

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-IEKĻAUSĀNAS PROCESU UN TEHNOLOĢISKO RISINĀJUMU PĒTĪJUMI

Promocijas darba kopsavilkums

Zinātniskais vadītājs
Dr. phys.
ATIS KAPENIEKS

RTU Izdevniecība
Rīga 2021

Vītoliņa I. E-iekļaušanas procesu un tehnoloģisko risinājumu pētījumi. Promocijas darba kopsavilkums. Rīga: RTU Izdevniecība, 2021. – 59 lpp.

Iespiests saskaņā ar promocijas padomes „RTU P-21” 2021. gada 21. septembra lēmumu, protokols Nr. 1.

NACIONĀLAIS
ATTĪSTĪBAS
PLĀNS 2020



EIROPAS SAVIENĪBA
Eiropas Sociālais
fonds

I E G U L D Ī J U M S T A V Ā N Ā K O T N Ē

<https://doi.org/10.7250/9789934226977>

ISBN 978-9934-22-697-7 (pdf)

PROMOCIJAS DARBS IZVIRZĪTS ZINĀTNES DOKTORA GRĀDA IEGŪŠANAI RĪGAS TEHNISKAJĀ UNIVERSITĀTĒ

Promocijas darbs zinātnes doktora (*Ph. D.*) grāda iegūšanai tiek publiski aizstāvēts 2021. gada 16. decembrī plkst. 11 Rīgas Tehniskās universitātes E-studiju tehnoloģiju un humanitāro zinātņu fakultātē, Kronvalda bulvārī 1, 200. auditorijā.

OFICIĀLIE RECENZENTI

Sarma Cakula, *Dr. paed.*, RTU promocijas padome „RTU P-21”

Māris Vītiņš, *Dr. comp.*, Latvijas Universitāte

Peter Francis Chatterton, Ph. D. (fizika) Londonas Universitāte, *Daedalus e-World*
(Apvienotā Karaliste)

APSTIPRINĀJUMS

Apstiprinu, ka esmu izstrādājusi šo promocijas darbu, kas iesniegts izskatīšanai Rīgas Tehniskajā universitātē zinātnes doktora (*Ph. D.*) grāda iegūšanai. Promocijas darbs zinātniskā grāda iegūšanai nav iesniegts nevienā citā universitātē.

Ieva Vītoliņa (paraksts)

Datums:

Promocijas darbs ir uzrakstīts latviešu valodā, tajā ir ievads, 4 nodaļas, secinājumi, literatūras saraksts, 52 attēli, 35 tabulas, 10 pielikumu, kopā 184 lappuses, neieskaitot pielikumus. Literatūras sarakstā ir 387 nosaukumi.

Saturs

DARBA VISPĀRĒJS RAKSTUROJUMS.....	5
Pētījuma problēmsituācija un pamatojums.....	5
Pētījuma objekts.....	7
Pētījuma priekšmets.....	7
Pētījuma mērķis.....	7
Pētījuma jautājumi.....	7
Pētījuma darba uzdevumi.....	9
Aizstāvēšanai izvirzītās tēzes.....	9
Pētījuma metodes.....	10
Pētījuma posmi.....	10
Pētījuma bāze.....	11
Pētījuma zinātniskā novitāte, teorētiskā un praktiskā nozīme.....	11
Rezultātu aprobācija.....	12
Promocijas darba struktūra.....	14
1. E-IEKĻĀUŠANAS UN TĀS PROCESU ANALĪZE.....	14
1.1. Metodes izvēle e-iekļaušanu aprakstošā modeļa izveidē.....	14
1.2. E-iekļaušanas un tās procesu modelis.....	14
1.3. Kopsavilkums un secinājumi.....	18
2. E-IEKĻĀUŠANAS PROGNOZĒŠANAS TEHNOLOĢIJU UN METOŽU ANALĪZE.....	19
2.1. Prognozēšanas, mācību analītikas un saistīto jēdzienu skaidrojums.....	19
2.2. Prognozējošu modeļu izveides metodes un tehnoloģijas.....	20
2.3. Prognozējošu modeļu novērtēšanas metodes un veikspējas rādītāji.....	20
2.4. Studentu sasniegumu prognozēšanā izmantoto pazīmju raksturojums.....	23
2.5. Studentu sasniegumus prognozējošo modeļu raksturojums.....	24
2.6. Prognozējošu informācijas sistēmu darbības procesi mašīnmācīšanās tehnoloģiju kontekstā.....	25
2.7. Prognozējoša modeļa izveides process un tā lietojums e-iekļaušanu prognozējošā tehnoloģiskā modeļa izveidē.....	26
2.8. E-iekļaušanu prognozējošā modeļa izveides posmi.....	26
3. INDIVĪDA E-IEKĻĀUŠANU IETEKMĒJOŠO FAKTORU UN PROGNOZĒJOŠO MODEĻU PĒTĪJUMS ZINĀŠANU RADĪŠANAS UN PĀRNESES PROCESA KONTEKSTĀ.....	27
3.1. Zināšanu pārvaldības teorijā balstīti e-iekļaušanu ietekmējošie faktori.....	27
3.2. Datu ieguve un sagatavošana pētījumiem par prognozējošo modeļu izveidi un iespējamo e-iekļaušanu ietekmējošo faktoru pārbaudi.....	29
3.3. Lineārās regresijas pieejā balstīta e-iekļaušanu prognozējošā modeļa izveide un prognozi ietekmējošo faktoru izvērtējums.....	30
3.4. Indivīda e-iekļautību raksturojošu klasteru izveide un e-iekļautību ietekmējošo faktoru atšķirību izvērtējums klasteros.....	32
3.5. Indivīda e-iekļautības modelēšana ar klasifikācijas algoritmiem un e-iekļautības faktoriem.....	34
3.6. Indivīda e-iekļautību prognozējošā algoritmiskā modeļa izveide.....	35
4. TEHNOLOĢISKAIS MODELIS UN TĀ NOVĒRTĒJUMS INDIVĪDA e-IEKĻAUTĪBAS PROGNOZĒŠANAI.....	39
4.1. E-iekļaušanu prognozējošas sistēmas funkcionālās prasības un galvenie darbības principi.....	39
4.2. E-iekļaušanu prognozējošas sistēmas prototips.....	43
4.3. E-iekļaušanu prognozējošā algoritmiskā modeļa un prototipa novērtējums.....	44
SECINĀJUMI.....	47
IZMANTOTĀ LITERATŪRA.....	50

DARBA VISPĀRĒJS RAKSTUROJUMS

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 iesaistīšana 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 nevienam 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 spējam 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). Šīs 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; *Bélanger 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-iekļautos 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 neaptvertas 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 plaiss 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 iespējamās 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, 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 veikspējās rādītājiem, paredzot indivīda e-iekļautību;

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

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

Lai noskaidrotu, cik lielā mērā, kombinējot lineārās regresijas, klasteranalīzes un klasifikācijas metodes, ir iespējams izveidot e-iekļautību prognozējošu modeli ar augstākiem veikspējas 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 veikspējas 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 veikspēju 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 veikspējas rādītājus) prognozēt e-iekļautību indivīdiem, kas apgūst digitālās prasmes kursus, 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 prognozējošo 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 studentus raksturojošajiem faktoriem zināšanu pārvaldības aspektā. Zinātniskās literatūras izpēte un analīze par studentus 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 (*Naïve 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

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

2013.–2014. gads: sākta 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). Comparision 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). Comparision 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, ko veido ievads, četras nodaļas, nobeigums un literatūras avoti.

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 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 apkopoti promocijas darba rezultāti un secinājumi, kā arī turpmāko pētījumu virzieni un iespējas.

1. E-IEKĻĀUŠANAS UN TĀS PROCESU ANALĪZE

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

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

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

E-iekļaušanas aprakstošā modeļa sākotnējā versija dota autorei publikācijā [1] (skatīt darbu uzskaitījumu nodaļā “Darba vispārējs raksturojums”).

1.1. Metodes izvēle e-iekļaušanu aprakstošā modeļa izveidē

Saskaņā ar J. Bubenko (2007) teoriju uzņēmuma modelēšana ir process, kura rezultātā tiek radīts modelis, kas atspoguļo uzņēmumu vai kādu objektu no dažādiem aspektiem. Izvērtējot metožu dokumentācijas pieejamības ērtumu un esošās iestrādes modelēšanā, promocijas darbā e-iekļaušanas modelēšanai tika izvēlēta *4EM* (iepriekš zināma kā *EKD*) metode (Stirna un Persson, 2018).

4EM metode paredz, ka tiek veidots vienots modelis, kas sastāv no vairākiem 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 (Stirna un Persson, 2018).

1.2. E-iekļaušanas un tās procesu modelis

Modelējot e-iekļaušanas procesus, autore veic atkāpes no *4EM* vadlīnijām, jo netiek organizēts modelēšanas seminārs, bet kā zināšanu avotus autore izmanto dokumentus – ES vai zinātnieku pētījumus, ES politikas plānošanas dokumentus un ziņojumus par sasniegto, kā arī statistikas datus. Kā darba rezultāts ir iegūts e-iekļaušanu aprakstošs *4EM* modelis, kas sastāv no e-iekļaušanas mērķu modeļa, likumu modeļa, resursu un dalībnieku modeļa, jēdzienu

modeļa, procesu modeļa (modeļu pilnās versijas ir pieejamas promocijas darbā).

E-iekļaušanas mērķu modelis

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*).

Autore e-iekļaušanas mērķu modelī kā galvenos stratēģiskos mērķus izmanto 2006. gada e-iekļaušanas deklarācijā inoteiktos sešus 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.

E-iekļaušanas deklarācijā tika noteikti seši stratēģiskie mērķi, kas līdz 2010. gadam bija jāsasniedz: (1) risināt gados vecāko strādājošo un gados vecāku cilvēku vajadzības; (2) samazināt ģeogrāfiskās digitālās robežšķirtnes; (3) uzlabot e-pieejamību un lietojamību; (4) uzlabot digitālās prasmes un digitālo prātību; (5) veicināt kultūras daudzveidību saistībā ar iekļaušanu; (6) veicināt iekļaujošas e-pārvaldes attīstību.

Tomēr e-iekļaušanas deklarācijas mērķi atbilstoši noteiktajiem skaitliskajiem rādītājiem netika sasniegti, un 2010. gadā Eiropas Komisija nāca klajā ar Digitālo programmu Eiropai, kurā tika definēti ES digitālās jomas mērķi 2020. gadam (*European Commission, 2010*). Digitālā programma Eiropai aktualizē 2006. gadā e-iekļaušanas deklarācijā noteiktos mērķus. 2019. gadā Eiropas Komisija publicēja digitālo stratēģiju nākamajiem 10 gadiem, un 2021. gada 10. martā Eiropas Komisija piedāvāja Digitālo kompasu (*European Commission, 2020; European Commission, 2021*). Digitālais kompass turpina īstenot e-iekļautības mērķus, uzsverot, ka digitālajā telpā ir jānodrošina, ka tās pašas tiesības, kas darbojas bezsaistē, ir pilnībā īstenojamas tiešsaistē. Lai to nodrošinātu, cilvēkiem ir jābūt pieejamai drošai un kvalitatīvai piekļuvei internetam, iespējai apgūt digitālās prasmes, piekļuvei nediskriminējošiem digitālajiem pakalpojumiem.

Šķēršļi e-iekļaušanas stratēģisko mērķu sasniegšanai. Analizējot problēmas, kas traucē sasniegt mērķus, var secināt, ka dažādu stratēģisko mērķu sasniegšanai atkārtoti rodas vairāki šķēršļi.

1) IKT nepieejamība, piemēram, nav pieslēguma internetam, nav pieejams dators vai viedierīce vecāka gadagājuma cilvēkiem vai imigrantiem, nav atbilstoši izstrādāti pakalpojumi vecāka gada gājuma cilvēkiem un nodrošināta to e-pieejamība un lietojamība (*Driessen u. c., 2011; European Commission, 2006; European Commission, 2010; European Commission, 2020c; European Commission, 2021; Rana u. c., 2013; Soja u. c., 2019*).

2) Digitālo prasmju trūkums vecāka gadagājuma cilvēkiem un iedzīvotājiem ekonomiski mazāk attīstītos reģionos (*Chena, Liu, 2013; European Commission, 2006; European Commission, 2010; European Commission, 2021; Khalil Moghaddam un Khatoon-Abadi, 2013*), cilvēkiem ar īpašām vajadzībām (*Benda u. c., 2011; Farbeh-Tabrizi, 2012*), imigrantiem un etniskajām minoritātēm (*Lupiañez u. c., 2015; Yu u. c., 2018*).

3) Sociāldemogrāfiskie un ekonomiskie faktori, piemēram, vecāka gadagājuma cilvēkiem ir ierobežots finansējums vai iedzīvotāji nevar atļauties apmaksāt interneta pieslēgumu (*Ala-*

Mutka u. c., 2008; Amy, 2011; Townsend u. c., 2013).

Analizējot nosacījumus, kas ietekmē e-iekļaušanas mērķu sasniegšanu, var redzēt, ka tieši pasākumi **digitālo prasmju uzlabošanai** ir nepieciešami ikviena e-iekļaušanas stratēģiskā mērķa sasniegšanai. Digitālās prasmes ir atzītas par vienu no astoņām pamatprasmēm, kas ir būtiski svarīgas ikkatram cilvēkam (Eiropas Padome, 2006; Eiropas Padome, 2018). Eiropas Komisija ir definējusi mērķi līdz 2030. gadam panākt, ka vismaz 80 % visu pieaugušo ir apguvuši digitālās pamatprasmes.

Digitālās izglītības ekosistēma – digitālo prasmju uzlabošanas sekmēšanai. Regulāra prasmju pilnveide ir nepieciešama, lai uzturētu prasmes atbilstoši tehnoloģiju attīstības tendencēm (*European Commission*, 2010). Būtiski ir attīstīt augstas veiktspējas digitālās izglītības ekosistēmu, lai sekmētu digitālo prasmju uzlabošanu (*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), otrkārt, digitālo tehnoloģiju izmantošanu pedagoģiskajā darbā, izglītības un apmācības sistēmās (*European Commission*, 2018). 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).

Datu analīzes un prognozēšanas nodrošināšana digitālo prasmju uzlabošanas sekmēšanai. Digitālās izglītības rīcības plāns 2018.–2020. gadam uzsver datu nozīmi digitālās izglītības nodrošināšanā, par vienu no prioritātēm izvirzot labākas datu analīzes un prognozēšanas nodrošināšanu (*European Commission*, 2018). Digitālās izglītības rīcības plāns nosaka nepieciešamību veikt eksperimentālus projektus izglītības jomā saistībā ar mākslīgo intelektu un mācību analītiku, lai sekmētu digitālās izglītības nodrošināšanu. 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, un jāņem vērā, ka ES mācību analītika ir tās izpētes sākumposmā (*Ferguson u. c.*, 2016; *Maennel*, 2020; *Viberg u. c.*, 2018). Tādēļ nepieciešami papildu pētījumi.

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

Autore, veidojot e-iekļaušanas stratēģisko mērķu modeli, secina, ka digitālo prasmju uzlabošana ir nepieciešama ikviena e-iekļaušanas stratēģiskā mērķa sasniegšanai un digitālās prasmes ir viens no būtiskākajiem priekšnoteikumiem indivīda e-iekļaušanai, tāpēc indivīda e-iekļaušanas procesa modelis tiek balstīts digitālo prasmju apguvē.


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

Lai indivīds nonāktu pie jēgpilnas IKT lietošanas, jānodrošina vairāki e-iekļaušanas procesa posmi (1.1. att.) (*Scheerder u. c.*, 2017; *van Dijk*, 2006; *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).

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 (Lerchner u. c., 2007; Ono un Zavodny, 2008). Mūsdienās tiek ieviests jēdziens „3. paaudzes digitālā plaisa”, kas ir izveidojusies starp tiem, kas lieto jēgpilni tehnoloģijas, gūstot labumu profesionālām vajadzībām vai personības pilnveidei, un tiem, kuri tehnoloģijas lieto, bet negūst no tām ne profesionālām, 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** (van Deursen un van Dijk, 2015).



1.1. att. Indivīda e-iekļaušanas procesa modelis.

E-iekļaušanas process indivīdam atkārtojas, parādoties jaunai IKT (van Dijk, 2006; Yu u. c., 2018). E-iekļaušanas kontekstā ir jārunā par indivīda situatīvo e-iekļaušanu, kas attiecas uz konkrētas tehnoloģijas izmantošanu konkrētam mērķim konkrētā situācijā. Indivīda kopējo e-iekļautību veido tā situatīvās e-iekļaušanas kopums.

E-iekļaušanas mērķgrupas

E-iekļaušana attiecas praktiski uz ikvienu iedzīvotāju. E-iekļaušanas mērķgrupu veido: strādājošie pirmspensijas vecumā; pensijas vecumā esošie indivīdi; personas ar zemākiem ienākumiem; personas ar zemu vispārējo izglītības līmeni; personas no mazāk attīstītiem reģioniem; cilvēki ar īpašām vajadzībām; sievietes; bezdarbnieki; imigranti; etniskās minoritātes (Basili, 2013; de Hoyos u. c., 2013).

Pretēji uzskatam, ka paaudzei, kas ir iepazinusi internetu jau bērnībā, nav problēmu

interneta lietošanā, tiek norādīts, ka šai paaudzei trūkst digitālās prasmes, respektīvi, prasmes jēgpilni lietot internetu (informācijas un stratēģiskās prasmes) (*Santos u. c., 2013; van Deursen un van Dijk, 2009*).

Digitālo prasmju uzlabošana ir būtiska komponente, kas jānodrošina topošajiem nodarbinātajiem un jāpildina esošajiem nodarbinātajiem. Viena no iekļaušanas mērķgrupām, ko profesionālajā darbībā aizvien vairāk ir nepieciešams jēgpilni izmantot IKT iespējas, ir izglītības darbinieki (*Altun, 2019; Rintamäki un Lehto, 2018; Záhorec u. c., 2019*). 2014. gadā 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). Ekonomiskās sadarbības un attīstības organizācijas (ESAO) 2018. gada pētījums (*Jerrim un Sims, 2019*) liecina, ka mazāk nekā 40 % pedagogu jutās gatavi izmantot digitālās tehnoloģijas mācību procesā un ka ES ietvaros ir lielas atšķirības. Pedagogu apmācība ir nepieciešama gan tāpēc, lai uzlabotu pedagogu digitālās prasmes, gan arī tāpēc, lai vēlāk pedagogi kļūtu par augstas veiktspējas digitālās izglītības ekosistēmas sastāvdaļu.

1.3. Kopsavilkums un secinājumi

Par būtiskāko mērķi e-iekļaušanas kopējo mērķu sasniegšanā var uzskatīt digitālo prasmju uzlabošanu. Uzlabojot indivīdu digitālās prasmes, tiek sekmēta arī citu e-iekļaušanas politikas mērķu sasniegšana. Vissvarīgākā ikvienam indivīdam ir digitālo prasmju jēgpilna izmantošana, kas cieši ir saistīta gan ar tehnoloģiju pieejamību, gan digitālo prasmju apguvi.

1) Nepieciešams panākt efektīvu indivīdu pāreju no e-iekļaušanas procesa posma, kurā tas apgūst digitālās prasmes, uz nākamo, pēdējo e-iekļaušanas procesa posmu, kurā indivīds jēgpilni izmanto apgūtās digitālās prasmes. Promocijas darbā pētīts, kā nodrošināt to, ka indivīds no e-iekļaušanas procesa 3. posma nonāk e-iekļaušanas 4. (noslēguma) posmā, iegūtās digitālās prasmes jēgpilni lietojot profesionālām vai privātām vajadzībām, kā panākt to, ka samazinās jēgpilnas lietošanas plaša.

2) Nepieciešams noteikt faktorus, 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 faktorus, un, ņemot vērā šos faktorus, secina, kāds vecums, dzimums un citi raksturojoši lielumi ir cilvēkiem, kuriem ir digitālās prasmes un kuri tās jēgpilni izmanto. Tomēr jāņem vērā tas, ka sociāldemogrāfiskie un ekonomiskie faktori ir grūti izmaināmi lielumi, un jāmeklē ir indivīdu raksturojoši faktori zināšanu radīšanas un pārneses procesu kontekstā, kuru vērtības mācību procesā ir iespējams ietekmēt.

3) Nepieciešams digitālo prasmju apmācību indivīdu e-iekļaušanas nolūkā veikt interneta vidē, kombinējot to ar klātienes tikšanās. Mācības, izmantojot interneta vidi, atbilst ES Rīcības plānam digitālās izglītības jomā (2021–2027), kas aicina pielāgot izglītības un apmācības sistēmas digitālajam laikmetam.

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 izvēles pamatojums balstās tajā, ka lielākajai daļai pedagogu nav pietiekamu digitālo prasmju. 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.

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

Autore promocijas darbā izvirza e-iekļaušanu prognozējošajam modelim šādus mērķus:

1) izmantojot mācību analītikas iespējas, noteikt individu, kuram ir risks, ka tas nelielos nodarbībās jaunapgūtās digitālās prasmes (risks, ka indivīds nebūs e-iekļauts);

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

2. E-IEKĻAUŠANAS PROGNOZĒŠANAS TEHNOLOĢIJU UN METOŽU ANALĪZE

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

1) Izpētīta zinātniskā literatūra par prognozējošo modeļu izveides tehnoloģijām un metodēm, mācību analītiķu, 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) Noteikti indivīda e-iekļaušanu prognozējošā modeļa izveides procesa posmi.

2.1. Prognozēšanas, mācību analītikas un saistīto jēdzienu skaidrojums

Ar **prognozēšanu** tiek saprasta fakts, novērojums vai pieņēmums balstīta paredzēšana, nākotnes tēla veidošana ar noteiktu varbūtības pakāpi (Skujiņa, 2000). Prognozēšanas metodes var iedalīt kvalitatīvās un kvantitatīvās (Anderson u. c., 2012; Tilde, 2014).

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, 2014).

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 analītikā ir iesaistītas trīs galvenās lietotāju grupas: izglītojamie; pedagogi/instruktori; iestādes (Miteva un Stefanova, 2020; Ortiz-Rojas u. c., 2019).

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).

Mācību analītikā prognozēšanas modeļu izveidē izmanto statistikas, datizraces un mašīnmācīšanās metodes un tehnoloģijas (Lenar u. c., 2019).

Pieaugošais ar apmācības procesu saistīto datu apjoms un to pieejamība dod iespēju

studentu datu analīzē izmantot jaunas pieejas, kas jau līdz šim ir lietotas 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 nezināmus notikumus, izmantojot statistikas un datizraces tehnikas. Mašīnmācīšanās procesa mērķis ir nodrošināt datorprogrammai apmācību, balstoties pagātnes pieredzē (*Cios u. c.*, 2002).

2.2. Prognozējošu modeļu izveides metodes un tehnoloģijas

Prognozējošu modeļu izveidē ir iespējams izmantot statistiskā, datizracē un mašīnmācīšanās tehnoloģijā balstītas metodes un algoritmus. Mašīnmācīšanās tiek izmantotas vairākas stratēģijas (*Schuh u. c.*, 2020): neuzraudzītā apmācīšana; uzraudzītā apmācīšana; daļēji uzraudzītā apmācīšana; stimulētā apmācīšana. Neuzraudzītās apmācības piemērs ir klasterēšanas uzdevumi, kad no ieejas datiem jāatrod potenciāli svarīgas grupas. Uzraudzītajā apmācīšanās notiek mēģinājums apmācīt, kādas attiecības pastāv starp ieejas datiem un gaidāmajiem rezultātiem. Ar uzraudzītās apmācības stratēģiju tiek risināti klasifikācijas un regresijas uzdevumi.

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). Viens no algoritmiem, kas ir izmantots klasteranalīzē prognozēšanas mērķiem, ir *kMeans* algoritms (*Sorour u. c.*, 2014; *Tamada u. c.*, 2019).

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 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 (*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. 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. 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*). Citi slinkās mācīšanās algoritmi ir balstīti *Locally Weighted Learning* pieejā.

Mašīnmācīšanās regresijas uzdevums ir iemācīt modelim, kā prognozēt nākotnes notikumus ar skaitlisku vērtību (nevis nominālā skalā), izmantojot iepriekš zināmas piemēru vērtības un to, kā tās ietekmē atkarīgā atribūta vērtību. 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.

2.3. Prognozējošu modeļu novērtēšanas metodes un veikspējas rādītāji

Prognozējošu modeļu novērtēšana

Galvenās metodes modeļa novērtēšanai ir jaunu datu kolekcionēšana, lai pārbaudītu prognožu precizitāti, vai esošo datu sadalīšana vairākās kopās, lai iegūtu neatkarīgus modeļa precizitātes mērījumus (Snee, 1977). Esošo datu sadalīšanu apakškopās modeļa precizitātes novērtējumam var veikt vairākos veidos. Divas metodes, kas visbiežāk tiek izmantotas, lai novērtētu izveidoto modeli, ir novilcināšanas (angļu val. – *holdout*) metode un šķērsvalidācijas (angļu val. – *cross-validation*) metode (Arlot un Celisse, 2010). Situācijās, kad ir pieejams ierobežots datu apjoms, lai objektīvi novērtētu modeli, tiek izmantota kāda no šķērsvalidācijas metodēm (Yadav un Shukla, 2016). Viena no šķērsvalidācijas metodēm ir *k* kārtu (angļu val. – *k-fold*) metode. Par teorētiski labāko tiek atzīta desmitkārtīgā šķērsvalidācijas metode. Šķērsvalidācijas metode ir izmantota studentu sasniegumu klasifikatoru modeļu novērtēšanā (Buraimoh u. c., 2021; Pereira u. c. 2019).

Prognozējošu modeļu veikspējas rādītāji

Klasifikācijas algoritma (modeļa) veikspējas rādītāji. 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).

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

2.1. tabula

Pārpratumu matrica binārā klasifikatorā

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

Pārpratumu matricu veido četras dažādas paredzēto un reālo vērtību kombinācijas: pareiza atbilde (angļu val. – *true positive*, *tp*); pareiza neatbilde (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, kad ir vai viltus negatīvs, tad ir 2. veida kļūda.

Binārā klasifikācijas modelī tā veikspēju 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). **F1 mērs** ir harmoniskais vidējais starp precizitāti un pārklājumu. **F2 mērs** apvieno precizitāti un pārklājumu, dubulti uzsverot pārklājuma nozīmīgumu.

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*, 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 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”).

Kā primārais modeļa veikspējas rādītājs promocijas darbā tiek izmantots F mērs. Indivīda e-iekļautības prognozēšanas modelim ir nozīme, ja tā prognoze aptver pēc iespējas vairāk riska grupu 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*; *RMSE*), vidējā absolūtā kļūda (angļu val. – *Mean Absolute Error*; *MAE*), determinācijas koeficients, koriģētais determinācijas koeficients.

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

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 modeļa individuālo prognozi (Hung u. c.,

2019). Cita pieeja, kā uzlabot studentu mācību sasniegumu prognozējošo modeļu veikspēju, ir veidot klasifikatoru ansambļus (*Atallah un Al-Mousa, 2019; Mulyani u. c., 2019*).

Nelīdzsvarotu klašu problēmas novēršana klasifikācijā. Nelīdzsvarotu klašu problēmas novēršanas metodes ir iedalītas divās grupās (*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. Promocijas darba pētījumos tiek izmantotas salīdzinoši neliela apjoma datu kopas, tāpēc autore apskata metodes, kā palielināt piemēru skaitu klasē. Lai izvairītos no piemēru pārklāšanās, tiek piedāvāta *SMOTE* (angļu val. – *Synthetic Minority Over-Sampling Technique*) metode (*Chawla u. c., 2002*). *SMOTE* metode no mazākās klases piemēriem sintezē jaunus piemērus. *SMOTE* metode ir izmantota riska studentu prognozējošo modeļu izveidē (*Mulyani u. c., 2019*).

2.4. Studentu sasniegumu prognozēšanā izmantoto pazīmju raksturojums

Iepazīstoties ar literatūrā pieejamajiem pētījumiem par mācību analītiku un studentu sasniegumu prognozēšanu, jāsecina, ka 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) (*Niet u. c., 2016; Moncada, 2018*);

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; Herrera u. c., 2019; Maennel, 2020*);

3) kombinācijas no laikā mainīgām un nemainīgām pazīmēm (*Mahboob u. c., 2016*).

Otrs būtisks aspekts prognozējošo modeļu izveidē ir veids, pēc kādiem kritērijiem izvēlēties prognozēšanai izmantojamās pazīmes:

1) pazīmju izvēle ir balstīta teorijā, kas pamato prognozes prediktoru un rezultatīvo datu saistību. Lai no mācību analītikas būtu ieguvums pedagoģiskajā procesā, izvēloties analizējamās datus, būtiski ir izprast, kā indivīdi mācās (*Ferguson u. c., 2016; 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. Izmantojot mašīnmācīšanās rīku iespējas, nosaka atribūtus, ar kuriem modelis uzrāda augstākos veikspējas rādītājus (*Márquez-Vera u. c., 2013*). Šādos gadījumos trūkums ir tas, ka par atribūtiem var tikt identificēti tādi riska faktori, 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 noslēguma darbu atzīmes, taču netiek noteikti riska faktori, ko iespējams ietekmēt, lai uzlabotu studentu sasniegumus (*Cobos un Olmos, 2018; Mahboob, 2016; Sorour u. c., 2014*).

Autore secina, ka nepastāv vienots pazīmju komplekts, ko varētu pārņemt un izmantot

e-iekļaušanu prognozējošā modelī. 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. 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.

2.5. Studentu sasniegumus prognozējošo modeļu raksturojums

Tikai nedaudzos pētījumos ir pieejama informācija par prognozējošiem modeļiem, kas nosaka indivīda IKT lietošanas līmeni, un galvenokārt šie modeļi ir balstīti demogrāfiskos faktoros vai indivīda personības iezīmēs un iepriekšējās digitālās prasmēs, tas ir, faktoriem, ko mācību procesa laikā nav iespējams mainīt, lai novērstu risku (*Azcona u. c., 2019; Akhtar u. c., 2017; Guillén-Gámez u. c., 2020a; Hidalgo u. c., 2020; Verhoeven u. c., 2020*).

Prognozējošo modeļu izveidē ir izmantotas atšķirīga apjoma datu kopas, piemēram, modeļiem, kuru prognozes ir saistītas ar e-iekļautību, ir gan 52 dalībnieki (*Berkowsky u. c., 2017*), gan 17000 dalībnieki (*Hidalgo u. c., 2020*). Digitālās prasmes indivīdi bieži apgūst tālākizglītības, profesionālās pilnveides, neformālās izglītībasursos, kur dalībnieku skaits ir nosacīti neliels, tāpēc autore literatūras izpētē pievērta uzmanību pētījumiem, kur prognozēšanas tehnoloģijas ir izmantotas nelielām studentu grupām. Pieejamā zinātniskā literatūra rāda, ka modeļiem, kas prognozē studentu sasniegumus modeļa apmācībai, lietotas salīdzinoši nelielas datu kopas: 76 studentu datu kopa (*Suresh u. c., 2016*), 149 studentu datu kopa (*Azcona u. c., 2019*) vai 273 studentu datu kopa (*Baksa-Haskó un Baranyai, 2018*). Pētījumā, kur izmantota studentu datu kopa, kurā ir mazāk par 100 objektiem, secina, ka ar mašīnmācīšanās metodēm un prognozējošo modeļu kombinēšanu iespējams sasniegt pat 97–100 % korekti prognozētus riska studentus (*Lykourantzou u. c., 2009*).

Prognozēšanas metodes literatūrā pieejamos pētījumos ir daudzveidīgas, izmantotas gan klasteranalīzes (*Luo u. c., 2020*), gan lineārās regresijas (*Akhtar u. c., 2017; Berkowsky u. c., 2017; Guillén-Gámez u. c., 2020a; Xu u. c., 2020*), gan klasifikācijas metodes (*Baksa-Haskó un Baranyai, 2018; Buraimoh u. c., 2021; Cobos un Olmos, 2018; Hidalgo u. c., 2020; Pereira u. c., 2019; Suresh u. c., 2016*).


Pētījumos bieži kā veikspējas rādītājs ir norādīts prognozēšanas modeļa akurātums (*Alamri u. c., 2019; Buraimoh u. c., 2021; Mahboob u. c., 2016*). Retāk kā modeļa veikspējas rādītāji ir norādīti prognozējamās klases precizitāte, pārklājums, F mērs, kas precīzāk raksturo prognozējošo modeli, kad klasē, par kuru ir galvenā interese, ir mazāks gadījumu skaits (*Márquez-Vera u. c., 2013*). Kā veikspējas rādītāji atkarībā no izvēlētajās metodes ir izmantoti arī determinācijas koeficienti (*Berkowsky u. c., 2017*). Veikspējas rādītāju vērtības izmantotajiem algoritmiem ir atšķirīgas. Veikspējas rādītāji ar vienu un to pašu klasifikatoru algoritmu veidotajos klasifikācijas modeļos ar atšķirīgām datu kopām, pazīmēm ir dažādi, kas liecina par to, ka katram individuālam prognozēšanas gadījumam ir jāmeklē atbilstošs klasifikatora algoritms, ar kuru modelis uzrāda labākos veikspējas rādītājus. Pētījumi atklāj, ka, lai uzlabotu veikspējas rādītājus, veidojot klasifikācijas modeļus, tiek izmantoti vairāki klasifikatori, salīdzināti to veikspējas rādītāji, turpmākai lietošanai izvēloties tos klasifikatorus, kam ir augtāki veikspējas rādītāji vai veidoti klasifikatoru ansambļi (*Azcona u. c., 2019*). Literatūras analīze rāda, ka studentu sasniegumu

prognozējošo modeļu veikspējas rādītāji ir diapazonā no 50 % līdz pat 100 % atkarībā no izmantotajiem studentus raksturojošajiem atribūtiem un prognozēšanā izmantotajiem algoritmiem.

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 tieši pārņemt iepriekš izveidotus modeļus, saskan ar rezultātiem, kas iegūti pētījumā par mācību prognozējošu modeļu lietošanu 17ursos, 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, to ka tie ir ne tikai vienreizējai lietošanai vai vienam kursam, bet ir nepieciešams tos vispārināt plašākam kursu skaitam (*Hung* u. c., 2019; *Romero* un *Ventura*, 2019). Nepieciešams izmantot dažādas datizraces metodes, izveidot vairākus modeļus, lai, salīdzinot to veikspējas rādītājus, varētu izvēlēties modeļus ar augstākiem veikspējas rādītājiem.

2.6. Prognozējošu informācijas sistēmu darbības 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). Prognozēšanas posmā notiek sistēmai iemācīto zināšanu izmantošana, lai veiktu sistēmai paredzētos uzdevumus (*Ning* u. c., 2011). Prognozēšanas posms ietver arī šādu darbību – iegūtās prognozes analīze un rezultātu interpretācija (*Halkidi* u. c., 2001). Noslēdzošais prognozēšanas posmā ir sistēmas rīcība atbilstoši iegūtajai prognozei (*Ribeiro De Carvalho Martinho* u. c., 2013). Informācijas sistēmām, kuru izveide ir balstīta mašīnmācīšanās tehnoloģiju lietojumā, būtiska ir arī prognozējošā modeļa kvalitātes uzturēšanas funkcija (*Studer* u. c., 2021).



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

Secinājumi par e-iekļaušanas prognozējošo informācijas sistēmu. Autore secina, ka, veidojot e-iekļaušanas prognozējošo modeli, jānodrošina, ka tas (2.1. att.):

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

2) spēj prognozēt e-iekļaušanas riskam pakļautos studentus.

Vēlams 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 (Sclater, 2017). Mācību analītikas procesu var detalizēt sešus galvenos posmos atbilstoši *CRISP-DM* (angļu val. – *Cross-industry standard process for data mining*) standartam, ja prognozēšanas modeli veido ar datizraces metodēm (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. 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)* (angļu val. – *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 papildina 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.

2.8. E-iekļaušanu prognozējošā modeļa izveides posmi

Balstoties uz 2.7. nodaļas prognozējošo modeļa izveides procesa posmiem, autore izstrādā e-iekļaušanu prognozējošā modeļa izveides posmus.

Lai noteiktu e-iekļaušanu prognozējošā modeļa mērķus, autore indivīda e-iekļaušanu prognozējošas mašīnmācīšanās balstītas sistēmas izveidei par pirmo posmu nosaka biznesa izpratnes posmu. Promocijas darba 1. nodaļa ietver e-iekļaušanas procesu analīzi un e-iekļaušanu prognozējošā modeļa biznesa mērķus. Par otro posmu autore nosaka prognozējošo tehnoloģiju izpēti, lai īstenotu e-iekļaušanas prognozēšanas modelim noteiktos biznesa mērķus. E-iekļaušanu prognozējošajam modelim ir jāspēj atklāt riska faktori, ko novēršot būtu iespējams ietekmēt studenta sasniegumus. Promocijas darba 2. nodaļā ir noteikti datizraces un mašīnmācīšanās tehnoloģiju un to lietojuma mērķi atbilstoši e-iekļaušanas procesa biznesa mērķiem.

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 metodi, un modeļa veikspējas 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.

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

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

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

1) izmantojot zināšanu pārvaldības teorijas atziņas, noteikt iespējamus faktorus, kas ietekmē indivīda e-iekļaušanu;

2) izmantojot iespējamus faktorus, izveidot modeli, ar ko ir iespējams prognozēt studentus, kam ir digitālās atstumtības risks, un noteikt, kuri faktori jāizmanto prognozējošajā modelī;

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

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.

Nodaļā aprakstītie pētījumi ir atspoguļoti autores publikācijās: [2]–[7], [9], [10].

3.1. Zināšanu pārvaldības teorijā balstīti e-iekļaušanu ietekmējošie faktori

Plaisa starp zināšanām un zināšanu praktisko lietojumu

Plaisa starp zināšanām un zināšanu praktisko lietojumu ir viens no iemesliem, kāpēc organizācijās darbinieki, atgriežoties no apmācībām, zināšanas pilnvērtīgi neizmanto organizācijas mērķiem (*Pfeffer* un *Sutton*, 1999). Par plaisu starp zināšanām un zināšanu praktisko lietojumu digitālo prasmju kontekstā tiek uzskatītas atšķirības starp digitālo prasmju esamību un to praktisko lietošanu. Pieņemts, ka ideālā stāvoklī kādas tehnoloģijas aktuālo izmantotāju skaits konverģē ar potenciālo lietotāju skaitu (*Becker* u. c., 2008).

Zināšanu plūsmas e-iekļaušanas kontekstā

Atbilstoši Nisena (*Nissen*) (2006) teorijai plaisa starp zināšanām un zināšanu praktisko 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 veicina 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-vide zināšanu pārnese 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 (*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 tehnoloģijām nonāktu pie indivīda, instruktoram ir jāgrib un jāspēj dalīties ar zināšanām, 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.

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. Instruktora ieinteresētība un spēja dalīties ar zināšanām. Instruktora 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 materiāliem, 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; Sundqvist u. c., 2020*). Mācību vides ietekme uz studentu sasniegumiem ir norādīta 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 (*Subramaniam, 2009*). Pētījumos studentu motivācija ir norādīta kā priekšnoteikums digitālo prasmju ieguvei (*Hatlevik u. c., 2015*). Saskaņā ar Djuī (*John Dewey*) teoriju (1913) mācīšanās rezultāti ir atkarīgi no studenta interesēm.

Studenta spēju mācīties autore apraksta ar studenta iepriekšējo pieredzi, kas atspoguļojas zināšanu līmeni. Saskaņā ar konstruktīvisma teoriju, katrs students konstruē jaunas zināšanas, balstoties savā esošajā pieredzē (*Powell u. c., 2009; Vedins, 2011*). Lai noteiktu studenta spēju mācīties, autore lieto procentuālo zināšanu līmeņa pieaugumu.

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.

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

Promocijas darba pētījumā iesaistīti 767 profesionālo izglītības iestāžu pedagogi, kas no 2011. gada novembra līdz 2012. gada maijam apguva moduli „Informācijas tehnoloģiju prasmju kompetenču paaugstināšana”. Atsevišķiem promocijas darba pētījumiem izlases dati tika papildināti ar datiem, kas iegūti no 160 profesionālo izglītības iestāžu pedagogiem, kas no 2014. līdz 2016. gadam apguva mācību programmas „Mūsdienu interešu izglītība” trīs kursus: mobilās tehnoloģijas; robotika; video tehnoloģijas un dizains.

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. Pēc kursa apguves veikta telefonaptauja vai nosūtīta aptauja e-pastā par digitālo prasmju lietošanu profesionālām vai privātām vajadzībām.

Pētījumos izmantoto mainīgo un atribūtu raksturojums

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

3.1. tabula

E-iekļaušanas procesu raksturojošie faktori un tiem atbilstošie neatkarīgie mainīgie

Faktors	Neatkarīgais mainīgais, tā saīsinājums	Datu ieguve
I. Instruktora vēlme un spēja dalīties ar zināšanām	<u>Studenta vērtējums instruktora ieinteresētībai dalīties ar zināšanām, IWS.</u> Mainīgā vērtība: no 1 (ļoti zema) līdz 5 (ļoti augsta).	Aptauja pēc kursa apguves
	<u>Studenta vērtējums apmierinātībai ar e-materiāliem, ELM.</u> Mainīgā vērtība: no 1 (pilnībā neapmierināts) līdz 5 (pilnībā apmierināts).	Aptauja pēc katras tēmas apguves
	<u>Studenta vērtējums apmierinātībai ar e-vidi, ELE.</u> Mainīgā vērtība: no 1 (pilnībā neapmierināts) līdz 5 (pilnībā apmierināts).	Aptauja pēc katras tēmas apguves
II. Studenta vēlme un spējas mācīties	<u>Studenta vērtējums savai vēlmei mācīties, SWL.</u> Mainīgā vērtība: no 1 (pilnībā nav vēlmes) līdz 5 (izteikta vēlme).	Aptauja pirms kursa apguves
	<u>Studenta spējas mācīties, SAL.</u> Šī mainīgā vērtība tiek interpretēta kā studenta procentuālais zināšanu līmeņa pieaugums. Mainīgā vērtība: no 0 % (nav spēju) līdz 100 % (izcilas spējas) vai tiek mērogota no 1 līdz 5.	Aptauja pirms katras tēmas apguves Aptauja pēc katras tēmas apguves

Papildus iepriekš minētajiem neatkarīgajiem mainīgajiem autore pētījumā izmanto vēl šādus mainīgos:

studenta vispārīgās digitālās prasmes, DS. Šī mainīgā vērtība tiek iegūta no studenta pašvērtējuma savām datorlietošanas un interneta prasmēm. Mainīgā vērtība: no 0 (nav prasmju) līdz 1 (izcilas prasmes). Mainīgā vērtība tika mērogota no 1 līdz 5.

Atkarīgie mainīgie. Lai noteiktu indivīda e-iekļautības pakāpi e-iekļaušanas procesā,

autore izmanto vairākus raksturlielumus, kas apraksta indivīda 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 indivīdu digitālās prasmes (*Kreijns* u. c., 2014). Mainīgie, kas raksturo indivīda e-iekļautības pakāpi, apkopoti 3.2. tabulā.

3.2. tabula

Atkarīgo mainīgo raksturojums

Atkarīgais mainīgais, tā saīsinājums	Datu ieguve
Studenta prognoze par to, vai pēc kursa pabeigšanas apgūtās prasmes students izmantos profesionālām vai privātām vajadzībām, <i>PU</i> . Mainīgā vērtība: no 1 (pilnībā nepiekrītu) līdz 5 (pilnībā piekrītu).	Aptauja pēc kursa apguves
Novērotā prasmju lietošana, <i>OU</i> . 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.	Aptauja par jauniegūto digitālo prasmju lietošanu atkarībā no kursa veida 4 līdz 8 nedēļas pēc kursa pabeigšanas vai līdz 6 mēnešiem pēc kursa beigšanas.
Iespējamā prasmju lietošana, <i>PU&OU</i> . 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.	Aptauja pēc kursa apguves Aptauja par jauniegūto digitālo prasmju lietošanu atkarībā no kursa veida 4 līdz 8 nedēļas pēc kursa pabeigšanas vai līdz 6 mēnešiem pēc kursa pabeigšanas.

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

Pētījuma mērķis ir pārbaudīt, cik lielā mērā ar lineārās regresijas modeli, izmantojot iepriekš noteiktos iespējamās 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.

Datu analīzes metode. Lai noskaidrotu sakarības starp e-iekļautības faktoriem un e-iekļautības pakāpi, autore izmanto Pīrsona korelācijas koeficientu noteikšanu. Lai veidotu e-iekļautību prognozējošo modeli un noskaidrotu e-iekļautības faktoru ietekmi uz e-iekļautības pakāpi, autore izmanto daudzfaktoru lineārās regresijas analīzi. Mainīgajiem veikta atbilstības pārbaude normālsadalījumam.

Rezultāti: korelācijas starp e-iekļautības faktoriem un e-iekļautības pakāpi

Atbilstoši Pīrsona korelāciju aprēķiniem korelācijas koeficienti starp e-iekļautības faktorus raksturojošiem mainīgiem un e-iekļautības pakāpi raksturojošiem mainīgajiem ir robežās no 0,23 līdz 0,64.

Rezultāti: lineārās regresijā balstīts e-iekļaušanu prognozējošs modelis

Atbilstoši korelāciju pētījumiem kā rezultatīvie mainīgie lineārās regresijas modeļos var tikt izmantoti: (1) studenta prognoze, ka pēc kursa pabeigšanas students apgūtās prasmes izmantos profesionālām vai privātām vajadzībām; (2) prasmju iespējamā lietošana pēc kursa pabeigšanas. Korelāciju pētījumi rāda, ka saistība starp e-iekļaušanas faktoriem un e-iekļautības pakāpi dažādām kursa tēmām ir atšķirīga.

Atbilstoši pētījuma jautājumam noskaidrots, ka ir iespējams prognozēt studenta e-iekļautības pakāpi ar e-iekļaušanas faktoriem, ko var izteikt ar šādiem mainīgiem – 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.

Prognozētā lietošana un prediktori. Biežāk izmantotie prediktori prognozētajai lietošanai ir šādi: 1. faktora neatkarīgie mainīgie: „Studenta apmierinātība ar mācību e-materiāliem” (43,75 %) un „Studenta apmierinātība ar e-vidi” (37,5 %); 2. faktora mainīgais „Studenta vēlme mācīties” salīdzinoši mazāk tēmās ietekmē prognozēto lietošanu, tas tiek iekļauts vienādojumos kā otrais faktors 12,5 %. Tikai 6 % gadījumu 2. faktora mainīgais „Studenta spēja mācīties” noteica prognozēto lietošanu.

Iespējamā lietošana un prediktori. Biežāk izmantotie prediktori iespējamai lietošanai ir šādi. 1. faktora neatkarīgie mainīgie: „Studenta apmierinātība ar e-vidi” (37,5 %), „Studenta apmierinātība ar mācību e-materiāliem” (25 %) un „Studenta spēja mācīties” (25 %). 2. faktora mainīgais „Studenta vēlme 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. Individīda e-iekļautību raksturojošu klasteru izveide un e-iekļautību ietekmējošo faktoru atšķirību izvērtējums klasteros

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.

Datu analīzes metode. Lai sagrupētu profesionālos pedagogus, balstoties uz tos raksturojošiem datiem, un veiktu šo grupu salīdzināšanu vienlaikus pēc vairākiem parametriem, autore izmantoja iteratīvu attālumā balstītu klasterēšanas pieeju, kas pazīstama kā *kMeans* jeb „k vidējo vērtību” algoritms. Praksē ir problemātiski noteikt optimālo klasteru skaitu (*Hamerly un Elkan, 2003*).

Lai noteiktu klasteru skaitu *kMeans* algoritmam profesionālo izglītības iestāžu pedagogu analīzē, autore izmantoja *EM (Expectation-Maximization)* algoritmu, kā arī empīriski noteica *k* lielumu (*Osamor u. c., 2012*). Klasteranalīzi autore veica ar atvērtā pirmkoda programmatūru *WEKA*. Studenti tika iedalīti trīs veidu klasteros atkarībā no atbildes par jaunapgūto prasmju lietojumu: (1) nē, vispār neesmu izmantojis/usi ar šo tēmu saistītas prasmes; (2) nē, bet izmantoju prasmes tādā pašā līmenī, kā pirms kursa apguves; (3) jā, izmantoju jaunapgūtās prasmes.

Rezultāti atbilstoši definētajiem 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 pēc mācību kursa beigām nelieto.

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 pēc mācību kursa beigām nelieto.

Augstāks e-materiālu vērtējums liecina par piederību klasterim, kur studenti izmanto jaunapgūtās digitālās prasmes. E-iekļaušanas procesa mērķu sasniegšanai ir nepieciešams e-vidē nodrošināt to, ka mācību materiāli tiek pielāgoti studenta vajadzībām.

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 pēc mācību kursa beigām nelieto. Augstākais vērtējums 4,5, kas ir tuvu maksimāli iespējamam 5,0, liecina par to, ka students pieder klasterim, kas turpinās lietot jaunapgūtās prasmes, savukārt zemākie vērtējumi ir tuvu pārējo klasteru, kuri nelieto apgūtās digitālās prasmes, vērtējumam. Autore secina, ka jāpievērš uzmanība tam, kā students jūtas e-vidē. Jāprecizē, kur studentam ir problēmas, un laikā, kamēr students apgūst mācību kursu e-vidē, jāpiedāvā studentam dažādas iespējas, kas atvieglotu e-vides lietošanu.

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

Studenta spējas mācīties. 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.

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 % (vispār nelieto digitālās prasmes) un 52,3 % (lieto, taču 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 pierādīt, ka pēc tēmas apgūšanas viņas zināšanas ir pieaugušas. Šo studentu augstais zināšanu līmenis varētu izskaidrot studentu kritisko attieksmi, tas ir, salīdzinoši zemo vērtējumu e-videi – 4,0 un e-materiāliem par apgūstamo tēmu – 3,8, jo tie studentam nav noderējuši, kā arī ne pārāk augsto vērtējumu vēlmei mācīties – 3,7, jo studentam jau ir bijušas pietiekamas zināšanas par kursa tēmu.

Secinājumi par centroīdu vērtībām un klasteranalīzi studenta e-iekļautības paredzēšanai. Klasteranalīzes rezultāti liecina, ka studentus var iedalīt 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, kuros iekļauti studenti, kas lieto jaunapgūtās prasmes, centroīdu vērtības ir augstākas, salīdzinot ar tiem klasteriem, kuros iekļautie studenti jauniegūtās prasmes nelieto. Autore secina, ka klasteranalīzi ir iespējams izmantot studenta e-iekļautības paredzēšanā, izmantojot indivīda e-iekļautības faktorus.

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

Pētījuma mērķis ir noskaidrot, 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.

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 veikšanai autore sagatavoja 12 datu kopas. Katram kursam – mobilās tehnoloģijas, robotika, video tehnoloģijas – tika izveidotas datu kopas, kas apkopo visu studentu ierakstus vai tikai to studentu ierakstus, kam ir tehnoloģijas jaunapgūto prasmju izmantošanai. Datu kopas tika līdzsvarotas.

Prognozējošā modeļa izveides metode. Lai sagrupētu profesionālo pedagogus „e-iekļautajos” un „ne e-iekļautajos”, pētījumā tika izveidoti pieci klasifikācijas modeļi, izmantojot šādus klasifikatoru ģenerēšanas algoritmus: *NaiveBayes*, *SimpleLogistic*, *LWL*, *OneR* un *LMT Waikato Environment for Knowledge Analysis (WEKA)* platformā.

Izveidoto klasifikācijas modeļu veikspējās novērtēšanai autore izmanto pārpratuma matricas metodiku un nosaka modeļa F1 mērus. E-iekļautību prognozējošo klasifikācijas modeļu novērtēšanai tiek izmantota desmitkārtīgā šķērsvalidācija (*Yadav un Shukla*, 2016).

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

Atbilstoši definētajiem pētījuma jautājumam ir noskaidrots, ka dažādiem datu kopu veidiem atšķiras veikspējās rādītāji F1 mēram. Pētījumā iegūtie F1 mēra rādītāji apstiprina, ka datu kopas līdzsvarošana pirms klasifikācijas modeļu ģenerēšanas procedūras uzlabo veikspējās rezultātus izveidotajiem klasifikācijas modeļiem, it īpaši ar lazy.LWL algoritmu ģenerētajiem modeļiem.

Pētījumā ir salīdzināti pieci dažādi klasifikācijas modeļi un konstatēts, ka vislabākie veikspējās rādītāji F1 mēram ir modeļiem, kas apmācībai izmanto līdzsvarotas datu kopas, studentiem ar piekļuvi tehnoloģijām.

Atbilstoši definētajiem pētījuma jautājumam ir noskaidrots, ka nepastāv viens klasifikatoru ģenerēšanas algoritms, ar kuru veidotie klasifikācijas modeļi uzrāda vislabākos veikspējās 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, savukārt 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 veikspējās rādītājus.

Turklāt ar *lazy.LWL* un *LMT* algoritmiem veidotie modeļi līdzsvarotām 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 – 0,770.

Tādējādi var uzskatīt, ka *lazy.LWL* un *LMT* klasifikācijas modeļus var izmantot dažādiem digitālo prasmju attīstības kursiem.

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 augstākus veikspējas rādītājus.

Vadoties no šiem secinājumiem, autore nākamajā apakšnodaļā veic pētījumu, veidojot indivīda e-iekļautību prognozējošu modeli, apmācot to ar datu kopām, kas apvieno datus no vairākiem digitālo prasmju apguves kursiem.

3.6. Indivīda e-iekļautību prognozējošā algoritmiskā modeļa izveide

Pētījuma mērķis ir, kombinējot lineārās regresijas, klasteranalīzes un klasifikācijas metodes, izveidot e-iekļautību prognozējošu modeli ar iespējami augstākiem veikspējas rādītājiem, vienlaikus atpazīstot pēc iespējas vairāk digitālās atstumtības riska studentus.

Pētījuma jautājumi:

1) noteikt, kādām lineārās regresijas, klasteranalīzes un klasifikācijas modeļu kombinācijām, prognozējošā modeļa veikspējas 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.

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 (Frank u. c., 2009).

Modeļu veikspēja tika novērtēta, izmantojot pārklājuma, precizitātes, F1 mēra un F2 mēra rādītājus. E-iekļautību prognozējošo klasifikācijas modeļa novērtēšanai tika izmantota desmitkārtīgā šķērsvalidācija, kas plaši tiek lietota modeļa novērtēšanai mašīnmācīšanās (Yadav un Shukla, 2016).

Prognozes M1 modelis: klasifikatoru ansamblī balstīts modelis

Ņemot vērā iepriekš iegūtos rezultātus, ka ar *lazy.LWL* un *LMT* algoritmiem ģenerētajiem modeļiem ir augstāki veikspējas rādītāji un to kombinēšanu ar klasifikācijas modeļiem, kas veidoti, izmantojot šādus algoritmus: *NaiveBayes*, *Simple Logistic* un *OneR*, autore noteica

modeļu kombinācijas ar augstākajiem veikspējas rādītājiem F1 un F2 mēram. M1 modelis ir ansambļa klasifikators, kas apvieno:

1) četrus klasifikācijas modeļus, kas veidoti ar *lazy.LWL* (ar *Random Forest*), *LMT*, *OneR* un *Simple Logistic* 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 *Simple Logistic* 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. *kMeans* klasteranalīzes metode tiek izmantota datu grupēšanai divos klasteros („e-iekļauts” un „nav e-iekļauts”).

Prognozes M3 modelis: Lineārā regresijā balstīts modelis

Lineārās regresijas modelis prognozē e-iekļautības pakāpi procentos no maksimāli iespējamās pakāpes. Lai noteiktu indivīda 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”. Autore secināja, ka augstākā F1 mēra vērtība ir, ja e-iekļautības pakāpe ir 75 %, F2 mēra augstākā vērtība ir, ja e-iekļautības pakāpe ir 85 % (3.1. att.).



3.1. att. Veikspējas metrikas izmaiņas atkarībā no prognozētās e-iekļautības pakāpes. E-iekļautības pakāpes sliekšņa noteikšana.

Prognozes M3 modelis ir daudzfaktoru lineārās regresijas modelis, kas paredz, ka izglītojamais ir pakļauts digitālās atstūmtības 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 modelis, M5 modelis, M6 modelis, M7 modelis. 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.

Modeļu apmācības rezultāti: F1 mērs kā galvenais veikspējas rādītājs

Iegūtie rezultāti (3.2. att.) rāda, ka F1 mērs ir visaugstākais modelim, kas apvieno kombināciju no klasifikatoru ansambļa un klasteriem.

Augstākā F1 mēra vērtība 0,812 ir M4 modelim, ko iegūst, apvienojot M1 modeli un M2 modeli. M1 modelī tiek izmantoti klasifikācijas modeļi, kas balstīti šādos algoritmos: *lazy.LWL*, *LMT*, *OneR* un *Simple Logistic*, apvienojot tos ar ansambļa un vairākuma balsojuma metodi. M2 modelis ir *kMeans* klasteranalīzes modelis, kur dati tiek sagrupēti klāstros „e-iekļauts” un „nav e-iekļauts”. M4 modeļa pārklājums ir 0,828, precizitāte – 0,796.




3.2. att. Rezultāti. F1 mēra, precizitātes, pārklājuma vērtības e-iekļautības prognozēšanas modeļiem, ja pieņem, ka pārklājumam un precizitātei ir vienlīdz svarīga nozīme.

Modeļu apmācības rezultāti: F2 mērs kā galvenais veikspējas rādītājs

Iegūtie rezultāti (3.3. att.) rāda, ka F2 mērs ir visaugstākais modeļiem, ko 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 modelim, M6 modelim un M7 modelim. M5 modelis tiek iegūts, apvienojot M1 modeli un M3 modeli. M1 modelī tiek izmantoti klasifikācijas modeļi, kas veidoti ar algoritmiem *lazy.LWL*, *LMT* un *Simple Logistic*, apvienojot tos ar ansambļa metodi un izmantojot vairākuma balsošanas metodi. M3 modelis ir lineārās regresijas modelis, kur izglītojamaais tiek uzskatīts par e-iekļautu, ja tā e-iekļautības pakāpe ir augstāka par 85 %. M6 modelis un M7 modelis ir M1, M2 un M3 modeļa kombinācijas rezultāts. Šiem modeļiem ir izmantota klasifikācijas, klastera un lineārās regresijas metodes kombinācija. M5, M6 un M7 modelim pārklājums ir 0,984, precizitāte – 0,582.



3.3. att. Rezultāti. F2 mēra, precizitātes, pārklājuma vērtības e-iekļautības prognozēšanas modeļiem, ja pieņem, ka pārklājums ir svarīgāks nekā precizitāte.

Ja mērķis ir prognozēt aptvert pēc iespējas vairāk riska studentu, tad ir piemērota klasifikatoru ansambla metode, kas kombinēta ar lineāras 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, ir patiesi riska studenti.

Ja precizitāte un pārklājums ir vienlīdz svarīgi un kā veikspējas kritērijs tiek izmantots F1 mērs, tad augstākos veikspējas rādītājus var iegūt, apvienojot klasifikatoru ansambla 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.

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 (3.4. 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

3.4. 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. *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.

Otrs skats uz studenta riska faktoriem tiek nodrošināts, izmantojot lineārās regresijas modeli M3. Iegūtais lineārās regresijas modeļa koeficientu vērtības redzamas 3.5. attēlā.

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 – mazāka. Atkarībā no studenta atribūtiem ar lineārās regresijas prognozēšanas algoritmu iespējams noteikt, kuri ir noteicošie riska faktori studentam.

$$\begin{aligned}
 PUOU = & \\
 & 0.538 * SWL + \\
 & 0.2807 * SAL + \\
 & 0.6354 * ELM + \\
 & 0.3163 * ELE + \\
 & -1.7483
 \end{aligned}$$

3.5. att. Lineārās regresijas koeficientu vērtības M3 modelim. 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.

Prognozējot profesionālo izglītības iestāžu pedagogu e-iekļautību, autore uzskata, ka svarīgāk ir atpazīt pēc iespējas vairāk riska grupas pārstāvju (lielāks pārklājums), nekā nodrošināt lielāku modeļa precizitāti, taču 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, ko iegūst, kombinējot klasifikatoru ansambli ar lineārās regresijas modeli vai klasifikatoru ansambli ar lineārās regresijas modeli un klasteranalīzes modeli.

4. TEHNOLOĢISKAIS MODELIS UN TĀ NOVĒRTĒJUMS INDIVĪDA E-IEKĻAUTĪBAS PROGNOZĒŠANAI

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.
- Autores publikācijas par nodaļā aprakstītajiem pētījumiem pieejamas: [8], [11].

4.1. E-iekļaušanu prognozējošas sistēmas funkcionālās prasības un galvenie darbības principi

E-iekļaušanu prognozējošās sistēmas mērķi


E-iekļaušanu prognozējošās sistēmas galvenais mērķis ir noteikt studentus, kuriem ir digitālās atstumtības risks. Pirmais apakšmērķis ir veidot zināšanu bāzi, kas sastāv no apmācības piemēru datubāzes un apmācīta prognozēšanas modeļa. Otrais apakšmērķis ir paredzēt studentus ar digitālās atstumtības risku, balstoties uz iepriekš noteikto e-iekļautības pakāpes sliekšni un aprēķiniem, kas iegūti, izmantojot prognozēšanas 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 veikspējas kvalitāti.

Prasības e-iekļaušanu prognozējošās sistēmas funkcionalitātei

Atbilstoši sistēmas mērķiem galvenās funkcionālās prasības e-iekļaušanu prognozējošajai sistēmai ir: (1) prognozēt studentus, kuriem ir digitālās atstumtības risks; (2) nodrošināt prognozes rezultātu kvalitāti, lai tie saglabātu veiktspējas rādītājus; (3) saskarnei jābūt vienkāršai un ērti lietojamai.

E-iekļaušanu prognozējošās sistēmas pamatprocesi un datu plūsmas starp tiem

4.1. attēlā parādīta konteksta līmeņa datu plūsmas diagramma e-iekļaušanas prognozēšanas tehnoloģiskajam modelim. Galvenais e-iekļaušanas tehnoloģiskā modeļa lietotājs ir instruktors, kurš māca studentus kombinētās mācīšanās kursos. Instruktors nosaka e-iekļautības 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. 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 iepriekšējā pieredzē, nodrošinot kombinētās mācīšanās kursos, izmantojot vairāku ekrānu pieeju. *SMS* sistēma saņem no e-iekļautību prognozējošās sistēmas studenta tālruna 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. E-iekļautību prognozējošās sistēmas datubāze tiek papildināta ar datiem par jauniegūto prasmju faktisko izmantošanu.



4.1. att. Konteksta līmeņa datu plūsmas diagramma, kas parāda saikni starp e-iekļaušanas prognozēšanas sistēmu, instruktoru, MVS (mācīšanās vadības sistēma) un *SMS* sistēmu.


Studenta e-iekļaušanu prognozējošais algoritms

E-iekļaušanu prognozējošo algoritms sastāv no prognozējošā algoritma apmācības procesa algoritma, prognozēšanas procesa algoritma un veiktspējas uzraudzības algoritma.

E-iekļaušanu prognozējošā algoritma apmācības process. 4.2. attēlā parādīts e-iekļautības prognozēšanas algoritma apmācības process. Lai iegūtu e-iekļautību prognozējošo modeli *PROGN*, vispirms tiek apmācīti trīs dažādi prognožu modeļi – M1, M2 un M3, pēc tam tiek noteikta šo modeļu prognožu optimālā kombinācija un aprēķināta galīgā prognozēšanas funkcija $PROGN = f(M1, M2, M2, \text{e-iekļautības sliekšnis})$.


Modelis M1 ir prognozēšanas modelis, kas klasifikatoru ansablī apvieno klasifikācijas modeļus, kas veidoti ar šādiem algoritmiem: *lazy.LWL* ar *Random Forest*, *LMT* un *Simple Logistic* algoritmus, izmantojot vairākuma balsošanas pieeju. Prognozēšanas modelis – M2

izmanto *kMeans* klasteru veidošanas algoritmu, tas iedala studentus divos klasteros, kur katrs no klasteriem atbilst e-iekļautiem vai ne e-iekļautiem studentiem. Prognozēšanas modelis – M3 ir daudzfaktoru lineārās regresijas modelis, kas prognozē izglītojamā e-iekļautību atbilstoši iepriekš noteiktam sliekšnim.




4.2. att. Apmācības process indivīda e-iekļautības prognozēšanas algoritmam, izmantojot trīs modeļu apmācību un *PROGN* funkcijas aprēķinu.

Funkcija *PROGN* atrod modeļu prognožu optimālo kombināciju (4.3. att.). 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 modeļa M2 prognozes pārbaude. Ja M2 modelis paredz, ka students netiek digitāli iekļauts, tad gala rezultāts atkal ir tāds, ka students ir pakļauts riskam. Līdzīgi tiek pārbaudīts M3 modelis. Šī pieeja izvēlēta, lai pārbaudītu pēc iespējas vairāk studentu, kuri ir potenciāli pakļauti riskam. To, ka students nav pakļauts riskam, sistēma paredz tikai vienā gadījumā – ja visi trīs modeļi prognozē, ka students ir digitāli iekļauts.



4.3. att. Fināla prognozes *PROGN* noteikšanas process, pamatojoties uz M1, M2, M3 modeļu prognozēm.

E-iekļaušanas prognozēšanas procesa algoritms. Prognozēšanas procesa algoritms konkrēta studenta e-iekļaušanas prognozei redzams 4.4. attēlā. Lai sistēma veiktu prognozi, ir nepieciešams zināt tēmu, studenta datus, iepriekš definēto e-iekļautības sliekšni 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 viņš varētu pieņemt lēmumu par turpmāko rīcību, piemēram, veikt izmaiņas komunikācijā ar studentu vai piedāvāt citus mācību materiālus.



4.4. att. Prognozēšanas procesa algoritms konkrētam studentam.

Prognozes precizitātes līmenis tiek noteikts šādi. Ja modelis prognozi veic, 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 M1, M2, M3 modeļu kombinācijā un ja tiek prognozēts, ka students ir riska grupā, tad prognozes precizitātes līmenis ir zems, savukārt, ja tiek prognozēts, ka students nav riska grupā, tad prognozes precizitātes līmenis ir augsts.

Prognozēšanas modeļa veikspējas uzraudzības procesa algoritms. Prognozēšanas modeļa veikspējas uzraudzības process, kura mērķis ir noteikt, vai nepieciešama atkārtota prognozējošā modeļa apmācība, ir šāds. Piemēru datubāze 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 datubāzē. Iepriekš noteiktos laika posmos tiek novērtēti modeļa veikspējas rādītāji. Ja modeļa kvalitāte samazinās, prognozējošais modelis tiek apmācīts atkārtoti, izmantojot jauniegūtos datus, atbilstoši iepriekš aprakstītajam e-iekļautības prognozēšanas algoritma apmācības procesam.

4.2. E-iekļaušanu prognozējošās 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; datu līmenis. Biznesa loģikas līmenī tiek realizēta prototipa funkcionalitāte (piemēram, apmāca prognozēšanas modeļus, prognozē). Prezentācijas līmeņa uzdevums ir informācijas saņemšana un tās atspoguļošana prototipa lietotājiem (piemēram, studentus raksturojošie dati, atbilstoša prognoze). Datu līmenis organizē datu pārvaldību.

Prototips ir e-iekļaušanas prognozēšanas sistēmas agrīna versija, tas sastāv no bāzes funkcionalitātes un e-iekļaušanu prognozējošā modelis (algoritma), ar kura palīdzību instruktors redz riska studentus (4.5. att.) Prototipam ir daži ierobežojumi, taču tie neietekmē prognozējošā modeļa un prototipa mērķa novērtēšanas iespējamību atbilstoši iepriekš definētajiem mērķiem.

Video	Name	Submit date	M1	M2	M3	Prediction	Precision
Video	Jānis Bērziņš	2019-08-09				Risk	High
Video	Anna Liepiņa	2019-08-09				Risk	Medium
Video	Juris Ozols	2019-08-07				Risk	Low
Video	Eva Egle	2019-08-07				No risk	High

4.5. att. Prognozēšanas rezultātu skats un precizitātes līmenis.

Prototipa izstrādes mērķis ir noteikt un novērtēt e-iekļaušanas prognozēšanas sistēmas

pamata funkcionalitātes atbilstību sistēmai definētajiem mērķiem.

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. Pedagogi specializējās vienā no trim tēmām: robotikas tehnoloģijas; video izveide un apstrāde; mobilās tehnoloģijas.

E-iekļaušanu prognozējošā modeļa un prototipa novērtēšanai sagatavota datu kopa ar 65 studentu ierakstiem, kas iepriekš prognozējošā modeļa izveidei nav izmantoti. 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-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 mācīšanās kursos.

Mašīnmācīšanās pieejā balstīta modeļa novērtējums ietver tā novērtējumu atbilstoši mašīnmācīšanās uzdevumam (veiktspējas un robustuma novērtējums) noteiktajām prasībām (2. nod.) un biznesa mērķiem (*Ashmore* u. c., 2019; *Studer* u. c., 2021).

Lai novērtētu e-iekļaušanu prognozējošā modeļa veiktspēju un atbilstību biznesa mērķiem, definēti trīs pētījuma jautājumi.

1) Cik procentu no visiem digitālās atstumtības riska grupas profesionālo izglītības iestāžu pedagogiem, kas apgūst digitālās prasmes kombinētās mācīšanās kursos, 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 mācīšanās kursos, reāli pieder riska grupai.

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

Modeļa prognoze par studentiem, kas lieto vai nelieto jaunapgūtās prasmes, un reālais prasmju lietojumu skaits ir parādīts pārpratumu matricā (4.1. tab.). Kā redzams tabulā, modelis nav atpazinis tikai trīs studentus (no 31 studenta), kas ir riska grupā un nav lietojuši jaunapgūtās prasmes.

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. Modelis prognozē riska grupas studentus, tāpēc var secināt, ka modelis izpilda tam paredzētos biznesa mērķus.

E-iekļaušanu prognozējošā modeļa pārpratumu matrica: modeļa prognozes un reāli novērotā situācija par jaunapgūto prasmju lietojumu.

$n = 65$	Prognoze, ka nelielos jaunapgūtās prasmes	Prognoze, ka lielos jaunapgūtās prasmes	
Reāli nelieto jaunapgūtās prasmes	28	3	31
Reāli lieto jaunapgūtās prasmes	13	21	34
	41	24	

Modeļa F2 mēra vērtība ir 0,848, un modeļa akurātums – 0,754. Modeļa veikspējas rādītāji atbilst iepriekš noteiktajām prasībām, 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

Pētījuma mērķis ir novērtēt e-iekļaušanu prognozējošā modeļa un to veidojošo modeļu novirzi, salīdzinot apmācības un testa datu kopu veikspējas rādītājus – F mēru, pārklājumu un precizitāti modeļa prognozei par studentiem, kas nelielos jaunapgūtās digitālās prasmes.

Lai novērtētu e-iekļaušanu prognozējošā modeļa novirzi, noteikti trīs 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 mācīšanās kursos, 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 mācīšanās kursos, tiešām nelielos 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. 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 %, savukārt apmācību datu kopai – 62,09 %. Atšķirībā no pārklājuma precizitāte, prognozējot ar testa kopu, ir palielinājusies, precizitātes rādītājs ir pieaudzis par 6,21 %.

M1 un M2 modeļu kombinācijas gadījumā apmācību kopai F2 mērs ir 82,35 %, testa kopai – 82,28 %. M1 un M2 modeļu kombinācijai apmācības kopas pārklājuma vērtība ir 83,45 %, testa kopai – 83,87 %. Testa kopas gadījumā pārklājums ir pieaudzis par 0,42 %. M1 un M2 modeļu kombinācijai precizitāte testa kopai ir 76,47 %, apmācību kopai – 78,23 %, precizitātes vērtība testa kopai ir samazinājusies par 1,76 %.

M1 modeļa gadījumā apmācību kopai F2 mērs ir 79,98 %, testa kopai – 79,59 %. Salīdzinot F2 mērs ir samazinājies par 0,39 %. Pārklājumiem atšķirība ir šāda: M1 modelim apmācības kopai pārklājums ir 79,50 %, 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 %, apmācību kopai – 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.

E-iekļaušanas prognozēšanas prototipa novērtējums

E-iekļaušanu prognozējošā prototipa atbilstība funkcionālajām prasībām apkopota 4.2. tabulā. Novērtējot prototipa funkcionalitāti, var secināt, ka tā atbilst definētajām prasībām.

4.2. tabula

E-iekļaušanu prognozējošā prototipa atbilstība funkcionālajām prasībām

Prasība	Novērtējums
Prognozēt studentus, kuriem ir digitālās atstumtības risks.	Prognozes rezultātu novērtējums apstiprina modeļa veikspēju, tas ir, spēju prognozēt riska studentus.
Nodrošināt prognozes rezultātu kvalitāti, lai tie saglabātu veikspējas rādītājus.	Modeļa novirzes novērtējums apstiprina modeļa veikspējas 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).

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 faktorus 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.
- Indivīda 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 veikspējas rādītājus.
- Ja, prognozējot indivīda e-iekļautību, mērķis ir prognozē 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 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.

- Individā e-iekļautības pakāpe ietekmē prognozēšanas modeļa pārklājuma un precizitātes vērtības. E-iekļautības pakāpes sliekšņa izmaiņas lineārās regresijas modelī ietekmē pārklājuma un precizitātes vērtības. Jo augstāks e-iekļautības pakāpes sliekšnis, 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 faktoros 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. Individā 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 veikspējas 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 faktoros:

- 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. Individā 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

- Individā 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.
- Individā 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 faktorus.
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 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.
- 3 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.
- 4 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.
- 5 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.
- 6 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>).
- 7 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.
- 8 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.
- 9 Anderson, D., Sweeney, D., Williams, T., Camm, J., & Cochran, J. (2012). Quantitative methods for business. Cengage Learning.
- 10 Arlot, S., & Celisse, A. (2010). A survey of cross-validation procedures for model selection. *Statistics surveys*, 4, 40–79.
- 11 Ashmore, R., Calinescu, R., & Paterson, C. (2019). Assuring the machine learning lifecycle: Desiderata, methods, and challenges. *arXiv preprint arXiv:1905.04223*.
- 12 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.
- 13 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.
- 14 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.

- 15 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.
- 16 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.
- 17 Bélanger, F., & Carter, L. (2008). Trust and risk in e-government adoption. *The Journal of Strategic Information Systems*, 17(2), 165–176.
- 18 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.
- 19 Berkowsky, R. W., Sharit, J., & Czaja, S. J. (2017). Factors predicting decisions about technology adoption among older adults. *Innovation in aging*, 1 (3), igy002.
- 20 Berral, J. L., Goiri, Í., Nou, R., Julià, F., Guitart, J., Gavalda, 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).
- 21 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).
- 22 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.
- 23 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.
- 24 Caraciolo, M. (2011). Machine Learning with Python – Linear Regression, <http://aimotion.blogspot.com/2011/10/machine-learning-with-python-linear.html>.
- 25 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>
- 26 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.
- 27 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, pp. 437–445.
- 28 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.
- 29 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.

- 30 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.
- 31 Csordás, A. (2020). Diversifying Effect of Digital Competence. *AGRIS on-line Papers in Economics and Informatics*, 12 (665-2020-1220), 3–13.
- 32 De Haan, J. (2004). A multifaceted dynamic model of the digital divide. *It & Society*, 1(7), 66–88.
- 33 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.
- 34 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.
- 35 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.
- 36 Drabowicz, T. (2014). Gender and digital usage inequality among adolescents: A comparative study of 39 countries. *Computers & Education*, 7498-111. doi:10.1016/j.compedu.2014.01.016.
- 37 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>.
- 38 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.
- 39 Eiropas Padome (2006). Eiropas Parlamenta un Padomes Ieteikums (2006. gada 18. decembris) par pamatprasmēm mūžizglītībā, OV L 394, 30.12.2006., 10.–18. lpp.
- 40 Eiropas Padome (2018) Padomes Ieteikums (2018. gada 22. maijs) par pamatkompetencēm mūžizglītībā, OV C 189, 04.06.2018., 1.–13. lpp.
- 41 Eiropas Revīzijas palāta (2021). ES rīcība nolūkā palielināt digitālās prasmes.
- 42 Ekubo, E. A. (2020). *Predictive system for characterizing low performance of Undergraduate students using machine learning techniques* (Doctoral dissertation, North-West University (South Africa)).
- 43 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.
- 44 European Commission (2010). A Digital Agenda for Europe: European Commission. Retrieved April 7, 2021.
- 45 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>.
- 46 European Commission (2017). Eurostat. <https://ec.europa.eu/eurostat>.

- 47 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>.
- 48 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.
- 49 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.
- 50 European Commission (2020c). Eurostat. <https://ec.europa.eu/eurostat>.
- 51 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>.
- 52 Farbeh-Tabrizi, K. (2012). Effective Computer Training for People with Disability. *Journal Of Applied Computing & Information Technology*, 16 (1), 1–5.
- 53 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.
- 54 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.
- 55 FreshMinds, & UK Online Centres. (2008). Economic benefits of digital inclusion: building the evidence. Retrieved October 31, 2015, from <http://www.tinderfoundation.org>.
- 56 Future Learn. Using Open Data for Digital Business, 2020 <https://www.futurelearn.com/courses/open-data-business/4/steps/659724>.
- 57 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.
- 58 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).
- 59 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.
- 60 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.
- 61 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.

- 62 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.
- 63 Halkidi, M., Batistakis, Y., & Vazirgiannis, M. (2001). On clustering validation techniques. *Journal of Intelligent Information Systems*, 17 (2–3), 107–145.
- 64 Hamerly, G., & Elkan, C. (2003). Learning the k in k-means. In *NIPS* (Vol. 3, pp. 281–288).
- 65 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.
- 66 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.
- 67 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.
- 68 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.
- 69 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.
- 70 ITU. (2006). World Telecommunication/ICT Development Report 2006: Measuring ICT for social and economic development, <https://www.itu.int/pub/D-IND-WTDR-2006>.
- 71 IZM (Izglītības un zinātnes ministrija). (2014). Izglītības attīstības pamatnostādnes 2014.–2020.gadam, <http://www.mk.gov.lv/lv/mk/tap/?pid=40305684>.
- 72 Jerrim, J., & Sims, S. (2019). The Teaching and Learning International Survey (TALIS) 2018: June 2019.
- 73 Johansson, L., & Tjäder, C. (2013). IT-Support Direct from Project to a National Service. *Assistive Technology: From Research to Practice: AAATE 2013*, 33, 399.
- 74 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.
- 75 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.
- 76 Kuhn, M., & Johnson, K. (2013). *Applied predictive modeling* (Vol. 26). New York: Springer.
- 77 LAK. 1st International Conference on Learning Analytics, 2011, <https://tekri.athabascau.ca/analytics/>.

- 78 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.
- 79 Lerchner, A., La Camera, G., & Richmond, B. (2007). Knowing without doing. *Nature neuroscience*, 10 (1), 15–17.
- 80 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.
- 81 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.
- 82 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, 2015–237 pp.
- 83 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.
- 84 Machine Learning and Learning Analytics Workshop. 2014. Learning Analytics & Machine Learning, <http://machineanalytics.org/>.
- 85 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.
- 86 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.
- 87 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.
- 88 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.
- 89 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.
- 90 Mason, R., Rennie, F. e-Learning and social networking handbook: resources for higher education; 2008.
- 91 Miteva, D., & Stefanova, E. (2020). Design of Learning Analytics Tool: The Experts' Eyes View. In *CSEDU (2)* (pp. 307–314).
- 92 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.
- 93 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.
 - 94 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.
 - 95 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.
 - 96 Nissen, M., E. Harnessing knowledge dynamics: Principled organizational knowing & learning; 2006. p. 278.
 - 97 Nistor, N., M. Derntl, 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, et al., Editors. 2015, Springer International Publishing. p. 453–459.
 - 98 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.
 - 99 Nyce, C., & Cpcu, A. (2007). Predictive analytics white paper. *American Institute for CPCU. Insurance Institute of America*, 9–10.
 - 100 Ono, H. (2005). Digital Inequality in East Asia: Evidence from Japan, South Korea, and Singapore. *Asian Economic Papers*, 4 (3), 116–139.
 - 101 Ortiz-Rojas, M., Maya, R., Jimenez, A., Hilliger, I., & Chiluiza, 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.
 - 102 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.
 - 103 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.
 - 104 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.
 - 105 Pereira F. D. et al. (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.
 - 106 Pfeffer, J., & Sutton, R. I. (1999). Knowing „what” to do is not enough: Turning knowledge into action. *California management review*, 42 (1), 83–108.

- 107 Powell, K. C., Kalina, C. J. Cognitive and Social Constructivism: Developing Tools for an Effective Classroom. *Education*. 130 (2); 2009. p. 241–250.
- 108 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).
- 109 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.
- 110 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.
- 111 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>.
- 112 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.
- 113 Rintamäki, K., & Lehto, A. (2018). A digital information literacy course for university teachers: challenges and possibilities.
- 114 Robles, J. M., & Torres-Albero, C. (2012). Digital Divide and the Information and Communication Society in Spain. *Sociologija i prostor/Sociology & Space*, 50 (3).
- 115 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.
- 116 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.
- 117 Rudin, C. (2014). Prediction: Machine Learning and Statistics, (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.
- 118 Samuelson, P. (2003). Mapping the digital public domain: Threats and opportunities. *Law & Contemp. Probs.*, 66, 147.
- 119 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.
- 120 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.
- 121 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.

- 122 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.
- 123 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>.
- 124 Shearer C., *The CRISP-DM model: the new blueprint for data mining*, J Data Warehousing (2000); 5:13–22.
- 125 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.
- 126 Snee, R. D. (1977). Validation of regression models: methods and examples. *Technometrics*, 19 (4), 415–428.
- 127 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.
- 128 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 *CSEDU (1)* (pp. 63–74).
- 129 Stirna, J., & Persson, A. (2018). Enterprise modeling. *Cham: Springer*.
- 130 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.
- 131 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.
- 132 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.
- 133 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.
- 134 Tilde. (2014). Letonika, letonika.lv.
- 135 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.
- 136 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.
- 137 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.
- 138 van Dijk, J. A. (2006). Digital divide research, achievements and shortcomings. *Poetics*, 34 (4–5), 221–235.
- 139 Vedins, I. Macīšanās māksla. In Latvian. Riga: Avots; 2011.
- 140 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.
- 141 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.
- 142 Xu, Z., Yuan, H., & Liu, Q. (2020). Student Performance Prediction Based on Blended Learning. *IEEE Transactions on Education*.
- 143 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.
- 144 Yu, B., Ndumu, A., Mon, L. M., & Fan, Z. (2018). e-inclusion or digital divide: an integrated model of digital inequality. *Journal of Documentation*.
- 145 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.
- 146 Záhorec, J., Hašková, A., & Munk, M. (2019). Teachers' Professional Digital Literacy Skills and Their Upgrade. *European Journal of Contemporary Education*, 8 (2), 378–393.
- 147 Zhuge, H. The Knowledge Grid; 2004.
- 148 Zillien, N., & Hargittai, E. (2009). Digital distinction: Status-specific types of internet usage. *Social Science Quarterly*, 90 (2), 274–291.