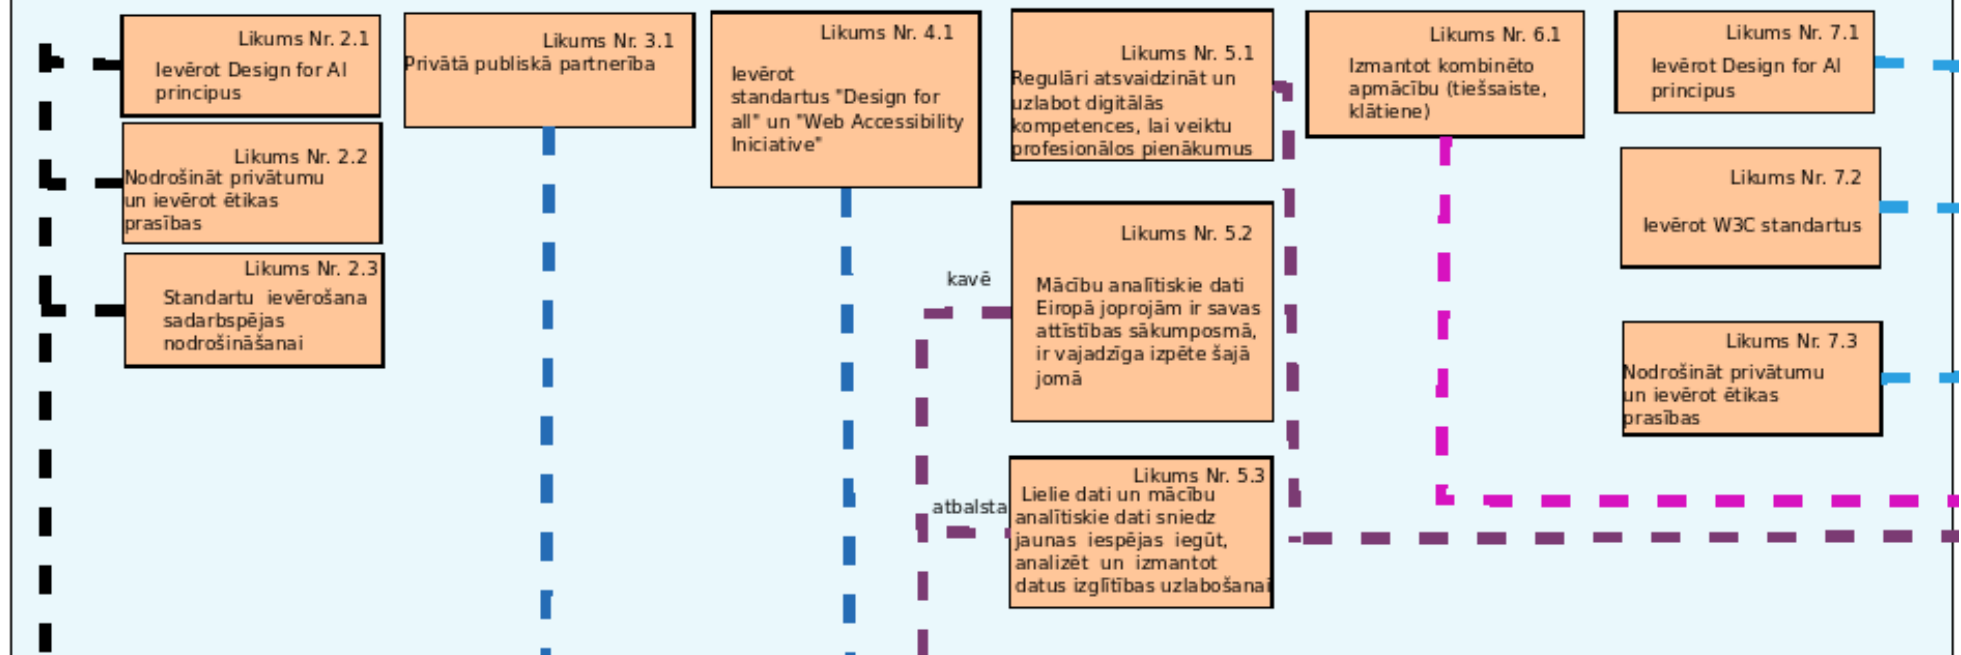




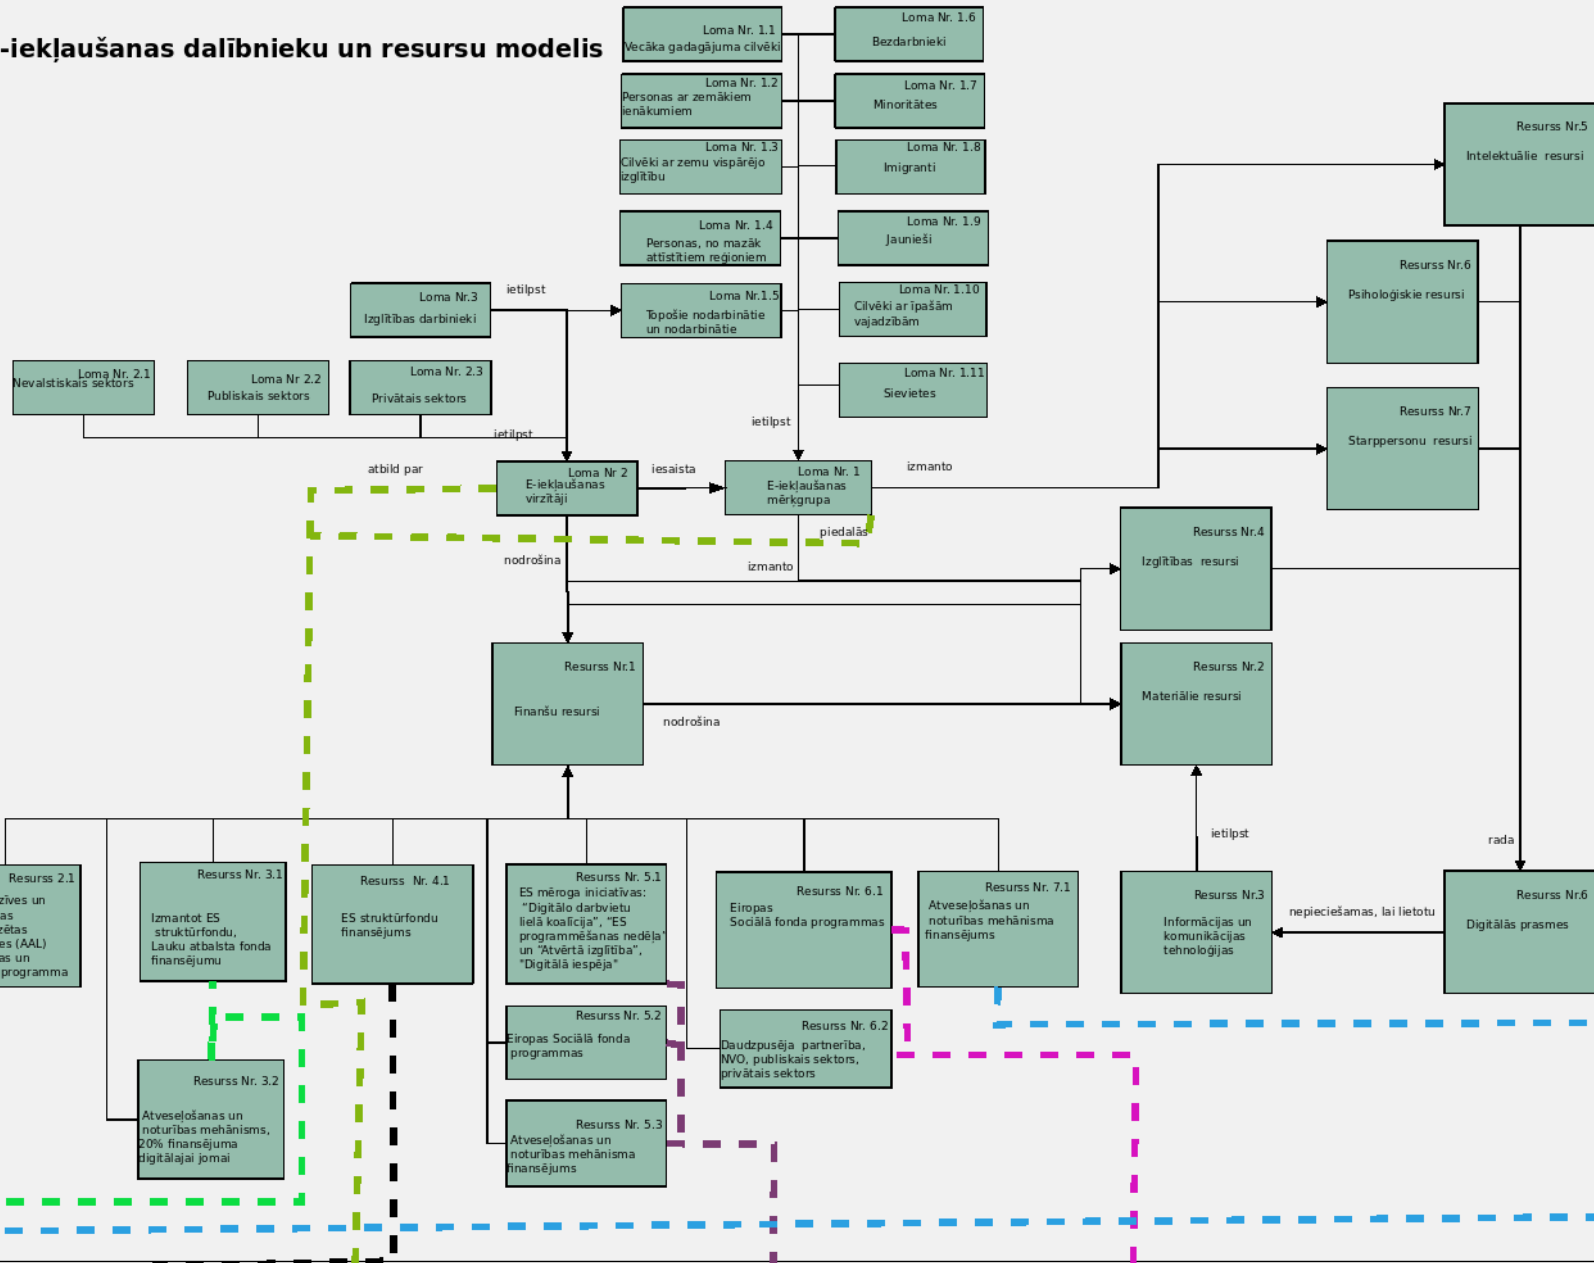
Indivīda e-iekļaušanas process




E-iekļaušanas likumu modelis



E-iekļaušanas dalībnieku un resursu modelis



Indivīda e-iekļaušanas process



6. pielikums

Pētījumos izmantoto aptaujas anketu paraugi

Telefonaptaujas jautājumi, lai novērtētu, vai studenti pēc kursa apguves izmanto jaunapgūtās digitālās prasmes

Studentiem tiek piedāvātas trīs iespējamās atbildes par katru no kursā apgūtajām tēmām:

- a. Nē, neesmu vispār izmantojis/usi ar šo tēmu saistītas prasmes.
- b. Nē, bet izmantoju prasmes tādā pašā līmenī kā pirms kursa apguves.
- c. Jā, izmantoju jaunapgūtās prasmes.

Apgalvojumi:

1. Tēmā "Perifērijas iekārtu pieslēgšana" apgūto esmu izmantojis/usi praktiski personiskām vai profesionālām vajadzībām.
2. Tēmā "Darbs ar skeneri" apgūto esmu izmantojis/usi praktiski personiskām vai profesionālām vajadzībām.
3. Tēmā "E-pasta izmantošana" apgūto esmu izmantojis/usi praktiski personiskām vai profesionālām vajadzībām.
4. Tēmā "Mājas lapas izveides pamati un publicēšana" apgūto esmu izmantojis/usi praktiski personiskām vai profesionālām vajadzībām.
5. Tēmā "Darbs ar PDF formāta failiem" apgūto esmu izmantojis/usi praktiski personiskām vai profesionālām vajadzībām.
6. Tēmā "Drošs darbs ar datoru" apgūto esmu izmantojis/usi praktiski personiskām vai profesionālām vajadzībām.
7. Tēmā "Iemaņas darbā ar DBVS MS Access datu bāzi" apgūto esmu izmantojis/usi praktiski personiskām vai profesionālām vajadzībām.
8. Tēmā "Video apstrāde" apgūto esmu izmantojis/usi praktiski personiskām vai profesionālām vajadzībām.
9. Tēmā "E-studiju kursi internetā pasaulē" apgūto esmu izmantojis/usi praktiski personiskām vai profesionālām vajadzībām.
10. Tēmā "Iemaņas darbā ar MS Excel" apgūto esmu izmantojis/usi praktiski personiskām vai profesionālām vajadzībām.
11. Tēmā "Sociālie tīkli" apgūto esmu izmantojis/usi praktiski personiskām vai profesionālām vajadzībām.

Aptauja pirms moduļa apguves**Informācija par kursa dalībnieku**

*1	Jūsu vecums: <input type="radio"/> -16 <input type="radio"/> 17-25 <input type="radio"/> 26-45 <input type="radio"/> 46-65 <input type="radio"/> 66-
*2	Jūsu dzimums <input type="radio"/> Sieviete <input type="radio"/> Vīrietis
Vai jūs piederat pie kādas no minētajām mērķa grupām?	
*3	Vecāki cilvēki (līdz valsts vecuma pensijas piešķiršanai nepieciešamā vecuma sasniegšanai atlikuši ne vairāk kā pieci gadi) un pensionāri <input type="radio"/> Jā <input type="radio"/> Nē
*4	Personas ar zemākiem ienākumiem (piešķirts pašvaldībā trūcīgā statuss) <input type="radio"/> Jā <input type="radio"/> Nē
*5	Cilvēki ar īpašām vajadzībām <input type="radio"/> Jā <input type="radio"/> Nē
*6	Persona no lauku rajona (problēmas ar interneta pieslēgumu) <input type="radio"/> Jā <input type="radio"/> Nē
*7	Sieviete, kas atrodas bērna kopšanas atvaļinājumā vai pēc tā <input type="radio"/> Jā <input type="radio"/> Nē
*8	Cilvēks ar zemu izglītību (piem., neiegūtu vidējo izglītību) <input type="radio"/> Jā <input type="radio"/> Nē
*9	Jūsu nodarbošanās <input type="radio"/> Izglītības nozares darbinieks <input type="radio"/> Pašvaldības darbinieks

- Valsts iestādes darbinieks
- Darbinieks privātuzņēmumā
- Uzņēmējs
- Pašnodarbināta persona
- Students
- Bezdarbnieks
- Pensionārs
- Cita nodarbošanās

Kursu vēlaties apgūt, lai

- *10 Uzlabotu savas zināšanas par informācijas tehnoloģijām, jo tas ir nepieciešams tiešajā profesionālajā darbībā (1 - nepiekrītu, 5 - piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *11 Uzlabotu zināšanas par informācijas tehnoloģijām, jo tas ir nepieciešams, lai iegūtu jaunu (labāku) darbu (1 - nepiekrītu, 5 - piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *12 Papildinātu savas zināšanas neatkarīgi no profesionālajām vajadzībām (1 - nepiekrītu, 5 - piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *13 Iegūtu apliecību/sertifikātu, lai varētu turpināt veikt savus profesionālos pienākumus (1 - nepiekrītu, 5 - piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *14 Kopā ar kolēģiem/draugiem labi pavadītu laiku (1 - nepiekrītu, 5 - piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*15 Bagātinātu pelēko ikdienu - sen neko nebijāt mācījies un pārmaiņu pēc piekritāt (1 - nepiekrītu, 5 - piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*16 Kā vienmēr kaut ko mācītos un šis ir viens no iespējamiem kursiem (1 - nepiekrītu, 5 - piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*17 Iegūtās zināšanas par informācijas tehnoloģijām izmantotu savu vaļasprieku pilnveidei (piem., informācijas meklēšanā par floristiku, tūrisma maršrutu plānošanā utml.) (1 - nepiekrītu, 5 - piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Datorprasmju pašvērtējums

Kuras no minētajā darbībām jūs protat veikt ar datoru?

*18 Kopēt un/vai pārvietot dokumentus/mapes

Jā Nē

*19 Rakstīt tekstus un tos labot

Jā Nē

*20 Strādāt ar elektroniskajām tabulām, lietot aritmētiskās komandas(saskaitīt, atņemt, reizināt, dalīt)

Jā Nē

*21 Saspiest/ arhivēt dokumentus

Jā Nē

*22 Pievienot/instalēt jaunas iekārtas (piemēram, printeris, skeneris)

Jā Nē

*23	Programmēt, izmantojot specializētas programmēšanas valodas
<input type="radio"/> Jā <input type="radio"/> Nē	
Interneta prasmju pašvērtējums	
Kuras no minētajām darbībām jūs protat veikt Internetā?	
*24	Meklēt informāciju ar meklēšanas programmu (Google, Yahoo, u.c.)
<input type="radio"/> Jā <input type="radio"/> Nē	
*25	Nosūtīt e-pastu ar pievienotiem failiem/dokumentiem
<input type="radio"/> Jā <input type="radio"/> Nē	
*26	Sūtīt ziņojumus izmantojot ziņu grupas vai tiešsaistes forumus
<input type="radio"/> Jā <input type="radio"/> Nē	
*27	Veikt balss zvanus (izmantojot Skype, Messenger, u.c.)
<input type="radio"/> Jā <input type="radio"/> Nē	
*28	Izmantot koplietošanas failus /dokumentus un/vai apmainīties ar mūzikas, video failiem, filmām u.c.
<input type="radio"/> Jā <input type="radio"/> Nē	
*29	Izveidot mājas lapu vai emuāru (izmantojot Windows Live, WordPress, Dreamweaver, u.c.)
<input type="radio"/> Jā <input type="radio"/> Nē	

Aptauja pirms tēmas apguves: Darbs ar fotoattēliem

*1 Es protu raksturot attēlu uz datora ekrāna un to saglabāt (no 1-neprotu līdz 5-teicami protu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*2 Es protu pārnest attēlu no ārējām iekārtām (no 1-neprotu līdz 5-teicami protu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*3 Es protu izvēlēties attēla apstrādes programmatūru (no 1-neprotu līdz 5-teicami protu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*4 Es protu atvērt savu attēlu apstrādes programmatūrā (no 1-neprotu līdz 5-teicami protu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*5 Es protu mainīt attēla izmēru, apjomu, krāsas, kontrastu (no 1-neprotu līdz 5-teicami protu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*6 Es protu saglabāt attēlu izvēlētajā formātā (no 1-neprotu līdz 5-teicami protu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*7 Es protu ievietot attēlu citos dokumentos (no 1-neprotu līdz 5-teicami protu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

8	Es sagaidu no tēmas "Darbs ar fotoattēliem"...
<input type="text"/>	

Aptauja pēc tēmas apguves: Darbs ar fotoattēliem**Prasmju pašvērtējums pēc tēmas apguves:**

- *1 Es protu raksturot attēlu uz datora ekrāna un to saglabāt (no 1-neprotu līdz 5-teicami protu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *2 Es protu pārnest attēlu no ārējām iekārtām (no 1-neprotu līdz 5-teicami protu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *3 Es protu izvēlēties attēla apstrādes programmatūru (no 1-neprotu līdz 5-teicami protu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *4 Es protu atvērt savu attēlu apstrādes programmatūrā (no 1-neprotu līdz 5-teicami protu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *5 Es protu mainīt attēla izmēru, apjomu, krāsas, kontrastu (no 1-neprotu līdz 5-teicami protu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *6 Es protu saglabāt attēlu izvēlētajā formātā (no 1-neprotu līdz 5-teicami protu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *7 Es protu ievietot attēlu citos dokumentos (no 1-neprotu līdz 5-teicami protu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Tēmas materiālu novērtējums:

*8	Celvedis bija noderīgs mācību materiāla tēmu labākai izpratnei (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)										
1-5	<table border="1"><tr><td>1</td><td>2</td><td>3</td><td>4</td><td>5</td></tr><tr><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td></tr></table>	1	2	3	4	5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
1	2	3	4	5							
<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>							
*9	Video mācību materiāls bija labi izplānots un noderīgs (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)										
1-5	<table border="1"><tr><td>1</td><td>2</td><td>3</td><td>4</td><td>5</td></tr><tr><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td></tr></table>	1	2	3	4	5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
1	2	3	4	5							
<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>							
*10	Teksta mācību materiāls ar attēliem bija labi izplānots un noderīgs (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)										
1-5	<table border="1"><tr><td>1</td><td>2</td><td>3</td><td>4</td><td>5</td></tr><tr><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td></tr></table>	1	2	3	4	5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
1	2	3	4	5							
<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>							
*11	Patstāvīgā darba uzdevumi un vingrinājums bija labi izplānoti un noderīgi (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)										
1-5	<table border="1"><tr><td>1</td><td>2</td><td>3</td><td>4</td><td>5</td></tr><tr><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td></tr></table>	1	2	3	4	5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
1	2	3	4	5							
<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>							
*12	Tests bija atbilstošs mācību materiāla tēmai un noderīgs (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)										
1-5	<table border="1"><tr><td>1</td><td>2</td><td>3</td><td>4</td><td>5</td></tr><tr><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td></tr></table>	1	2	3	4	5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
1	2	3	4	5							
<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>							
*13	Materiālos vajadzētu iekļaut mazāk/vairāk teoriju (1-mazāk, 2-nemainīt, 3-vairāk)										
1-3	<table border="1"><tr><td>1</td><td>2</td><td>3</td></tr><tr><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td></tr></table>	1	2	3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>				
1	2	3									
<input type="radio"/>	<input type="radio"/>	<input type="radio"/>									
*14	Materiālos vajadzētu iekļaut mazāk/vairāk vingrinājumus/uzdevumus (1-mazāk, 2-nemainīt, 3-vairāk)										
1-3	<table border="1"><tr><td>1</td><td>2</td><td>3</td></tr><tr><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td></tr></table>	1	2	3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>				
1	2	3									
<input type="radio"/>	<input type="radio"/>	<input type="radio"/>									
*15	Materiālos vajadzētu iekļaut mazāk/vairāk testa jautājumus (1-mazāk, 2-nemainīt, 3-vairāk)										
1-3	<table border="1"><tr><td>1</td><td>2</td><td>3</td></tr><tr><td><input type="radio"/></td><td><input type="radio"/></td><td><input type="radio"/></td></tr></table>	1	2	3	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>				
1	2	3									
<input type="radio"/>	<input type="radio"/>	<input type="radio"/>									

16 Apgūstot tēmu "Darbs ar fotoattēliem", ieguvu jaunas zināšanas par ...

Aptauja pēc moduļa apguves**Pasniedzēja, e-vides un kursa norises novērtējums**

- *1 Pasniedzējs (instruktors) bija ziņošs un izpalīdzīgs (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *2 E-vides navigācija (iespēja atrast nepieciešamos materiālus) bija labi izplānota un viegli saprotama (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *3 Apmācību temps bija pārāk ātrs/pārāk lēns (no 1-pārāk ātrs līdz 5-pārāk lēns)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *4 Norādītie mērķi katras tēmas sākumā man palīdzēja labāk apgūt mācību vielu (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Tēmu aktualitātes novērtējums

- *5 Tēmā "Perifērijas iekārtu pieslēgšana" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *6 Tēmā "Darbs ar skeneri" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

- *7 Tēmā "Meklēšanas programmas" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*8 Tēmā "Darbs ar fotoattēliem" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*9 Tēmā "Elektroniskās kartes" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*10 Tēmā "E-pasta izmantošana" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*11 Tēmā "Mājas lapas izveides pamati un publicēšana" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*12 Tēmā "Objektu ievietošana mājas lapā un formatešana" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*13 Tēmā "Darbs ar PDF formāta failiem" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

*14 Tēmā "Drošs darbs ar datoru" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

***15** Tēmā "Iemaņas darbā ar DBVS MS Access datu bāzi" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

***16** Tēmā "Video apstrāde" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

***17** Tēmā "E-studiju kursi internetā pasaulē" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

***18** Tēmā "Iemaņas darbā ar MS Excel" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

***19** Tēmā "Sociālie tīkli" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

***20** Tēmā "E-komercija" apgūto domāju izmantot praktiski personiskām vai profesionālām vajadzībām (no 1-pilnīgi nepiekrītu līdz 5-tiešām piekrītu)

	1	2	3	4	5
1-5	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

21	Lūdzu ierakstiet, kādas tēmas Jums pietrūka
<input type="text"/>	
Papildus ierosinājumi kursa pilnveidei	
22	Vai Jums ir vēl kādi komentāri, ierosinājumi?
<input type="text"/>	

7. pielikums

Indivīdu raksturojošo pazīmju atbilstības normālsadalījumam pārbaude

Piemēri mainīgo *SWL* – Studenta vēlme mācīties un *SAL* – Studenta spējas mācīties atbilstībai normālsadalījumam, izmantojot Kolmogorova-Smirnova testu *SPSS* programmatūrā.

One-Sample Kolmogorov-Smirnov Test

		SWL	SAL	
N		71	71	
Normal Parameters ^{a,b}	Mean	3,6813380281690	52,172928104761	
	Std. Deviation	,75822535179498	33,967012625661	
Most Extreme Differences	Absolute	,059	,090	
	Positive	,051	,083	
	Negative	-,059	-,090	
Test Statistic		,059	,090	
Asymp. Sig. (2-tailed) ^c		,200 ^d	,200 ^d	
Monte Carlo Sig. (2-tailed) ^e	Sig.	,778	,158	
	99% Confidence Interval	Lower Bound	,768	,148
		Upper Bound	,789	,167

Piemēri, ka mainīgo *ELM* – E-materiālu, *IWS* – Instruktoru vēlme dalīties ar zināšanām sadalījums neatbilst normālsadalījumam, izmantojot Kolmogorova-Smirnova testu *SPSS* programmatūrā.

One-Sample Kolmogorov-Smirnov Test

		ELM	IWS	
N		71	71	
Normal Parameters ^{a,b}	Mean	4,08169014084507	4,59154929577464	
	Std. Deviation	,874121576891406	,785174499053416	
Most Extreme Differences	Absolute	,153	,417	
	Positive	,147	,301	
	Negative	-,153	-,417	
Test Statistic		,153	,417	
Asymp. Sig. (2-tailed) ^c		<,001	<,001	
Monte Carlo Sig. (2-tailed) ^e	Sig.	<,001	,000	
	99% Confidence Interval	Lower Bound	,000	,000
		Upper Bound	,001	,000

Piemēri, ka mainīgo ELE – E-mācību vide, PU – Prognozētā digitālo prasmju lietošana sadalījums neatbilst normālsadalījumam, izmantojot Kolmogorova-Smirnova testu SPSS programmatūrā.

One-Sample Kolmogorov-Smirnov Test

		ELE	PU	
N		71	71	
Normal Parameters ^{a,b}	Mean	3,6666666666666666	3,97183098591549	
	Std. Deviation	,939435832050103	1,13353846725219	
Most Extreme Differences	Absolute	,132	,283	
	Positive	,078	,182	
	Negative	-,132	-,283	
Test Statistic		,132	,283	
Asymp. Sig. (2-tailed) ^c		,004	<,001	
Monte Carlo Sig. (2-tailed) ^e	Sig.	,003	,000	
	99% Confidence Interval	Lower Bound	,002	,000
		Upper Bound	,005	,000

Piemēri, ka mainīgo OU – Novērotā digitālo prasmju lietošana, PUOU – iespējamā digitālo prasmju lietošana sadalījums neatbilst normālsadalījumam, izmantojot Kolmogorova-Smirnova testu SPSS programmatūrā.

One-Sample Kolmogorov-Smirnov Test

		OU	PUOU	
N		71	71	
Normal Parameters ^{a,b}	Mean	3,0000000000000000	4,97	
	Std. Deviation	1,69030850945703	1,639	
Most Extreme Differences	Absolute	,234	,200	
	Positive	,234	,146	
	Negative	-,234	-,200	
Test Statistic		,234	,200	
Asymp. Sig. (2-tailed) ^c		<,001	<,001	
Monte Carlo Sig. (2-tailed) ^e	Sig.	,000	,000	
	99% Confidence Interval	Lower Bound	,000	,000
		Upper Bound	,000	,000

a. Test distribution is Normal.

b. Calculated from data.

c. Lilliefors Significance Correction.

d. This is a lower bound of the true significance.

e. Lilliefors' method based on 10000 Monte Carlo samples with starting seed 205597102.

Piemērs. Mainīgais SAL – Studenta spējas mācīties tēmā *Drošs darbs ar datoru*: Atbilstība hī-kvadrāta kritērijam atbilstības pārbaudei normālam sadalījumam statistikas datu apstrādes datorprogrammā EasyFit Professional

Goodness of Fit - Summary

#	Distribution	Chi-Squared	
		Statistic	Rank
1	Beta	25,949	16
2	Burr	61,507	38
3	Burr	61,489	37
4	Cauchy	4,796	2
5	Chi-Squared	91,597	49
6	Chi-Squared	70,149	47
7	Dagum	66,734	45
8	Dagum	57,437	29
9	Erlang	53,169	28
10	Erlang	75,754	48
11	Error	8,559	6
12	Error Function	161,6	53
13	Exponential	46,081	26
14	Exponential (2P)	46,081	25
15	Fatigue Life	58,783	31
16	Fatigue Life	58,783	32
17	Frechet	68,001	46
18	Frechet	29,863	17
19	Gamma	61,113	35
20	Gamma	35,407	20
21	Gen. Extreme Value	8,1015	4
22	Gen. Gamma	58,638	30
23	Gen. Gamma	98,102	50
24	Gen. Pareto	9,0887	8
25	Gumbel Max	21,298	14
26	Gumbel Min	3,8625	1
27	Hypersecant	11,37	10
28	Inv. Gaussian	62,507	40
29	Inv. Gaussian	43,621	24
30	Johnson SB	9,3174	9
31	Kumaraswamy	N/A	
32	Laplace	11,431	11
33	Levy	101,2	52
34	Levy	101,2	51
35	Log-Logistic	31,502	18
36	Log-Logistic	62,331	39
37	Logistic	9,0419	7
38	Lognormal	62,572	41
39	Lognormal	62,573	42
40	Nakagami	25,728	15
41	Normal	8,3454	5

42	Pareto 2	17,304	12
43	Pearson 5	64,34	43
44	Pearson 5	64,34	44
45	Pearson 6	60,948	33
46	Pearson 6	60,962	34
47	Pert	36,491	22
48	Power Function	N/A	
49	Rayleigh	32,673	19
50	Rayleigh	39,037	23
51	Rice	50,519	27
52	Student's t	18,899	13
53	Uniform	7,1996	3
54	Weibull	35,65	21
55	Weibull	61,469	36
56	Johnson SU	No fit	
57	Log-Gamma	No fit	
58	Log-Pearson 3	No fit	
59	Pareto	No fit	
60	Reciprocal	No fit	
61	Triangular	No fit	

Goodness of Fit - Details

[top\]](#)

Normal [#41]					
Chi-Squared					
Deg. of freedom	5				
Statistic	8,3454				
P-Value	0,1382				
Rank	5				
a	0,2	0,1	0,05	0,02	0,01
Critical Value	7,2893	9,2364	11,07	13,388	15,086
Reject?	Yes	No	No	No	No

[\[top\]](#)

Piemērs. Mainīgais ELM – studenta vērtējums mācību materiālu piemērotībai tēmai *Videoapstrāde*
 Atbilstība hī-kvadrāta kritērijam atbilstības pārbaudei normālam sadalījumam statistikas datu
 apstrādes datorprogrammā EasyFit Professional.

Goodness of Fit - Summary

#	Distribution	Chi-Squared	
		Statistic	Rank
1	Beta	N/A	
2	Burr	8,3605	16
3	Burr (4P)	10,555	18
4	Cauchy	6,9052	7
5	Chi-Squared	39,791	49
6	Chi-Squared (2P)	26,386	42
7	Dagum	N/A	
8	Dagum (4P)	17,785	36
9	Erlang	18,266	37
10	Erlang (3P)	13,484	25
11	Error	21,586	39
12	Error Function	N/A	
13	Exponential	71,515	52
14	Exponential (2P)	30,339	44
15	Fatigue Life	14,12	28
16	Fatigue Life (3P)	7,8085	13
17	Frechet	7,491	9
18	Frechet (3P)	14,977	30
19	Gamma	12,017	22
20	Gamma (3P)	13,579	26
21	Gen. Extreme Value	4,5984	5
22	Gen. Gamma	11,147	20
23	Gen. Gamma (4P)	7,6891	10
24	Gen. Pareto	N/A	
25	Gumbel Max	12,925	23
26	Gumbel Min	24,688	41
27	Hypersecant	30,578	45
28	Inv. Gaussian	13,25	24
29	Inv. Gaussian (3P)	7,8531	15
30	Johnson SB	2,7727	1
31	Kumaraswamy	N/A	
32	Laplace	30,883	46
33	Levy	70,041	51
34	Levy (2P)	34,855	47
35	Log-Gamma	15,606	33
36	Log-Logistic	15,238	31
37	Log-Logistic (3P)	6,6599	6
38	Log-Pearson 3	7,0383	8
39	Logistic	14,717	29
40	Lognormal	15,94	35
41	Lognormal (3P)	7,8145	14
42	Nakagami	15,673	34
43	Normal	7,7022	11
44	Pareto	36,812	48

45	Pareto 2	72,081	53
46	Pearson 5	15,255	32
47	Pearson 5 (3P)	13,879	27
48	Pearson 6	11,511	21
49	Pearson 6 (4P)	7,7251	12
50	Pert	30,308	43
51	Power Function	9,1373	17
52	Rayleigh	20,117	38
53	Rayleigh (2P)	3,7456	4
54	Reciprocal	69,012	50
55	Rice	24,373	40
56	Triangular	3,3548	3
57	Uniform	N/A	
58	Weibull	2,8549	2
59	Weibull (3P)	10,557	19
60	Johnson SU	No fit	
61	Student's t	No fit	

Goodness of Fit - Details

Normal [#43]					
Chi-Squared					
Deg. of freedom	4				
Statistic	7,7022				
P-Value	0,10312				
Rank	11				
a	0,2	0,1	0,05	0,02	0,01
Critical Value	5,9886	7,7794	9,4877	11,668	13,277
Reject?	Yes	No	No	No	No

[\[top\]](#)

Piemērs. Mainīgais ELE – E-mācību materiāli tēmā *Skeneris*: Atbilstība hī-kvadrāta kritērijam atbilstības pārbaudei normālam sadalījumam statistikas datu apstrādes datorprogrammā EasyFit Professional

Goodness of Fit - Summary

#	Distribution	Chi-Squared	
		Statistic	Rank
1	Beta	12,558	31
2	Burr	8,9199	20
3	Burr (4P)	8,8975	18
4	Cauchy	3,4737	5
5	Chi-Squared	70,046	52
6	Chi-Squared (2P)	42,867	49
7	Dagum	9,1499	22
8	Dagum (4P)	N/A	
9	Erlang	7,4797	12
10	Erlang (3P)	36,325	45
11	Error	7,6882	13
12	Error Function	N/A	
13	Exponential	92,37	53
14	Exponential (2P)	18,514	38
15	Fatigue Life	3,9202	7
16	Fatigue Life (3P)	9,4222	25
17	Frechet	15,446	35
18	Frechet (3P)	2,6078	1
19	Gamma	5,9004	10
20	Gamma (3P)	36,411	46
21	Gen. Extreme Value	9,1698	23
22	Gen. Gamma	5,0606	8
23	Gen. Gamma (4P)	9,05	21
24	Gen. Pareto	N/A	
25	Gumbel Max	17,154	36
26	Gumbel Min	5,2038	9
27	Hypersecant	14,481	32
28	Inv. Gaussian	38,644	47
29	Inv. Gaussian (3P)	9,5879	28
30	Johnson SB	8,7618	17
31	Kumaraswamy	62,736	50
32	Laplace	17,947	37
33	Levy	149,0	55
34	Levy (2P)	21,145	39
35	Log-Gamma	3,4176	4
36	Log-Logistic	3,368	3
37	Log-Logistic (3P)	8,0553	15
38	Log-Pearson 3	9,3017	24
39	Logistic	14,532	33
40	Lognormal	3,8805	6
41	Lognormal (3P)	9,6065	29
42	Nakagami	35,233	43
43	Normal	9,4902	26

44	Pareto	29,039	41
45	Pareto 2	93,285	54
46	Pearson 5	2,912	2
47	Pearson 5 (3P)	35,764	44
48	Pearson 6	6,0523	11
49	Pearson 6 (4P)	9,5244	27
50	Pert	8,0941	16
51	Power Function	29,444	42
52	Rayleigh	65,251	51
53	Rayleigh (2P)	15,229	34
54	Reciprocal	40,585	48
55	Rice	23,503	40
56	Triangular	7,8979	14
57	Uniform	N/A	
58	Weibull	9,982	30
59	Weibull (3P)	8,8982	19
60	Johnson SU	No fit	
61	Student's t	No fit	

Goodness of Fit - Details

[\[top\]](#)

Normal [#43]					
Chi-Squared					
Deg. of freedom	6				
Statistic	9,4902				
P-Value	0,14783				
Rank	26				
a	0,2	0,1	0,05	0,02	0,01
Critical Value	8,5581	10,645	12,592	15,033	16,812
Reject?	Yes	No	No	No	No

[\[top\]](#)

Piemērs. Mainīgais IWS - Instruktora vēlme dalīties ar zināšanām tēmā *Perifērijas iekārtu pieslēgšana*: Atbilstība hī-kvadrāta kritērijam atbilstības pārbaudei normālam sadalījumam statistikas datu apstrādes datorprogrammā EasyFit Professional

Goodness of Fit - Summary

#	Distribution	Chi-Squared	
		Statistic	Rank
1	Beta	N/A	
2	Burr	1,2522	5
3	Burr (4P)	18,086	39
4	Chi-Squared	56,108	49
5	Chi-Squared (2P)	30,447	45
6	Dagum	N/A	
7	Dagum (4P)	12,407	36
8	Erlang	2,8119	22
9	Erlang (3P)	1,5652	11
10	Error	1,0241	2
11	Error Function	N/A	
12	Exponential	62,828	50
13	Exponential (2P)	49,416	48
14	Fatigue Life	18,718	41
15	Fatigue Life (3P)	1,622	13
16	Frechet	33,035	47
17	Frechet (3P)	5,0536	23
18	Gamma	1,9602	16
19	Gamma (3P)	1,4723	9
20	Gen. Extreme Value	2,3053	19
21	Gen. Gamma	9,3713	31
22	Gen. Gamma (4P)	1,3057	7
23	Gen. Pareto	6,2418	25
24	Gumbel Max	2,6839	20
25	Gumbel Min	1,0974	4
26	Hypersecant	2,2796	18
27	Inv. Gaussian	1,563	10
28	Inv. Gaussian (3P)	1,6898	15
29	Johnson SB	5,7086	24
30	Kumaraswamy	7,2292	27
31	Laplace	1,0241	1
32	Levy	25,895	44
33	Levy (2P)	21,651	42
34	Log-Gamma	9,603	32
35	Log-Logistic	14,958	37
36	Log-Logistic (3P)	2,7771	21
37	Log-Pearson 3	7,2516	28
38	Logistic	1,9974	17
39	Lognormal	8,6358	29
40	Lognormal (3P)	1,586	12
41	Nakagami	1,2807	6
42	Normal	1,669	14
43	Pareto	74,566	52
44	Pareto 2	65,726	51

45	Pearson 5	16,693	38
46	Pearson 5 (3P)	8,8452	30
47	Pearson 6	10,402	34
48	Pearson 6 (4P)	1,4629	8
49	Pert	1,0929	3
50	Power Function	7,1962	26
51	Rayleigh	30,517	46
52	Rayleigh (2P)	22,66	43
53	Reciprocal	156,61	54
54	Rice	10,524	35
55	Triangular	93,53	53
56	Uniform	N/A	
57	Weibull	9,6073	33
58	Weibull (3P)	18,112	40
59	Cauchy	No fit	
60	Johnson SU	No fit	
61	Student's t	No fit	

Goodness of Fit - Details

Normal [#42]					
Chi-Squared					
Deg. of freedom	2				
Statistic	1,669				
P-Value	0,43408				
Rank	14				
a	0,2	0,1	0,05	0,02	0,01
Critical Value	3,2189	4,6052	5,9915	7,824	9,2103
Reject?	No	No	No	No	No

[\[top\]](#)

Piemērs. Mainīgais PU - Prognozētā prasmju lietošana tēmā *MS Access*: Atbilstība hī-kvadrāta kritērijam atbilstības pārbaudei normālam sadalījumam statistikas datu apstrādes datorprogrammā EasyFit Professional

Goodness of Fit - Summary

#	Distribution	Chi-Squared	
		Statistic	Rank
1	Beta	21,899	46
2	Burr	6,5158	38
3	Burr (4P)	2,6663	12
4	Cauchy	4,5102	23
5	Chi-Squared	20,129	44
6	Chi-Squared (2P)	31,803	49
7	Dagum	N/A	
8	Dagum (4P)	34,801	50
9	Erlang	2,9642	16
10	Erlang (3P)	5,9021	31
11	Error	6,2172	37
12	Error Function	1312,8	55
13	Exponential	45,41	53
14	Exponential (2P)	6,8816	39
15	Fatigue Life	2,0054	6
16	Fatigue Life (3P)	5,8563	29
17	Frechet	1,2949	1
18	Frechet (3P)	2,3807	9
19	Gamma	3,5979	20
20	Gamma (3P)	5,9295	32
21	Gen. Extreme Value	2,9245	15
22	Gen. Gamma	1,9647	4
23	Gen. Gamma (4P)	2,8711	14
24	Gen. Pareto	N/A	
25	Gumbel Max	3,867	21
26	Gumbel Min	21,549	45
27	Hypersecant	5,9622	34
28	Inv. Gaussian	3,9016	22
29	Inv. Gaussian (3P)	5,8123	27
30	Johnson SB	3,3161	18
31	Kumaraswamy	N/A	
32	Laplace	5,9893	36
33	Levy	30,214	48
34	Levy (2P)	14,216	42
35	Log-Gamma	2,4694	10
36	Log-Logistic	3,0744	17
37	Log-Logistic (3P)	5,3993	24
38	Log-Pearson 3	23,476	47
39	Logistic	5,8926	30
40	Lognormal	2,0656	7
41	Lognormal (3P)	5,9674	35
42	Nakagami	7,472	40
43	Normal	5,8038	26
44	Pareto	43,521	52

45	Pareto 2	46,713	54
46	Pearson 5	8,4751	41
47	Pearson 5 (3P)	5,9559	33
48	Pearson 6	1,9728	5
49	Pearson 6 (4P)	5,8281	28
50	Pert	18,055	43
51	Power Function	1,6232	3
52	Rayleigh	5,5192	25
53	Rayleigh (2P)	2,1472	8
54	Reciprocal	38,851	51
55	Rice	2,6013	11
56	Student's t	1443,2	56
57	Triangular	1,3859	2
58	Uniform	N/A	
59	Weibull	3,3846	19
60	Weibull (3P)	2,6702	13
61	Johnson SU	No fit	

Goodness of Fit - Details

Normal [#43]

Chi-Squared					
Deg. of freedom	3				
Statistic	5,8038				
P-Value	0,12155				
Rank	26				
a	0,2	0,1	0,05	0,02	0,01
Critical Value	4,6416	6,2514	7,8147	9,8374	11,345
Reject?	Yes	No	No	No	No

[\[top\]](#)

Piemērs. Mainīgais OU – Novērotā prasmju lietošana tēmā *Drošs darbs ar datoru*: Atbilstība hī-kvadrāta kritērijam atbilstības pārbaudei normālam sadalījumam statistikas datu apstrādes datorprogrammā EasyFit Professional

Goodness of Fit - Summary

#	Distribution	Chi-Squared	
		Statistic	Rank
1	Beta	6,0398	34
2	Burr	5,0447	29
3	Burr (4P)	3,9601	19
4	Cauchy	3,4339	10
5	Chi-Squared	0,93868	1
6	Chi-Squared (2P)	N/A	
7	Dagum	N/A	
8	Dagum (4P)	7,945	39
9	Erlang	2,7952	7
10	Erlang (3P)	9,6659	42
11	Error	5,0072	27
12	Error Function	110,68	53
13	Exponential	4,6676	24
14	Exponential (2P)	9,4934	41
15	Fatigue Life	2,7643	6
16	Fatigue Life (3P)	2,402	3
17	Frechet	4,2937	23
18	Frechet (3P)	5,3761	31
19	Gamma	6,6281	36
20	Gamma (3P)	16,342	50
21	Gen. Extreme Value	15,695	49
22	Gen. Gamma	2,6881	5
23	Gen. Gamma (4P)	N/A	
24	Gen. Pareto	3,6217	14
25	Gumbel Max	6,5901	35
26	Gumbel Min	13,785	46
27	Hypersecant	3,4185	9
28	Inv. Gaussian	7,1572	38
29	Inv. Gaussian (3P)	4,026	20
30	Johnson SB	4,2539	22
31	Kumaraswamy	N/A	
32	Laplace	15,001	48
33	Levy	20,356	51
34	Levy (2P)	3,9049	17
35	Log-Gamma	13,558	45
36	Log-Logistic	1,397	2
37	Log-Logistic (3P)	14,081	47
38	Log-Pearson 3	5,5518	32
39	Logistic	3,5301	12
40	Lognormal	3,1506	8
41	Lognormal (3P)	3,9579	18
42	Nakagami	7,0385	37
43	Normal	3,7457	15
44	Pareto	12,765	43

45	Pareto 2	4,7958	25
46	Pearson 5	3,6183	13
47	Pearson 5 (3P)	4,0887	21
48	Pearson 6	2,495	4
49	Pearson 6 (4P)	13,377	44
50	Pert	48,832	52
51	Power Function	N/A	
52	Rayleigh	4,7976	26
53	Rayleigh (2P)	5,1883	30
54	Reciprocal	8,5339	40
55	Rice	3,8641	16
56	Student's t	163,24	54
57	Triangular	3,4477	11
58	Uniform	5,0074	28
59	Weibull	5,9958	33
60	Weibull (3P)	N/A	
61	Johnson SU	No fit	

Goodness of Fit - Details

Normal [#43]					
Chi-Squared					
Deg. of freedom	2				
Statistic	3,7457				
P-Value	0,15368				
Rank	15				
a	0,2	0,1	0,05	0,02	0,01
Critical Value	3,2189	4,6052	5,9915	7,824	9,2103
Reject?	Yes	No	No	No	No

[\[top\]](#)

Piemērs. Mainīgais PUOU – iespējamā prasmju lietošana tēmā *Video apstrāde*: Atbilstība hī-kvadrāta kritērijam atbilstības pārbaudei normālam sadalījumam statistikas datu apstrādes datorprogrammā EasyFit Professional

Goodness of Fit - Summary

#	Distribution	Chi-Squared	
		Statistic	Rank
1	Beta	2,7804	5
2	Burr	6,1391	22
3	Burr (4P)	6,8871	30
4	Cauchy	8,1302	37
5	Chi-Squared	21,283	49
6	Chi-Squared (2P)	6,6939	28
7	Dagum	N/A	
8	Dagum (4P)	2,594	4
9	Erlang	8,8583	39
10	Erlang (3P)	5,8946	21
11	Error	4,7751	12
12	Error Function	2051,9	56
13	Exponential	31,099	53
14	Exponential (2P)	6,6391	27
15	Fatigue Life	9,8699	42
16	Fatigue Life (3P)	5,8266	19
17	Frechet	7,6378	34
18	Frechet (3P)	9,1591	40
19	Gamma	6,8651	29
20	Gamma (3P)	5,8944	20
21	Gen. Extreme Value	1,6561	1
22	Gen. Gamma	6,2176	23
23	Gen. Gamma (4P)	3,6843	8
24	Gen. Pareto	3,2275	7
25	Gumbel Max	8,0998	36
26	Gumbel Min	13,494	46
27	Hypersecant	25,879	51
28	Inv. Gaussian	7,9969	35
29	Inv. Gaussian (3P)	5,7715	17
30	Johnson SB	N/A	
31	Kumaraswamy	N/A	
32	Laplace	25,522	50
33	Levy	61,96	55
34	Levy (2P)	3,8289	9
35	Log-Gamma	11,122	44
36	Log-Logistic	8,1642	38
37	Log-Logistic (3P)	4,4437	10
38	Log-Pearson 3	5,7334	15
39	Logistic	6,3386	25
40	Lognormal	9,7645	41
41	Lognormal (3P)	5,633	14
42	Nakagami	7,5548	33
43	Normal	5,6209	13

44	Pareto	12,764	45
45	Pareto 2	30,922	52
46	Pearson 5	10,086	43
47	Pearson 5 (3P)	5,7623	16
48	Pearson 6	6,3674	26
49	Pearson 6 (4P)	5,808	18
50	Pert	45,827	54
51	Power Function	2,9092	6
52	Rayleigh	2,528	3
53	Rayleigh (2P)	7,1425	32
54	Reciprocal	18,718	48
55	Rice	6,289	24
56	Student's t	2223,3	57
57	Triangular	17,531	47
58	Uniform	1,7123	2
59	Weibull	4,6582	11
60	Weibull (3P)	6,8935	31
61	Johnson SU	No fit	

Goodness of Fit - Details

Normal [#43]					
Chi-Squared					
Deg. of freedom	4				
Statistic	5,6209				
P-Value	0,2293				
Rank	13				
a	0,2	0,1	0,05	0,02	0,01
Critical Value	5,9886	7,7794	9,4877	11,668	13,277
Reject?	No	No	No	No	No

[\[top\]](#)

8. pielikums.

Klašu diagrammas prototipam

Biznesa loģikas līmenis



InstanceManager

- LOG: `Logger = Logger.getLogger(Instance...`
- `retrieveModelInstances (queryString : String) : Instances`


ModelManager

«...»

- `persistenceSet : String`
- `entityManager : EntityManager`
- `transaction : EntityTransaction`
- `props : Object`
- `factory : EntityManagerFactory`
- `key : String «...»`
- `value : String «...»`
- `coefficient : String «...»`
- `relative : String «...»`
- `initModelManager (persistenceSet : String)`
- `closeModelManager ()`
- `setStringValue (key : String , value : String)`
- `setStringValue (key : String , value : String , coefficient : String)`
- `setStringValue (key : String , value : String , coefficient : String , relative : String)`
- `setStringCoefficient (key : String , coefficient : String)`
- `getStringValue (key : String) : String`
- `getStringCoefficient (key : String) : String`
- `getRelativeCoefficient (key : String) : String`
- `getIntValue (key : String) : Integer`
- `getDoubleValue (key : String) : Double`
- `getProperties ()`
- `getURL () : String`
- `getUser () : String`
- `getPassword () : String`
- `setNumberValue (key : String , value : Number)`
- `setObjectValue (key : String , object : Object)`
- `setObjectValue (key : String , object : Object , coefficient : String)`
- `setObjectValue (key : String , object : Object , coefficient : String , relative : String)`
- `getObjectValue (key : String , objclass : Class) : Object`

PrepareData

- LOG: `Logger = Logger.getLogger(PrepareD...`
- `DB_URL : String = "jdbc:h2:data/Student;AUT...`
- `USER : String = "sa"`
- `PASS : String = ""`
- `DB_TABLE_NAME : String = "STUDENT"`
- `conn : Connection = null`
- `PERSISTENCE_SET : String = "test"`
- `updatePrediction ()`
- `generateModels ()`
- `csv2db (file : File)`



M3

```

LOG: Logger = Logger.getLogger(M3.class...)
QUERY_STRING: String = "SELECT KFA, PUOU from St..."
value: Integer

getRegression (topic : String , regression_key : String )
calculateKFA (topic : String )
getDataSet2 (topic : String ) : Instances
process2 (phone : String ) : Integer
getDataSet (topic : String ) : Instances

```

M2

```

LOG: Logger = Logger.getLogger(M2.class...)
QUERY_STRING: String = "SELECT SWL, SAL, ELM, IW..."

getRegression (topic : String , regression_key : String )
getRegression2 (topic : String ) : Evaluation

```

ModelException

```

serialVersionUID: long = -7937514651641173022L
ModelException () : ModelException
ModelException (message : String ) : ModelException

```

DBManager

```

cp: JdbcConnectionPool = JdbcConnectionPool.create...
DBManager () : DBManager

```

SQLException

Inclusion

```

main (args : String [1..*])

```



M1

```

LOG: Logger = Logger.getLogger(M1.class...)
QUERY_STRING: String = "SELECT SWL, DS, SAL, ELM..."

getAmountOfClusters (topic : String , clusterKey : String ) : int
getCentroids (topic : String , clusterKey : String , centroidKey : String , amount : int )
centroidToDouble (centroid : String ) : ArrayList <...>
calculateEuclidianDistance (SWL : double , DS : double , SAL : double , ELM : double , IWS : double , ELE : double , PU : double , centroidKey : String ) : String
getCluster (topic : String , clusterKey : String , centroidKey : String )

```

M0

- TRAINING_DATA_SET_FILENAME: String = "decision-train.arff"
- TESTING_DATA_SET_FILENAME: String = "decision-test.arff"
- LOG: Logger = Logger.getLogger(M0.class...)
- getDataSet (fileName: String, topic: String): Instances
- getDataSetUnlabeled (fileName: String, topic: String): Instances
- getDataSet2 (fileName: String, topic: String): Instances
- getDataSetUnlabeled2 (fileName: String, topic: String): Instances
- process ()
- process2 (): Evaluation

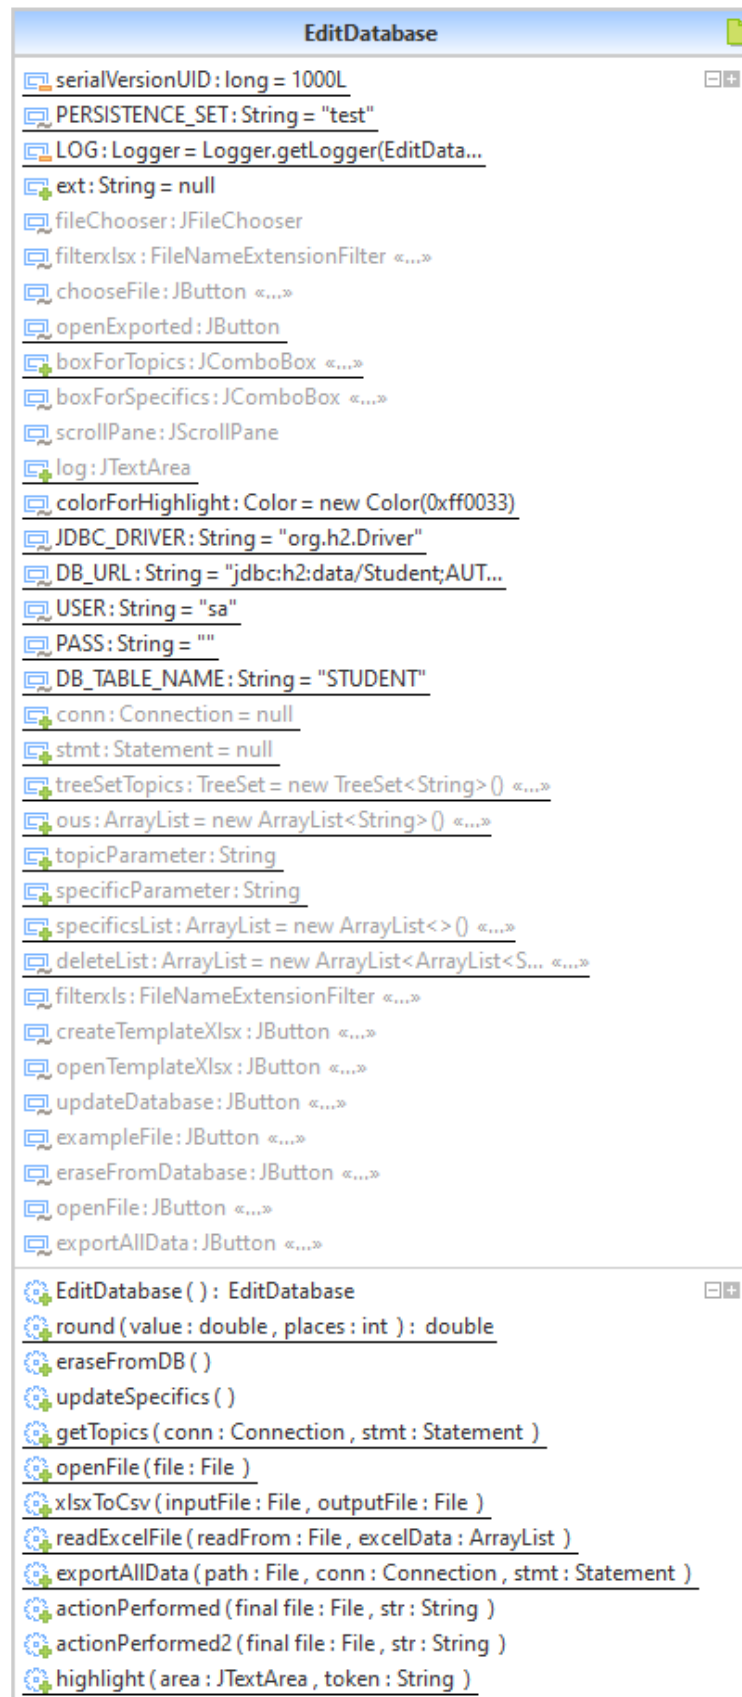
Prediction

- LOG: Logger = Logger.getLogger(Predicti...)
- QUERY_STRING: String = "SELECT OU from Student w..."
- getPrediction (topic: String)
- toInt (value: double): int
- calculateReliability (m1: int, m: int): String
- convertValue (value: String): String
- calculateM2orM3 (topic: String, student: Student)

Regression

- LOG: Logger = Logger.getLogger(Regressi...)
- coefficients: double
- Regression (): Regression
- toFormula (): String
- toString (): String «...»
- Regression (model: LinearRegression, data: Instances): Regression

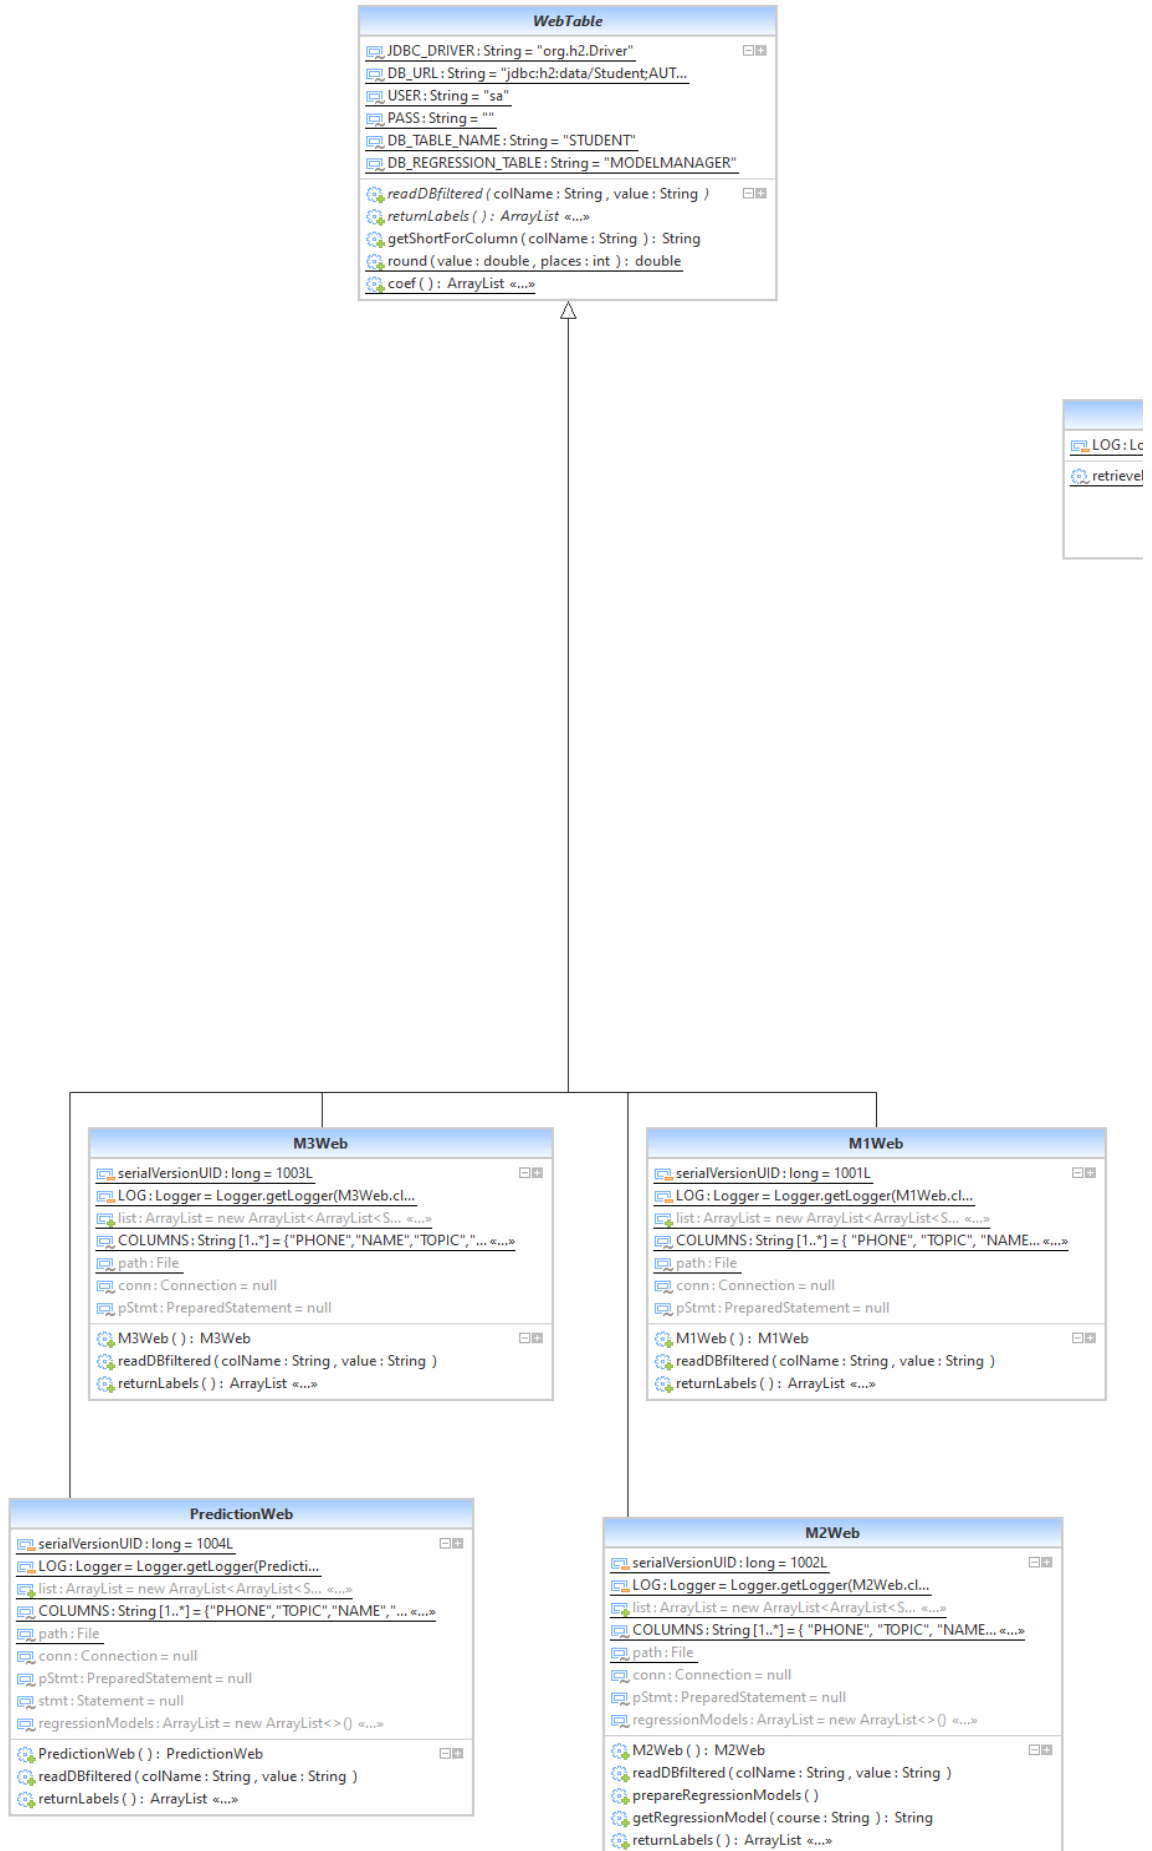
Prezentācijas līmenis



The screenshot displays the 'EditDatabase' class in IntelliJ IDEA, showing its fields and methods. The fields section includes variables like `serialVersionUID`, `PERSISTENCE_SET`, `LOG`, `ext`, `fileChooser`, `filterxlsx`, `chooseFile`, `openExported`, `boxForTopics`, `boxForSpecifics`, `scrollPane`, `log`, `colorForHighlight`, `JDBC_DRIVER`, `DB_URL`, `USER`, `PASS`, `DB_TABLE_NAME`, `conn`, `stmt`, `treeSetTopics`, `ous`, `topicParameter`, `specificParameter`, `specificsList`, `deleteList`, `filterxls`, `createTemplateXlsx`, `openTemplateXlsx`, `updateDatabase`, `exampleFile`, `eraseFromDatabase`, `openFile`, and `exportAllData`. The methods section includes `EditDatabase()`, `round()`, `eraseFromDB()`, `updateSpecifics()`, `getTopics()`, `openFile()`, `xlsxToCsv()`, `readExcelFile()`, `exportAllData()`, `actionPerformed()`, `actionPerformed2()`, and `highlight()`.

```
class EditDatabase {
    serialVersionUID : long = 1000L
    PERSISTENCE_SET : String = "test"
    LOG : Logger = Logger.getLogger(EditData...)
    ext : String = null
    fileChooser : JFileChooser
    filterxlsx : FileNameExtensionFilter «...»
    chooseFile : JButton «...»
    openExported : JButton
    boxForTopics : JComboBox «...»
    boxForSpecifics : JComboBox «...»
    scrollPane : JScrollPane
    log : JTextArea
    colorForHighlight : Color = new Color(0xff0033)
    JDBC_DRIVER : String = "org.h2.Driver"
    DB_URL : String = "jdbc:h2:data/Student;AUT..."
    USER : String = "sa"
    PASS : String = ""
    DB_TABLE_NAME : String = "STUDENT"
    conn : Connection = null
    stmt : Statement = null
    treeSetTopics : TreeSet = new TreeSet<String>() «...»
    ous : ArrayList = new ArrayList<String>() «...»
    topicParameter : String
    specificParameter : String
    specificsList : ArrayList = new ArrayList<>() «...»
    deleteList : ArrayList = new ArrayList<ArrayList<S... «...»
    filterxls : FileNameExtensionFilter «...»
    createTemplateXlsx : JButton «...»
    openTemplateXlsx : JButton «...»
    updateDatabase : JButton «...»
    exampleFile : JButton «...»
    eraseFromDatabase : JButton «...»
    openFile : JButton «...»
    exportAllData : JButton «...»

    EditDatabase() : EditDatabase
    round(value : double, places : int) : double
    eraseFromDB()
    updateSpecifics()
    getTopics(conn : Connection, stmt : Statement)
    openFile(file : File)
    xlsxToCsv(inputFile : File, outputFile : File)
    readExcelFile(readFrom : File, excelData : ArrayList)
    exportAllData(path : File, conn : Connection, stmt : Statement)
    actionPerformed(final file : File, str : String)
    actionPerformed2(final file : File, str : String)
    highlight(area : JTextArea, token : String)
}
```



«...»

ReportServlet

serialVersionUID : long = -5564406414973334671L

list : ArrayList = new ArrayList<ArrayList<S... «...»

doGet (req : HttpServletRequest , resp : HttpServletResponse)

InstanceManager

LOG : Logger = Logger.getLogger(Instance...

retrieveModelInstances (queryString : String) : Instances

ChartDrawer	
list: ArrayList «...»	☰
chart: JFreeChart = null	
from: String	
to: String	
type: String	
chosenTopic: String	
getChart () : JFreeChart	☰
drawFirstChart ()	
drawSecondChart ()	
customize ()	
ChartDrawer (list : ArrayList , type : String , from : String , to : String , chosenTopic : String) : ChartDrawer	

«...»
IOException

«...»
Exception

«...»
ServletException

FileUploadServlet	
serialVersionUID: long = -9164530828669301284L	☰
LOG: Logger = Logger.getLogger(FileUplo...	
file: File	
message: String = null	
doPost (request : HttpServletRequest , response : HttpServletResponse)	☰
doGet (request : HttpServletRequest , response : HttpServletResponse)	
getFileName (part : Part) : String	

1

9. Pielikums

Prototipa koda piemēri

Kods datu pievienošanai no csv faila datubāzei, prognozes iniciēšana vai prognozes modeļa izveides iniciēšana

```
package org.einclusion.model;

import java.io.BufferedReader;
import java.io.File;
import java.io.FileNotFoundException;
import java.io.FileReader;
import java.io.IOException;
import java.sql.PreparedStatement;
import java.sql.Connection;
import java.sql.Date;
import java.sql.DriverManager;
import java.sql.ResultSet;
import java.sql.SQLException;
import java.sql.Statement;

import javax.persistence.Query;

import org.apache.log4j.Logger;

import static org.einclusion.model.ModelManager.*;

/**
 * This class is used to add data from the converted .csv file to database
 *
 * @author student
 */

public class PrepareData {
    private static final Logger LOG = Logger.getLogger(PrepareData.class);
    static final String DB_URL = "jdbc:h2:data/Student;AUTO_SERVER=TRUE";
    static final String USER = "sa"; // username for database
    static final String PASS = ""; // password for database
    static final String DB_TABLE_NAME = "STUDENT"; // default table name
    public static Connection conn = null; // connection with a database
    static final String PERSISTENCE_SET = "test"; // persistence set for
    // connecting to database

    /**
     * Function that reads a given .csv file and writes students to database
     *
     * @param file
     *      - path to a .csv file
     */
    public static void csv2db(File file) {
        try {
            // EditDatabasePanel.log.append("Reading from file:
            // "+file.getName()+"\n");
            conn = DriverManager.getConnection(DB_URL, USER, PASS); // establish
            // connection to database
            conn.setAutoCommit(false); // sets autocommit to false
            // reads the file using buffered reader
            BufferedReader br = new BufferedReader(new FileReader(file));
            String line; // a row from the file
            while ((line = br.readLine()) != null) { // while rows aren't empty
                String[] value = line.split(","); // splits the line by ,
                String PHONE = value[0];
                String NAME = value[1];
                String TOPIC = value[2];
                Double IWS = Double.parseDouble(value[11]);
                Double KLAL = Double.parseDouble(value[12]);
                Double KLBL = Double.parseDouble(value[13]);
                Double PU = Double.parseDouble(value[14]);
                String SUBMITDATE = value[15];
                Double SWL = (Double.parseDouble(value[3]) + Double.parseDouble(value[4])) / 2; //
calculates

                //
                Double DS = (Double.parseDouble(value[5]) + Double.parseDouble(value[6])) / 2; //

```

```

calculates
DS //
Double ELM = (Double.parseDouble(value[7]) + Double.parseDouble(value[8])) / 2; //
calculates
ELM //
Double ELE = (Double.parseDouble(value[9]) + Double.parseDouble(value[10])) / 2; //
calculates
// ELE
Double SAL = (double) 0; // creates SAL
if (5 - KLBL == 0) { // if student cant learning anything new // (MAX - KLBL)
    SAL = (double) 0; // SAL is 0
} else { // else if student is able to learn smth new
    if (KLAL > KLBL)
        SAL = (KLAL - KLBL) * 4 / (5 - KLBL);
    else
        SAL = (KLBL - KLAL) * 4 / (5 - KLAL);
}
SAL++; // so SAL max value is 5 and lowest value is 1
Double KFA = ((IWS + ELE + ELM) * KLBL) / 3;
Integer VOTE = 0;

String sql = "UPDATE STUDENT" + " SET NAME=?, IWS=?, KLAL=?, KLBL=?, PU
=?, "
+ " SUBMITDATE=?, SWL=?, DS=?, ELM=?, ELE=?,"
+ " SAL=?, PUOU=?, M1=?, M2=?, KFA=?, M3=?,
RELIABILITY=?, OU=?, VOTE=?" + " WHERE PHONE=? and TOPIC=?";
PreparedStatement pst = conn.prepareStatement(sql);
pst.setString(1, NAME);
pst.setDouble(2, IWS);
pst.setDouble(3, KLAL);
pst.setDouble(4, KLBL);
pst.setDouble(5, PU);
pst.setDate(6, Date.valueOf(SUBMITDATE));
pst.setDouble(7, SWL);
pst.setDouble(8, DS);
pst.setDouble(9, ELM);
pst.setDouble(10, ELE);
pst.setDouble(11, SAL);
pst.setDouble(12, 0);
pst.setInt(13, -1);
pst.setDouble(14, -1);
pst.setDouble(15, KFA);
pst.setDouble(16, -1);
pst.setString(17, "not available");
pst.setNull(18, java.sql.Types.INTEGER);
pst.setInt(19, VOTE);
pst.setString(20, PHONE);
pst.setString(21, TOPIC);

// LOG.debug(pst.);
pst.executeUpdate();
conn.commit();

sql = "INSERT INTO STUDENT
(Phone,Name,Topic,IWS,KLAL,KLBL,PU,SubmitDate,SWL,DS,"
+ "ELM,ELE,SAL,PUOU,M1,M2,KFA, M3,
RELIABILITY,VOTE)"
+ " SELECT ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ? "
+ " WHERE NOT EXISTS (SELECT PHONE, TOPIC from
STUDENT WHERE PHONE=? and TOPIC=?)";
pst = conn.prepareStatement(sql);
pst.setString(1, PHONE);
pst.setString(2, NAME);
pst.setString(3, TOPIC);
pst.setDouble(4, IWS);
pst.setDouble(5, KLAL);
pst.setDouble(6, KLBL);
pst.setDouble(7, PU);
pst.setDate(8, Date.valueOf(SUBMITDATE));
pst.setDouble(9, SWL);

```

```

        pst.setDouble(10, DS);
        pst.setDouble(11, ELM);
        pst.setDouble(12, ELE);
        pst.setDouble(13, SAL);
        pst.setDouble(14, 0);
        pst.setInt(15, -1);
        pst.setDouble(16, -1);
        pst.setDouble(17, KFA);
        pst.setDouble(18, -1);
        pst.setString(19, "not available");
        pst.setInt(20, -1);
        pst.setString(21, PHONE);
        pst.setString(22, TOPIC);
        pst.executeUpdate();
        conn.commit();

    }
    br.close(); // closes buffered reader
    conn.close();
} catch (FileNotFoundException fnfe) {
    LOG.error(fnfe.getMessage() + " " + fnfe.getCause());
    fnfe.printStackTrace();
    String errorText = "File not found choose a different path!";
    LOG.error(errorText + "\n");
    //EditDatabasePanel.log.append(errorText + "\n");
    //EditDatabasePanel.highlight(EditDatabasePanel.log, errorText);
} catch (IOException ioe) {
    LOG.error(ioe.getMessage() + " " + ioe.getCause());
    ioe.printStackTrace();
    String errorText = "Exception while writing to file!";
    LOG.error(errorText + "\n");
    //EditDatabasePanel.log.append(errorText + "\n");
    //EditDatabasePanel.highlight(EditDatabasePanel.log, errorText);
} catch (SQLException e) {
    // TODO Auto-generated catch block
    e.printStackTrace();
} finally {

}

}

public static void updatePrediction() {
    try {
        conn = DriverManager.getConnection(DB_URL, USER, PASS);
        conn.setAutoCommit(false); // sets autocommit to false

        String sql = "SELECT DISTINCT TOPIC FROM STUDENT where OU IS NULL";
        PreparedStatement pst = conn.prepareStatement(sql);
        ResultSet rs = pst.executeQuery();
        conn.commit();

        while (rs.next()) { // while table has contents

            String topic = rs.getString("TOPIC");
            // Prediction should be called for topics which have OU values
            // with NULL.
            // FIXME : Should update SQL to exclude topics which don't have
            // coefficients
            try {
                LOG.info("Before prediction");
                // Prediction.getAll(topic);
                // LOG.info("Before prediction2");
                Prediction.getPrediction(topic);
                LOG.info("Before prediction3");

            } catch (Throwable t) {
                LOG.error(t.getMessage() + " " + t.getCause());
                LOG.info("Before prediction3");
                t.printStackTrace();
            }

        }

        conn.close();
    } catch (SQLException e) {
        // TODO Auto-generated catch block
        e.printStackTrace();
    }
}

```

```

    } // establisih

}

public static void generateModels() {
    try {

        conn = DriverManager.getConnection(DB_URL, USER, PASS);

        conn.setAutoCommit(false); // sets autocommit to false
        LOG.info("Generating models\n");

        String sql = "SELECT DISTINCT TOPIC FROM STUDENT where OU IS NOT NULL";
        PreparedStatement pst = conn.prepareStatement(sql);
        ResultSet rs = pst.executeQuery();
        conn.commit();
        // TOFIX: There were some memory leaks when testing from virtualbox
        // if model manager was initialized here, but there seem to be no
        // issues working from local pc
        // Model manager should be initialized for Instance manager to work
        // properly, necessary for model generation

        // ModelManager.initModelManager(PERSISTENCE_SET); // loads

        while (rs.next()) { // while table has contents

            String topic = rs.getString("TOPIC");
            // If one type of model generation fails, next one should still
            // be generated
            try {
                LOG.info("All cluster1");
                M1.getCluster(topic, "M1-clusters-" + topic, "M1-centroids-" + topic);
                LOG.info("All cluster2");
            } catch (Throwable t) {
                LOG.error(t.getMessage() + " " + t.getCause());
                t.printStackTrace();
            }
            try {
                M2.getRegression(topic, "M2-" + topic); //M2
            } catch (Throwable t) {
                LOG.error(t.getMessage() + " " + t.getCause());
                t.printStackTrace();
            }
            try {

                //M0 m0 = new M0();
                M0.process2();
                // M3.calculateVOTE(topic);
            } catch (Throwable t) {
                LOG.error(t.getMessage() + " " + t.getCause());
                t.printStackTrace();
            }
        }
        conn.close();
    } catch (SQLException e) {
        // TODO Auto-generated catch block
        e.printStackTrace();
    } finally {
        // ModelManager.closeModelManager(); // closes
        // connection
        LOG.info("Finished generating models\n");
    } //
}
}

```

Kods studentu tabulas izveidei un darbībām ar studentus raksturojošiem datiem

```

package org.einclusion.model;

import java.io.Serializable;

import java.lang.reflect.Field;

```

```

import java.util.Date;
import java.util.LinkedList;
import java.util.List;

import javax.persistence.*;

import org.apache.log4j.Logger;
import org.hibernate.annotations.DynamicUpdate;

import static org.einclusion.model.ModelManager.*;

@Entity
@Table(name="Student")
@DynamicUpdate(value = true)
public class Student implements Serializable {
    private static final Logger LOG = Logger.getLogger(Student.class);
    private static final long serialVersionUID = 10001L;

    @Id
    @GeneratedValue(strategy = GenerationType.AUTO)
    @Column(nullable = false)
    Long ID; // system generated unique identifier
    String PHONE; // students phone number
    String NAME; // student name and surname
    String TOPIC; // subject (topic)
    Double DS; // digital skills (average)
    Double ELE; // e-learning environment (average)
    Double ELM; // e-learning materials (average)
    Double IWS; // instructor willing to share knowledge
    Double SAL; // student ability learn
    Double SWL; // student wiling to learn (average)
    Double KLAL; // knowledge after learning
    Double KLBL; // knowledge before learning
    Integer OU; // observed usage
    Double PU; // predicted usage
    Double PUOU; // combination of predicted usage and observed usage (ou + pu)
    Integer M1; // m1 value
    Double M2; // m2 value
    Double KFA; // knowledge flow acceleration
    Double M3; // m3 value
    String RELIABILITY; // reliability of prediction model
    Date SUBMITDATE; // date (when the survey was completed)
    Integer VOTE;

    public Long getId(){ return ID; }

    public void setPhone(String PHONE){ this.PHONE = (PHONE != null) ? PHONE : "-1"; }
    public String getPhone(){ return PHONE; }

    public void setName(String NAME){ this.NAME = (NAME != null) ? NAME : "-1"; }
    public String getName(){ return NAME; }

    public void setTopic(String TOPIC){ this.TOPIC = (TOPIC != null) ? TOPIC : "-1"; }
    public String getTopic(){ return TOPIC; }

    public void setDS(Double DS){ this.DS = ( DS >= 1 && DS <= 5 ) ? DS : -1; }
    public Double getDS(){ return DS; }

    public void setELE(Double ELE){ this.ELE = ( ELE >= 1 && ELE <= 5 ) ? ELE : -1; }
    public Double getELE(){ return ELE; }

    public void setELM(Double ELM){ this.ELM = ( ELM >= 1 && ELM <= 5 ) ? ELM : -1; }
    public Double getELM(){ return ELM; }

    public void setIWS(Double IWS){ this.IWS = ( IWS >= 1 && IWS <= 5 ) ? IWS : -1; }
    public Double getIWS(){ return IWS; }

    public void setSAL(Double SAL){ this.SAL = ( SAL >= 1 && SAL <= 5 ) ? SAL : -1; }
    public Double getSAL(){ return SAL; }

    public void setSWL(Double SWL){ this.SWL = ( SWL >= 1 && SWL <= 5 ) ? SWL : -1; }
    public Double getSWL(){ return SWL; }

    public void setKLAL(Double KLAL){ this.KLAL = ( KLAL >= 1 && KLAL <= 5 ) ? KLAL : -1; }
    public Double getKLAL(){ return KLAL; }

    public void setKLBL(Double KLBL){ this.KLBL = ( KLBL >= 1 && KLBL <= 5 ) ? KLBL : -1; }

```

```

public Double getKLBL(){ return KLBL; }

//public void setOU(Integer OU){ this.OU = ( OU >= 0 && OU <= 2 ) ? OU : -1; }
public void setOU(Integer OU){ this.OU = ( OU == 0 && OU == 2 ) ? OU : -1; }
public Integer getOU(){ return OU; }

public void setPU(Double PU){ this.PU = ( PU >= 1 && PU <= 5 ) ? PU : -1; }
public Double getPU(){ return PU; }

public void setPUOU(){
    Double tmp = getOU() + getPU();
    this.PUOU = ( tmp >= 1 && tmp <= 7 ) ? tmp : -1;
}
public Double getPUOU(){ return PUOU; }

public void setM1(int M1){ this.M1 = (M1 >= 0 && M1 <= 2) ? M1 : 0; }
public int getM1(){ return M1; }

public void setM2(Double M2){ this.M2 = (M2 >= 0 && M2 <= 100) ? M2 : 0; }
public Double getM2(){ return M2; }

public void setKFA(Double KFA){ this.KFA = (KFA > 0) ? KFA : 0; }
public Double getKFA(){ return KFA; }

public void setM3(Double M3){ this.M3 = (M3 >= 0 && M3 <= 100) ? M3 : 0; }
public Double getM3(){ return M3; }

public void setReliability(String RELIABILITY){ this.RELIABILITY = RELIABILITY; }
public String getRealibility(){ return RELIABILITY; }

public void setDate(Date SUBMITDATE){ this.SUBMITDATE = SUBMITDATE;}
public Date getDate(){ return SUBMITDATE; }

public void setVote(int VOTE){ this.VOTE =
    (VOTE >= 0 && VOTE <= 2) ? VOTE : 0; }
public int getVote(){ return VOTE; }

public static List<Student> getStudent() {
    List<Student> tmp = new LinkedList<Student>();
    try {
        TypedQuery<Student> query = entityManager.createQuery(
            "FROM Student", Student.class);

        List<Student> students = query.getResultList();
        return students;

    } catch (Exception e) {
        LOG.error(e.getMessage() + " " + e.getCause());
    }
    return tmp;
}

/**
 * Returns a list of students in a topic
 * @param topic - name of topic (String)
 * @return List(Students)
 */
public static List<Student> getStudents(String topic) {
    List<Student> tmp = new LinkedList<Student>();
    try {
        TypedQuery<Student> query = entityManager.createQuery(
            "FROM Student WHERE OU IS NOT null AND Topic IS '"+topic+"'",
Student.class);

        List<Student> students = query.getResultList();
        LOG.info("<">+students.size());
        return students;

    } catch (Exception e) {
        LOG.error(e.getMessage() + " " + e.getCause());
    }
    return tmp;
}

/**
 * Returns a list of students in a topic

```

```

* @param topic - name of topic (String)
* @return List(Student)
*/
public static List<Student> getStudentsforPrediction(String topic) {
    List<Student> tmp = new LinkedList<Student>();
    try {
        TypedQuery<Student> query = entityManager.createQuery(
            "FROM Student WHERE Topic IS '"+topic+"' AND OU IS null" , Student.class);

        List<Student> students = query.getResultList();
        return students;

    } catch (Exception e) {
        LOG.error(e.getMessage() + " " + e.getCause());
    }
    return tmp;
}

/**
 * Function for updating one student values in database
 * @param students - student object (Student)
 * @return id - student id
 */
static Long setStudent(Student students) {
    EntityTransaction transaction = entityManager.getTransaction();
    Long id = -1;
    try {
        transaction.begin();
        if (students.ID != null && students.ID > 0) {
            entityManager.merge(students);
        } else
            entityManager.persist(students);
        transaction.commit();
        // entityManager.flush();
        id = students.ID;
        LOG.debug("Student ID:" + id);
        return id;
    } catch (Exception e) {
        LOG.error(e.getMessage() + " " + e.getCause());
        return id;
    }
}

/**
 * Returns student with given id
 * @param id - student id
 * @return student (Student)
 */
static Student getStudent(Long id) {
    return entityManager.find(Student.class, id);
}

@Override
public String toString() {
    StringBuilder result = new StringBuilder();
    String newLine = System.getProperty("line.separator");

    result.append(this.getClass().getName());
    result.append(" Object {");
    result.append(newLine);

    // determine fields declared in this class only (no fields of
    // superclass)
    Field[] fields = this.getClass().getDeclaredFields();

    // print field names paired with their values
    for (Field field : fields) {
        result.append(" ");
        try {
            result.append(field.getName());
            result.append(": ");
            result.append(field.get(this));
        } catch (IllegalAccessException ex) {
            LOG.error(ex.getMessage() + " " + ex.getCause());
        }
        result.append(newLine);
    }
}

```

```

    }
    result.append("{}");

    return result.toString();
}
}
}

```

Klasteranalīzē balstīta prognozēšanas modeļa izveide un studenta piederības klasterim noteikšana

```

package org.einclusion.model;

import java.util.ArrayList;
import java.util.List;

import javax.persistence.Query;

import org.apache.log4j.Logger;

import weka.core.Instances;
import weka.clusterers.EM;
import weka.clusterers.SimpleKMeans;
import weka.clusterers.ClusterEvaluation;
import weka.clusterers.Clusterer;
import weka.filters.Filter;
import weka.filters.unsupervised.attribute.NumericToNominal;
import static org.einclusion.model.InstanceManager.*;
import static org.einclusion.model.ModelManager.entityManager;
import static org.einclusion.model.ModelManager.transaction;
/**
 * This class is used to work with clusters, calculate centroids and euclidean distance
 * @author student
 */
public class M1 {
    private static final Logger LOG = Logger.getLogger(M1.class);
    static final String QUERY_STRING = "SELECT SWL, DS, SAL, ELM, IWS, ELE, PU, OU from STUDENT where "
        + "SWL>0 and DS>0 and SAL>0 and ELM>0 and IWS>0 and ELE>0 and PU>0 and OU>=0 and OU
IS NOT NULL";

    /**
     * Function that gets amount of clusters from given data and writes it to database
     * @param topic - name of topic (String)
     * @param clusterKey - unique cluster key, so it can be recognised in database (String)
     */
    public static int getAmountOfClusters(String topic, String clusterKey) {
        int clusters = 0;
        try {
            String sql = QUERY_STRING + " AND TOPIC = '"+topic+"'"; // gets data from specific
topic
            Instances data = retrieveModelInstances(sql);
            ClusterEvaluation eval = new ClusterEvaluation();
            Clusterer clusterer = new EM(); // new clusterer instance, default options
            clusterer.buildClusterer(data); // build clusterer
            eval.setClusterer(clusterer); // the clusterer to evaluate
            eval.evaluateClusterer(data); // data to evaluate the clusterer on

            clusters = clusterer.numberOfClusters(); // gets the number of clusters
            //ModelManager.setNumberValue(clusterKey, clusters); // writes number of clusters to
database

            //LOG.info("M1-clusters: " + clusters);
            return clusters;

        } catch (Exception e) {
            LOG.error(e.getMessage()+" "+e.getCause());
            return clusters;
        }
    }

    /**
     * Function that gets centroids from given data and writes them to database
     * @param topic - name of topic (String)
     * @param clusterKey - unique cluster key, so it can be recognised in database (String)
     * @param centroidKey - unique centroid key, so it can be recognised in database (String)
     */
    public static void getCentroids(String topic, String clusterKey, String centroidKey, int amount) {

```

```

        int clusters;
        try {
            String sql = QUERY_STRING + " AND TOPIC =" + topic + """; // gets data from specific
topic
            Instances data = retrieveModelInstances(sql); // retrieves
instances from database

            NumericToNominal convert = new NumericToNominal(); // filter for
converting numeric values to nominal values
            String[] options = new String[2]; // options for
filter
            options[0] = "-R";
            // "range" ( which attributes it will apply to )
            options[1] = "last";
            // range of variables to make numeric (1st, 2nd, last);

            convert.setOptions(options); // adds
options to filter
            convert.setInputFormat(data); //
adds inputformat to filter

            data = Filter.useFilter(data, convert); // filters instances (data)

            // create the model
            SimpleKMeans kMeans = new SimpleKMeans(); //
new SimpleKMeans instance

            //
            clusters = ModelManager.getIntValue(clusterKey); // gets amount of
clusters from database
            clusters = 2;

            kMeans.setNumClusters(clusters);
            // sets number of clusters for kmeans
            kMeans.buildClusterer(data);
            SSE = kMeans.getSquaredError();
            //
            System.out.println("sum of squared errors: " + kMeans.getSquaredError());

            try {
                ModelManager.setStringCoefficient(centroidKey);
            } catch (NullPointerException npe) {
                ModelManager.setStringCoefficient(centroidKey, Integer.MIN_VALUE + "");
            }

            try {
                String databaseCoefficient = null;
                LOG.info("SSE = " + kMeans.getSquaredError());
                databaseCoefficient = ModelManager.getStringCoefficient(centroidKey);
                LOG.info("Database coefficient: " + databaseCoefficient);
                if (databaseCoefficient.equals(Integer.MIN_VALUE + "")) {
                    LOG.info("databaseCoefficient == null");
                    ModelManager.setNumberValue(clusterKey, clusters); //
writes number of clusters to database
                    Instances centroids = kMeans.getClusterCentroids(); // gets cluster
centroids
                    StringBuilder sb = new StringBuilder();
                    // for appending multiple clusters
                    for (int i = 0; i < centroids.numInstances(); i++) { // iterates
amount of centroid instances times
                        if (i == centroids.numInstances() - 1) {
                            // if last iteration
                            LOG.info("Centroid " + i + ": " +
centroids.instance(i).toString());
                            sb.append(centroids.instance(i).toString()); //
appends centroids to string builder
                            ModelManager.setStringValue(centroidKey, sb.toString(),
kMeans.getSquaredError() + ""); // writes centroids to database
                        } else {
                            // if not last iteration
                            LOG.info("Centroid " + i + ": " +
centroids.instance(i).toString());
                            sb.append(centroids.instance(i).toString() + "|"); //
appends centroids to string builder
                        }
                    }
                } else {
                    LOG.info("databaseCoefficient != null");

```

```

        if( kMeans.getSquaredError() < Double.parseDouble(databaseCoefficient) ){
            LOG.info( "SSE < databaseCoefficient" );
            ModelManager.setNumberValue(clusterKey, clusters); // writes
number of cluters to database
            Instances centroids = kMeans.getClusterCentroids(); //
gets cluster centroids
            StringBuilder sb = new StringBuilder();
            // for appending multiple clusters
            for (int i = 0; i < centroids.numInstances(); i++) { //
iterates amount of centroid instances times
                if( i == centroids.numInstances()-1 ){
                    // if last iteration
                    LOG.info("Centroid " + i + ": " +
centroids.instance(i).toString());
                    sb.append(centroids.instance(i).toString());
                    // appends centroids to string builer
                    ModelManager.setStringValue(centroidKey,
sb.toString(), kMeans.getSquaredError()+""); // writes centroids to database
                } else {
                    // if not last iteration
                    LOG.info("Centroid " + i + ": " +
centroids.instance(i).toString());
                    sb.append(centroids.instance(i).toString()+"|");
                    // appends centroids to string builder
                }
            }
            LOG.info("Don't calculate new model");
        } else {
            }
        }
    } catch( NullPointerException npe ) {
        LOG.warn(npe.getMessage()+" "+npe.getCause());
        npe.printStackTrace();
    }
} catch( Exception e ) {
    LOG.error(e.getMessage()+" "+e.getCause());
    String errorText = "Couldn't build M1:"+topic+" model";
    LOG.warn(errorText+"\n");
    //EditDatabasePanel.log.append(errorText+"\n");
    //EditDatabasePanel.highlight(EditDatabasePanel.log, errorText);
}
}

/**
 * Function that converts a string of centroids to an ArrayList of doubles and returns it
 * @param centroid - a string of centroids (String)
 * @return ArrayList of Doubles (cetroids)
 */
public static ArrayList<Double> centroidToDouble(String centroid){
    ArrayList<Double> centroidValues = new ArrayList<Double>(); // double arrayList for saving values
    String [] centroidValue = centroid.split("\\,"); // splits values by "," ands adds
them to string array
    Double CSWL = Double.parseDouble(centroidValue[0]);
    Double CDS = Double.parseDouble(centroidValue[1]);
    Double CSAL = Double.parseDouble(centroidValue[2]);
    Double CELM = Double.parseDouble(centroidValue[3]);
    Double CIWS = Double.parseDouble(centroidValue[4]);
    Double CELE = Double.parseDouble(centroidValue[5]);
    Double CPU = Double.parseDouble(centroidValue[6]);
    Double COU = Double.parseDouble(centroidValue[7]);

    centroidValues.add(CSWL);
    centroidValues.add(CDS);
    centroidValues.add(CSAL);
    centroidValues.add(CELM);
    centroidValues.add(CIWS);
    centroidValues.add(CELE);
    centroidValues.add(CPU);
    centroidValues.add(COU);

    return centroidValues;
}
}
/**

```

```

*      Funtion that returns shortest Euclidian distance and centroid
*      @param SWL - student willingness to learn (double)
*      @param DS - digital skills (double)
*      @param SAL - student ability to learn (double)
*      @param ELM - e-learning materials (double)
*      @param IWS - instructors willingnes to share (double)
*      @param ELE - e-learning environment (double)
*      @param PU - predicted usage (double)
*      @param centroidKey - unique centroid key, so it can be recognised in database (String)
*      @return centroid + "|" + euclidian distance (String)
*/
public static String calculateEuclidianDistance(double SWL, double DS, double SAL, double ELM, double IWS, double
ELE, double PU, String centroidKey){

    String centroids = ModelManager.getStringValue(centroidKey);

    Double shortestDistance = Double.MAX_VALUE;
    Double centroidOU = (double)-1;

    if( centroids.contains("|") ){
        String [] splitCentroids = centroids.split("\\|");
        for( String centroid : splitCentroids ) {
            ArrayList<Double> values = centroidToDouble(centroid);
            Double CSWL = values.get(0);
            Double CDS = values.get(1);
            Double CSAL = values.get(2);
            Double CELM = values.get(3);
            Double CIWS = values.get(4);
            Double CELE = values.get(5);
            Double CPU = values.get(6);
            Double COU = values.get(7);
            // calculates euclidian distance sqrt((pn - qn)^2)
            double euclidianDistance = Math.sqrt( Math.pow((CSWL-SWL), 2) + Math.pow((CDS-
DS), 2) + Math.pow((CSAL-SAL), 2) + Math.pow((CELM-ELM), 2)+
                                                    Math.pow((CIWS-
IWS), 2) + Math.pow((CELE-ELE), 2) + Math.pow((CPU-PU), 2));
            if( euclidianDistance < shortestDistance ) { // gets shortest euclidian distance
                shortestDistance = euclidianDistance;
                centroidOU = COU;
            }
        }
    } else {
        ArrayList<Double> values = centroidToDouble(centroids);
        Double CSWL = values.get(0);
        Double CDS = values.get(1);
        Double CAL = values.get(2);
        Double CELM = values.get(3);
        Double CIWS = values.get(4);
        Double CELE = values.get(5);
        Double CPU = values.get(6);
        Double COU = values.get(7);
        // calculates euclidian distance sqrt((pn - qn)^2)
        double euclidianDistance = Math.sqrt( Math.pow((SWL-CSWL), 2) + Math.pow((DS-CDS), 2) +
Math.pow((SAL-CAL), 2) + Math.pow((ELM-CELM), 2)+
                                                    Math.pow((IWS-CIWS), 2) +
Math.pow((ELE-CELE), 2) + Math.pow((PU-CPU), 2));
        if( euclidianDistance < shortestDistance ) { // gets shortest euclidian distance
            shortestDistance = euclidianDistance;
            centroidOU = COU;
        }
    }

    if( shortestDistance != Double.MAX_VALUE ) // if shortestDistance is not first
initialized value
        return centroidOU+"|"+shortestDistance;
    else
        // if it is error text
        return "Couldnt calculate shortest distance";
}

/**
*      Function that calculates each student shortest euclidian distance and writes COU to database
*      @param topic - name of topic (String)
*      @param clusterKey - unique cluster key, so it can be recognised in database (String)
*      @param centroidKey - unique centroid key, so it can be recognised in database (String)
*/
public static void getCluster(String topic, String clusterKey, String centroidKey){

```



```

        Evaluation eval = new Evaluation(data);
// new evaluation model for given instances
int instances = data.numInstances();
if( instances > 10)
    instances = 10;
eval.crossValidateModel(model, data, instances, new Random(1));           // crossvalidate model
double coefficient = eval.correlationCoefficient();                       // get

correlation coefficient

double relative = eval.relativeAbsoluteError();

LOG.info( "Relative absolute error: " + eval.relativeAbsoluteError());

System.out.println( "Mean absolute error: " + eval.meanAbsoluteError());
System.out.println( "Root mean squared error: " + eval.rootMeanSquaredError());
System.out.println( "Relative absolute error: " + eval.relativeAbsoluteError());
System.out.println( "Root relative squared error: " + eval.rootRelativeSquaredError());
System.out.println( "Number of instances: " + eval.numInstances());

Instance studentb = data.instance(0);
double pu = model.classifyInstance(studentb);
System.out.println("\n\n"+studentb+" : "+ pu +"\n\n");

try{
    ModelManager.getStringCoefficient(regression_key);
} catch( NullPointerException npe ){
    ModelManager.setStringCoefficient(regression_key, Integer.MIN_VALUE+"");
}

LOG.info( "Corelation coefficient: " + eval.correlationCoefficient());
String databaseCoefficient = null;
databaseCoefficient = ModelManager.getStringCoefficient(regression_key);
LOG.info("Database coefficient: "+databaseCoefficient);

if( databaseCoefficient.equals(Integer.MIN_VALUE+"") ){
    if( model.toString().contains("SWL") || model.toString().contains("SAL") ||
model.toString().contains("ELM") || model.toString().contains("IWS") || model.toString().contains("ELE") ){
        // Save regression coefficients
        LOG.info("databaseCoefficient == null");
        Regression regression = new Regression(model, data);
        ModelManager.setObjectValue(regression_key, regression, coefficient+"",
relative+"");

        Query query;
        transaction.begin();
        List<?> result = Student.getStudents(topic);
        RegressionModel rm = new RegressionModel(regression_key,
regression.coefficients.toString(),true);

        System.out.println("\n"+regression.coefficients.toString()+"\n");
        Double maxswl = (double)5;
        Double maxsal = (double)5;
        Double maxelm = (double)5;
        Double maxiws = (double)5;
        Double maxele = (double)5;

contains negative coefficients

        for( Coefficient c : rm.coefficients ){                               // if model

            switch( c.name ){
                case"SWL":
                    if( Double.parseDouble(c.value) < 0 )
                        maxswl = (double)1;
                    break;
                case"SAL":
                    if( Double.parseDouble(c.value) < 0 )
                        maxsal = (double)1;
                    break;
                case"ELM":
                    if( Double.parseDouble(c.value) < 0 )
                        maxelm = (double)1;
                    break;
                case"IWS":
                    if( Double.parseDouble(c.value) < 0 )
                        maxiws = (double)1;
                    break;
                case"ELE":
                    if( Double.parseDouble(c.value) < 0 )

```

```

                maxele = (double)1;
                break;
            default:
                if( Double.parseDouble(c.value) < 0 )
                    maxele = (double)1;
                break;
            }
        }

//Double maxRmValue = RegressionModel.getM2regressionDegree(rm,
maxswl, maxsal, maxelm, maxiws, maxele);
Double maxRmValue = RegressionModel.getM2regressionDegreeMax(rm);//,
maxswl, maxsal, maxelm, maxiws, maxele);

        for (Object o: result) {
            Student student = (Student)o;
            Double m2 = RegressionModel.getM2regressionDegree(rm,
student.getSWL(), student.getSAL(), student.getELM(), student.getIWS(), student.getELE());
            LOG.info(student.getName()+" "+student.getTopic()+" m2: "+m2);
            m2 = m2/maxRmValue*100;
            student.setM2(m2);
            String sql = "UPDATE STUDENT SET M2="+m2+" WHERE
PHONE="+student.getPhone()+" AND TOPIC="+student.getTopic()+"";
            query = entityManager.createNativeQuery(sql);
            query.executeUpdate();
        }
        LOG.info("Changes have been committed to the database successfully\n");
    }
    /*else{
        Regression regression = new Regression(model, data);
        ModelManager.setObjectValue(regression_key, regression);
        Query query;
        transaction.begin();
        List<?> result = Student.getStudents(topic);
        for (Object o: result) {
            Student student = (Student)o;
            String sql = "UPDATE STUDENT SET M2='-1' WHERE
PHONE="+student.getPhone()+" AND TOPIC="+student.getTopic()+"";
            query = entityManager.createNativeQuery(sql);
            query.executeUpdate();
        }
        LOG.info("Changes have been committed to the database successfully\n");
        String errorText = "Couldn't generate valid M2 regression model for "+topic+"
there are either too less values or the values aren't different enough";
        LOG.warn(errorText+"\n");
        //EditDatabasePanel.log.append(errorText+"\n");
        //EditDatabasePanel.highlight(EditDatabasePanel.log, errorText);
    }
    */
} else {
    if( eval.correlationCoefficient() > Double.parseDouble(databaseCoefficient) ){
        if( model.toString().contains("SWL") || model.toString().contains("SAL") ||
model.toString().contains("ELM") || model.toString().contains("IWS") || model.toString().contains("ELE") ){
            // Save regression coefficients
            LOG.info("Correlation coef > databaseCoefficient");
            Regression regression = new Regression(model, data);
            ModelManager.setObjectValue(regression_key, regression,
coefficient+"" , relative+"" );

            Query query;
            transaction.begin();
            List<?> result = Student.getStudents(topic);
            RegressionModel rm = new RegressionModel(regression_key,

            System.out.println("\n"+regression.coefficients.toString()+"\n");
            Double maxswl = (double)5;
            Double maxsal = (double)5;
            Double maxelm = (double)5;
            Double maxiws = (double)5;
            Double maxele = (double)5;

            for( Coefficient c : rm.coefficients ){

                switch( c.name ){
                    case "SWL":
                        if( Double.parseDouble(c.value) < 0 )
                            maxswl = (double)1;
                        break;

```



```

        } finally {
            if( transaction.isActive() )
                transaction.commit();
        }
    }

    public static Evaluation getRegression2(String topic) {
        Evaluation eval =null;
        System.out.println("//////////////////////////////// //"+topic+" : "+ "STEM"+ " //////////////////////////////////////////////////\n");
        String statement = QUERY_STRING + " and Topic is " + topic + "" ;
        Instances data = retrieveModelInstances(statement); // get
instances from database

        data.setClassIndex(data.numAttributes() - 1);
        LinearRegression model = new LinearRegression(); // create new
linear regression model
        try {
            try {
                model.buildClassifier(data);
            } catch (Exception e) {
                // TODO Auto-generated catch block
                e.printStackTrace();
            }
        } //

        LOG.debug(model);
        System.out.println(model);
        String[] options = new String[2]; // options for remove
        options[0] = "-R"; // "range"
        options[1] = "1"; // first attribute
        Remove remove = new Remove(); // new instance of filter
        remove.setOptions(options); // set options
        remove.setInputFormat(data);

        eval= new Evaluation(data); //
new evaluation model for given instances
        int instances = data.numInstances();
        if( instances > 10)
            instances = 10;
        eval.crossValidateModel(model, data, instances, new Random(1)); // crossvalidate model
        double coefficient = eval.correlationCoefficient(); // get
correlation coefficient

        double relative = eval.relativeAbsoluteError();
        //System.out.println("Linear regression: **");
        //System.out.println(eval.toSummaryString());
        //System.out.print(" the expression for the input data as per algorithm is ");
        //System.out.println(eval.toMatrixString());
        // System.out.println(eval.toClassDetailsString());
        try {
            LOG.info( "Relative absolute error: " + eval.relativeAbsoluteError());
        } catch (Exception e) {
            // TODO Auto-generated catch block
            e.printStackTrace();
        }

        System.out.println( "Mean absolute error: " + eval.meanAbsoluteError());
        System.out.println( "Root mean squared error: " + eval.rootMeanSquaredError());
        try {
            System.out.println( "Relative absolute error: " + eval.relativeAbsoluteError());
        } catch (Exception e) {
            // TODO Auto-generated catch block
            e.printStackTrace();
        }

        System.out.println( "Root relative squared error: " + eval.rootRelativeSquaredError());
        System.out.println( "Number of instances: " + eval.numInstances());
        Instance studentb = data.instance(0);
        double pu;
        try {
            pu = model.classifyInstance(studentb);
            System.out.println("\n\n"+studentb+" : "+ pu +"\n\n");
        } catch (Exception e) {
            // TODO Auto-generated catch block
            e.printStackTrace();
        }

    } catch (Exception e1) {

```

```
        // TODO Auto-generated catch block
        e1.printStackTrace();
    } finally {
        //if( transaction.isActive() )
        //transaction.commit();
    }
    return eval;
}
}
```

10. Pielikums.

Indivīda e-iekļaušanas prognozēšanas prototipa ekrānu skati

Ekrāna skats darbībām ar datu failiem, kas tiek izmantoti modeļu apmācībai vai indivīda e-iekļautības prognozei

The screenshot shows the 'Edit database' page of the Einclusion application. The header features the 'Einclusion' logo and a navigation menu with items: EDIT DATABASE, M1, M2, M3, PREDICTION, REPORT, and COEFFICIENTS. A breadcrumb trail indicates the current location: Home > Edit database. The main content area is titled 'Edit database' and includes several interactive elements:

- A section titled 'Select a file to upload:' with a 'Select file' button.
- A section titled 'Select file to update database parameters' with three buttons: 'Select file to train model', 'Create/OPEN Template', and 'Export and open all data'.
- A section titled 'Delete from database' containing a dropdown menu set to 'All', a 'Refresh names' button, and a 'Delete from database' button.

Ekrāna skats indivīda e-iekļautības prognozes rezultātam ar Modeli M1, kas izmanto klasifikācijā balstītas metodes



Einclusion

[EDIT DATABASE](#) [M1](#) [M2](#) [M3](#) [PREDICTION](#) [REPORT](#) [COEFFICIENTS](#)

Home > M1

Base evaluation

Name your file:

Export to xls

Prediction: **Green** - included, **Red** - not included

Phone	Topic	Name	Instructor	E-environment	E-materials	Before learning	Submit date	M1
1001	STEM	RVU1	5.00	4.00	5.00	1.00	2015-05-04	Red
1010	STEM	RVU10	5.00	3.50	2.50	1.00	2015-05-15	Red
1011	STEM	RVU11	5.00	5.00	5.00	1.00	2015-05-15	Red
1012	STEM	RVU12	4.00	4.00	4.00	1.00	2015-05-15	Red
1013	STEM	RVU13	4.00	3.00	4.00	1.00	2015-06-18	Red
1014	STEM	RVU14	5.00	4.00	4.00	1.00	2015-07-03	Green

Ekrāna skats indivīda e-iekļautības prognozes rezultātam ar Modeli M2, kas izmanto klasteranalīzē balstītas metodes

The screenshot displays the 'Einclusion' web application interface. At the top, there is a navigation bar with the logo and menu items: EDIT DATABASE, M1, M2, M3, PREDICTION, REPORT, and COEFFICIENTS. The main content area shows a breadcrumb trail 'Home > M2' and a title 'Cluster evaluation'. Below the title, there is a text input field labeled 'Name your file:' and a blue 'Export to xls' button. A legend indicates 'Prediction: Green - included, Red - not included'. The main part of the interface is a table with 11 columns: Phone, Topic, Name, Motivation, Digital skills, Learning ability, E-materials, Instructor, E-environment, Predicted usage, Submit date, and M2. The M2 column contains colored cells (green or red) representing the prediction for each row.

Phone	Topic	Name	Motivation	Digital skills	Learning ability	E-materials	Instructor	E-environment	Predicted usage	Submit date	M2
1001	STEM	RVU1	3.00	3.00	2.00	5.00	5.00	4.00	2.00	2015-05-04	Red
1010	STEM	RVU10	3.00	4.00	2.33	2.50	5.00	3.50	3.00	2015-05-15	Red
1011	STEM	RVU11	3.00	3.50	2.00	5.00	5.00	5.00	5.00	2015-05-15	Green
1012	STEM	RVU12	3.00	4.50	2.33	4.00	4.00	4.00	3.00	2015-05-15	Red
1013	STEM	RVU13	4.00	4.00	3.00	4.00	4.00	3.00	3.00	2015-06-18	Red
1014	STEM	RVU14	4.00	4.00	4.00	4.00	5.00	4.00	4.00	2015-07-03	Green

Ekrāna skats indivīda e-iekļautības prognozes rezultātam ar Modeli M3, kas izmanto lineārā regresijā balstītas metodes



Home > M3

Linear regression evaluation

Name your file:

Export to xls

Prediction: **Green** - included, **Red** - not included

Phone	Topic	Name	Motivation	Learning ability	E-materials	E-environment	Submit date	M3
1001	STEM	RVU1	3.00	2.00	5.00	4.00	2015-05-04	Red
1010	STEM	RVU10	3.00	2.33	2.50	3.50	2015-05-15	Red
1011	STEM	RVU11	3.00	2.00	5.00	5.00	2015-05-15	Red
1012	STEM	RVU12	3.00	2.33	4.00	4.00	2015-05-15	Red
1013	STEM	RVU13	4.00	3.00	4.00	3.00	2015-06-18	Red
1014	STEM	RVU14	4.00	4.00	4.00	4.00	2015-07-03	Red
1015	STEM	RVU15	4.00	3.00	4.00	4.00	2015-07-03	Red

Ekrāna skats indivīda e-iekļautības fināla prognozes rezultātam

Precision level: **Green** - high (e-included), **Red** - high (not e-included), **Yellow** - low

Prediction: **Green** - e-included, **Red** - not e-included

Phone	Topic	Name	Submit date	M1	M2	M3	Prediction	Precision
1001	STEM	RVU1	2015-05-04	Red			Risk	High
1010	STEM	RVU10	2015-05-15	Red			Risk	High
1011	STEM	RVU11	2015-05-15	Red			Risk	High
1012	STEM	RVU12	2015-05-15	Red			Risk	High
1013	STEM	RVU13	2015-06-18	Red			Risk	High
1014	STEM	RVU14	2015-07-03	Green	Green	Red	Risk	Low
1015	STEM	RVU15	2015-07-03	Red			Risk	High
1016	STEM	RVU16	2015-07-03	Green	Green	Red	Risk	Low
1017	STEM	RVU17	2015-07-03	Green	Green	Green	No risk	High
1018	STEM	RVU18	2015-07-03	Green	Green	Green	No risk	High
1019	STEM	RVU19	2015-07-03	Red			Risk	High
1002	STEM	RVU2	2015-05-09	Red			Risk	High
1020	STEM	RVU20	2015-07-07	Green	Green	Red	Risk	Low
1021	STEM	RVU21	2015-07-07	Green	Green	Red	Risk	Low
1022	STEM	RVU22	2015-07-07	Green	Green	Green	No risk	High
1023	STEM	RVU23	2015-07-07	Green	Green	Green	No risk	High
1024	STEM	RVU24	2015-07-07	Green	Green	Green	No risk	High

Ekrāna skati ar detalizētu informāciju par indivīdu raksturojošiem faktoriem un to atbilstību prognozes modeļa kritērijiem

Precision level: **Green** - high (e-included), **Red** - high (not e-included), **Yellow** - low

Prediction: **Green** - e-included, **Red** - not e-included

Phone	Topic	Name	Submit date	M1	M2	M3	Prediction	Precision
1001	STEM							High
1010	STEM							High
1011	STEM							High
1012	STEM							High
1013	STEM							High
1014	STEM							Low
1015	STEM							High
1016	STEM							Low
1017	STEM							High
1018	STEM	RVU18	2015-07-03				No risk	High
1019	STEM	RVU19	2015-07-03				Risk	High
1002	STEM	RVU2	2015-05-09				Risk	High
1020	STEM	RVU20	2015-07-07				Risk	Low
1021	STEM	RVU21	2015-07-07				Risk	Low
1022	STEM	RVU22	2015-07-07				No risk	High
1023	STEM	RVU23	2015-07-07				No risk	High
1024	STEM	RVU24	2015-07-07				No risk	High

M3 results for: RVU16

motivation: 4.00
e-included approximation: **75%**
size of the effect: 30 %
learning ability: 1.00
e-included approximation: **0%**
size of the effect: 16 %
e-materials: 4.00
e-included approximation: **75%**
size of the effect: 36 %
e-environment: 4.50
e-included approximation: **88%**
size of the effect: 18 %

OK

Precision level: **Green** - high (e-included), **Red** - high (not e-included), **Yellow** - low

Prediction: **Green** - e-included, **Red** - not e-included

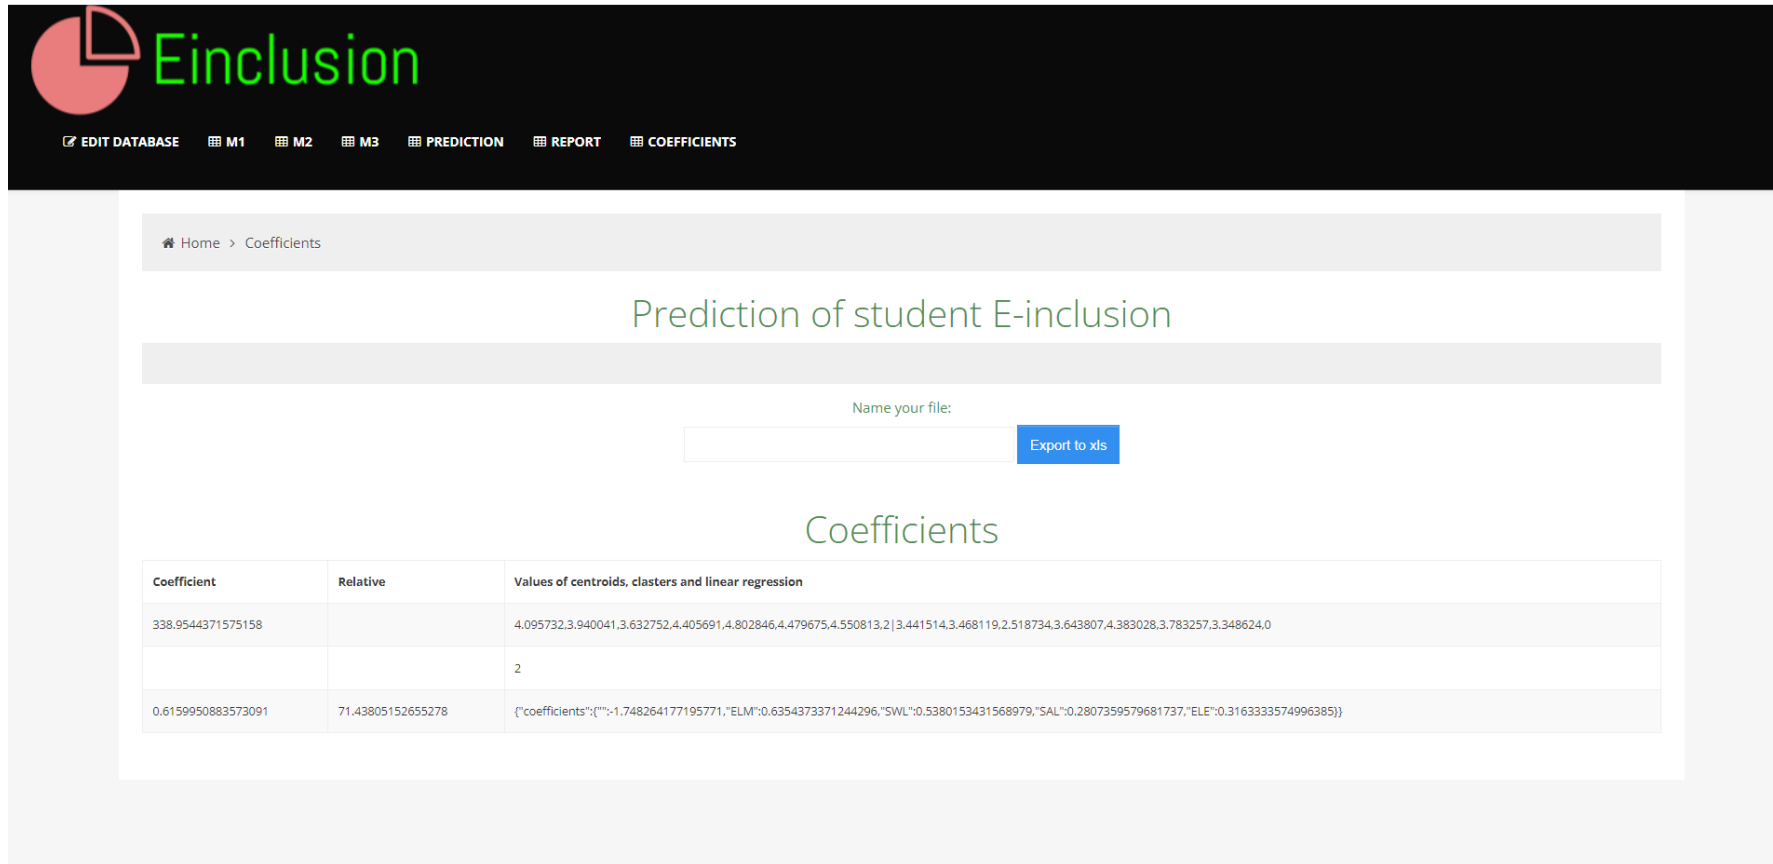
Phone	Topic	Name	Submit date	M1	M2	M3	Prediction	Precision
1001	STEM							High
1010	STEM							High
1011	STEM							High
1012	STEM							High
1013	STEM							High
1014	STEM							Low
1015	STEM							High
1016	STEM							Low
1017	STEM						Risk	High
1018	STEM						Risk	High
1019	STEM	RVU19	2015-07-03				Risk	High
1002	STEM	RVU2	2015-05-09				Risk	High
1020	STEM	RVU20	2015-07-07				Risk	Low
1021	STEM	RVU21	2015-07-07				Risk	Low
1022	STEM	RVU22	2015-07-07				No risk	High
1023	STEM	RVU23	2015-07-07				No risk	High
1024	STEM	RVU24	2015-07-07				No risk	High

M2 results for: RVU16

motivation: 4.00
e-included approximation: **97%**
digital skills: 5.00
e-included approximation: **136%**
learning ability: 1.00
e-included approximation: **0%**
e-materials: 4.00
e-included approximation: **88%**
instructor: 5.00
e-included approximation: **105%**
e-environment: 4.50
e-included approximation: **101%**
predicted usage: 5.00
e-included approximation: **113%**

OK

Ekrāna skats ar prognozes modeļu parametriem



The screenshot displays the 'Einclusion' web application interface. At the top, there is a navigation bar with a logo and menu items: EDIT DATABASE, M1, M2, M3, PREDICTION, REPORT, and COEFFICIENTS. The main content area is titled 'Prediction of student E-inclusion' and includes a form for 'Name your file:' with an 'Export to xls' button. Below this, the 'Coefficients' section features a table with three columns: Coefficient, Relative, and Values of centroids, clusters and linear regression.

Coefficient	Relative	Values of centroids, clusters and linear regression
338.9544371575158		4.095732,3.940041,3.632752,4.405691,4.802846,4.479675,4.550813,2 3.441514,3.468119,2.518734,3.643807,4.383028,3.783257,3.348624,0
		2
0,6159950883573091	71.43805152655278	{"coefficients":{"":""-1.748264177195771,"ELM":0.6354373371244296,"SWL":0.5380153431568979,"SAL":0.2807359579681737,"ELE":0.3163333574996385}}