



Kauno technologijos universitetas

Informatikos fakultetas

**Studentų akademinės sėkmės nuotolinėse studijose
prognozavimo galimybės taikant duomenų tyrybą**

Baigiamasis magistro projektas

Artūras Kukštys

Projekto autorius

Doc. Vytenis Punys

Vadovas

Kaunas, 2023



Kauno technologijos universitetas
Informatikos fakultetas

**Studentų akademinės sėkmės nuotolinėse studijose
prognozavimo galimybės taikant duomenų tyrybą**
Baigiamasis magistro projektas
Nuotolinio mokymosi informacinės technologijos (6211BX010)

Artūras Kukštys
Projekto autorius

Doc. Vytenis Punys
Vadovas

Lekt. Ramūnas Kubiliūnas
Recenzentas

Kaunas, 2023



Kauno technologijos universitetas

Informatikos fakultetas

Artūras Kukštys

Studentų akademinės sėkmės nuotolinėse studijose prognozavimo galimybės taikant duomenų tyrybą

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdama(s) kitų asmenų autoriaus ar kitų teisių, laikydamasi(s) Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu mokėjęs (-usi);
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalinta(s) iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Artūras Kukštys

Patvirtinta elektroniniu būdu

Kukštys Artūras. Studentų akademinės sėkmės nuotolinėse studijose prognozavimo galimybės taikant duomenų tyrybą. Magistro baigiamasis projektas / vadovas doc. dr. Vytenis Punys; Kauno technologijos universitetas, Informatikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Programų sistemos (B03), Informatikos mokslai.

Reikšminiai žodžiai: akademinė sėkmė, prognozavimas, duomenų tyryba, duomenų tyrybos metodai ir algoritmai.

Kaunas, 2023. 53 p.

Santrauka

Aukštosios mokyklos veikia konkurencingoje aplinkoje. Studentų akademiniai pasiekimai yra svarbus studijų kokybės rodiklis ir konkurencinio pranašumo faktorius, todėl aukštojo mokslo institucijoms aktualus tampa besimokančiųjų akademinės sėkmės prognozavimas. Atliekant akademinės sėkmės prognozavimą naudojami švietimo duomenys, kurių analizei yra taikoma duomenų tyrybos technologija.

Atlikta SSGG analizė atskleidė, kad KTU antrosios pakopos studentai nuotolinėse studijose „Nuotolinio mokymosi informacinės technologijos“ patiria akademinę nesėkmę ir studijas nutraukia. Šio darbo tikslas – taikant duomenų tyrybos technologiją ir siekiant sumažinti studentų nubyrejimą sudaryti sąlygas besimokančiųjų nuotoliniu būdu akademinėi sėkmei prognozuoti.

Tikslui pasiekti suprojektuota ankstyvojo įspėjimo sistema, kuri paremta duomenų tyrybos technologija. Ši sistema apima nuoseklią ir skaitmenizuotą studentų akademinės sėkmės stebėseną, padedančią nustatyti su studijų sunkumais susiduriančius studentus, įspėti apie juos aukštąją mokyklą ir imtis prevencinių priemonių, kad besimokantieji sėkmingai tęstų studijas ir jas baigtų.

Siekiant išanalizuoti sistemos tinkamumą studijų programoje buvo atliktas tyrimas, kurio rezultatai parodė, kad akademinės sėkmės prognozavimo modeliu galima numatyti, kuriems studentams gresia studijų nutraukimas, tačiau modelį svarbu tobulinti, kad sumažinti klaidos tikimybę ir padidinti prognozavimo tikslumą.

Kukštys Artūras. The Possibilities for Predicting Students' Academic Success in Distance Studies Using Data Mining. Master's Final Degree Project / supervisor doc. dr. Vytenis Punys; Faculty of Informatics, Kaunas University of Technology.

Study field and area (study field group): Software Engineering (B03), Computing.

Keywords: academic success, prediction, data mining, data mining methods and algorithms

Kaunas, 2023. 53 p.

Summary

Higher education institutions operate in a competitive market. Students' academic performance is significant in evaluating the quality of educational institutions and has a direct impact on their reputation. The ability to forecast students' academic success in a course or study program allows universities to take preventive measures to reduce student dropout rates. Recently, data mining techniques have been extensively used for prediction of academic success.

The SWOT analysis revealed that students experience academic failure and dropout in second cycle distance studies „Information Technologies of Distance Education“ in KTU. The aim of this project is to reduce the dropout rate among distance learners by creating conditions for predicting their academic success using data mining technique.

To achieve the aim, an early warning system based on data mining has been designed. This system involves a consistent and digitized monitoring of students' academic success, helping to identify learners who are facing academic difficulties and alerting the higher education institution about them. Furthermore, the designed system includes measures to prevent students from dropping out and to support their successful completion of their studies.

To assess the suitability of the system for the study program, a research was conducted. The results showed that it is possible to predict academic success using the forecasting model. Although the model can identify students that are at risk of dropping out, but it is important to refine the model to reduce the likelihood of errors and increase the accuracy of the predictions.

Turinys

Lentelių sąrašas.....	7
Paveikslų sąrašas	8
Terminų sąrašas	9
Įvadas.....	10
1. Problemos analizė	13
2. Literatūros apžvalga.....	17
2.1. Duomenų tyryba	17
2.2. Duomenų tyrybos metodai švietime	18
2.3. Akademinės sėkmės prognozavimas ir prognozavimui naudojami duomenys	20
2.3.1. Akademinės sėkmės prognozavimo procesas taikant duomenų tyrybą.....	21
2.4. Akademinės sėkmės prognozavimo ir akademinio saviveiksmingumo sąsajos.....	22
2.5. Akademinės sėkmės prognozavimas ir bendravimas virtualiojoje mokymosi aplinkoje	25
2.6. Programinė įranga aktualiai virtualiajai mokymosi aplinkai įgyvendinti	27
3. Ankstyvosios išpėjimo sistemos projektavimas	29
3.1. Duomenų paėmimas iš KTU IF Moodle duomenų bazės.....	29
3.2. Prognozavimui naudojamos duomenų tyrybos programinės sistemos parinkimas	30
3.2.1. Programinės sistemos diegimo dokumentacija.....	32
3.3. Akademinės sėkmės prognozavimo modeliavimas.....	33
3.4. Akademinės sėkmės prognozavimo modelio naudojimo dokumentacija.....	35
3.5. Akademinės nesėkmės prevencija KTU	41
4. Parengtos ankstyvojo išpėjimo sistemos tyrimas	42
4.1. SQL užklausų rezultatai.....	42
4.2. Akademinės sėkmės prognozavimo rezultatai	43
4.3. Rekomendacijos sukurtos ankstyvojo išpėjimo sistemos tobulinimui	45
Išvados.....	46
Literatūros sąrašas	47
Priedai	54
1 priedas. Tikslų medis	54
2 priedas. Parengtas tyrimo klausimynas „Google Forms“ įrankiu.....	55
3 priedas. Ištrauka iš pokalbio su KTU studijų departamento direktore	60
4 priedas. Leidimai naudotis „Studentų akademinio saviveiksmingumo skalė“ metodika	61
5 priedas. VMA vertinimo posistemio panaudojimo atvejų specifikacija.....	63
6 priedas. VMA bendravimo posistemio panaudojimo atvejų specifikacija	64
7 priedas. Akademinės sėkmės prognozavimui parengtos veiklos Moodle ir Chamilo VMA.....	65
8 priedas. Chamilo VMA grafinė vartotojo sąsaja lietuvių kalba	68
9 priedas. Studentų akademinės sėkmės prognozavimo nuotolinėse KTU studijose ontologija.....	69
10 priedas. SQL užklausos duomenims paimti iš KTU IF Moodle duomenų bazės	70
11 priedas. Duomenų parengimas programinėje sistemoje R	71
12 priedas. Prognozavimo modelio apmokymui parengto duomenų rinkinio iškarpa	73
13 priedas. Duomenų tyrybos programinės sistemos Weka diegimas Windows 10 OS.....	74
14 priedas. Pirminis akademinės sėkmės prognozavimo modelis Weka programinėje sistemoje	77
15 priedas. SQL užklausų testavimo rezultatai	78
16 priedas. Prognozavimo modelio testavimui parengto duomenų rinkinio iškarpa	82
17 priedas. Akademinės sėkmės prognozavimo modelio testavimo rezultatai	83
18 priedas. Studentų akademinės sėkmės prognozavimo sistemos modelio diegimo pažyma	86

Lentelių sąrašas

1 lentelė. Duomenų tyrybos taikymo galimybių KTU antrosios pakopos nuotolinėse studijose SSGG analizė.....	13
2 lentelė. Duomenų tyrybos metodai švietime	18
3 lentelė. Akademinei sėkmei prognozuoti naudojami duomenys.....	20
4 lentelė. Virtualiosios mokymosi aplinkos vertinimo posistemio reikalavimai	24
5 lentelė. Virtualiosios mokymosi aplinkos bendravimo posistemio reikalavimai.....	26
6 lentelė. Moodle ir Chamilo VMA palyginimas.....	28
7 lentelė. Akademines sėkmės prognozavimo modelio apmokymui sudaryto duomenų rinkinio struktūra.....	30
8 lentelė. Duomenų tyrybos programinių sistemų Weka, Orange ir SPSS palyginimas	31
9 lentelė. Pirminiame akademines sėkmės prognozavimo modelyje taikomų algoritmų rodikliai... 34	34
10 lentelė. Apmokymo ir testavimo duomenų rinkinio parengimas Weka programinėje sistemoje 35	35
11 lentelė. Akademines sėkmės prognozavimas Weka programinėje sistemoje	38
12 lentelė. Duomenų bazės serverių techniniai duomenys	42

Paveikslų sąrašas

1 pav. KTU antrosios pakopos nuotolinių studijų problemų medis	15
2 pav. Akademinės sėkmės prognozavimui taikomi duomenų tyrybos metodai ir algoritmai	22
3 pav. VMA vertinimo posistemio panaudojimo atvejų diagrama	24
4 pav. Panaudojimo atvejo „Atlikti testą“ veiklos diagrama	24
5 pav. VMA bendravimo posistemio panaudojimo atvejų diagrama.....	26
6 pav. Panaudojimo atvejo „Asmeninės žinutės siuntimas“ veiklos diagrama.....	27
7 pav. Panaudojimo atvejo „E. laiško siuntimas“ veiklos diagrama.....	27
8 pav. KTU antrosios pakopos nuotolinių studijų ankstyvojo išspėjimo sistema	29
9 pav. Studento duomenų pseudonimizacija	30
10 pav. Pirminiame akademinės sėkmės prognozavimo modelyje taikomų algoritmų rezultatai	33
11 pav. Studentų akademinės sėkmės prognozavimo modelis Weka programinėje sistemoje.....	35
12 pav. SQL užklauso testavimo pavyzdys paimant duomenis apie 2021 m. įstojusią studentų prisijungimus prie modulio „Tiriamasis projektas 1”.....	42
13 pav. Akademinės sėkmės prognozės 2021 m. įstojušiems studentams.....	43
14 pav. Akademinės sėkmės prognozės 2022 m. įstojušiems studentams.....	44
15 pav. KTU antrosios pakopos nuotolinių studijų tikslų medis	54

Terminų sąrašas

Akademinis saviveiksmingumas (angl. academic self-efficacy) – tai besimokančiojo tikėjimas savo gebėjimais atlikti akademinę užduotį [56].

Akademinė sėkmė (angl. academic success) – daugialypė sąvoka, kurią sudaro besimokančiojo pasiekimai, įgytos kompetencijos ir išsiugdyti įgūdžiai studijų metu, patiriamas mokymosi pasitenkinimas, palankiai susiklosčiusi karjera, mokymosi sunkumų įveikimas ir išsilavinimo patvirtinimas [14].

Ankstyvojo įspėjimo sistema (angl. early warning system) – aukštojo mokslo kontekste ankstyvojo įspėjimo sistema yra studentų stebėsenos priemonė, paremta iš švietimo duomenų ištraukta informacija apie studentų pasiekimus, aktyvumą, mokymąsi ir pan. Ši priemonė visų pirma skirta nustatyti studijų metu sunkumus patiriančius studentus ir įspėti apie juos švietimo instituciją. Pastaroji reaguodama į įspėjimus, numato ir taiko proaktyvias / reaktyvias pagalbos priemones, vedančias identifikuotus studentus į akademinę sėkmę [parengta autoriaus, remiantis 70, 71].

Duomenų tyryba (angl. data mining) – naujos informacijos išgavimas iš didžiųjų duomenų, saugomų duomenų bazėse [31].

Pseudonimizacija (angl. pseudonymisation) – unikalios identifikatoriaus suteikimas konkrečiam asmeniui bei to identifikatoriaus naudojimas vietoje tiesiogiai identifikuojamų duomenų, pvz. vardo, pavardės, asmens kodo ar jų derinio [72]

Virtualioji mokymosi aplinka (VMA) (angl. virtual learning environment) – tai nuotolinėms studijoms realizuoti naudojama internetinė platforma, kurioje pateikiama konkreti studijų informacija, tarpinių atsiskaitymų užduotys, patalpinama mokymosi medžiaga, vyksta sinchroninė ar asinchroninė komunikacija, bendradarbiavimas, atliekamas vertinimas ir įsivertinimas, mokymosi proceso stebėjimas ir pan. Tarp populiariausių VMA galima išskirti „Moodle“, „Canvas“, „Google Classroom“ [73].

Įvadas

Visose švietimo sistemos pakopose vienas svarbiausių švietimo institucijų darbo tikslų yra suteikti galimybę visiems besimokantiejiems patirti mokymosi sėkmę [1]. Pastarojo dešimtmečio nuotolinio mokymosi tyrimai [2, 3, 4] atskleidžia, kad suaugusieji dažnai renkasi nuotolines studijas, tačiau jų nebaigia dažniau nei tradicinių. Taigi besimokantieji akademinę nesėkmę patiria dažniau nuotolinėse studijose negu tradicinėse studijose. Akademinė nesėkmė aukštojoje mokykloje turi neigiamų pasekmių: mažina studentų pasitenkinimą mokymusi, silpnina jų savivertę, sukelia baimę būti atstumtiems visuomenėje ir darbo rinkoje [5]; švietimo institucijoje nekontroliuojamas besimokančiųjų skaičius apsunkina studijų proceso organizavimą, prasti akademiniai rezultatai kenkia švietimo institucijos reputacijai [6]; švietimui valstybės skiriami finansiniai ištekliai panaudojami neoptimaliai [7].

Šiandien aukštosios mokyklos veikia konkurencingoje aplinkoje, todėl aukštojo mokslo institucijoms aktualus tampa studentų akademinų rezultatų prognozavimas. Mokymosi rezultatų prognozavimo aktualumas pabrėžiamas ir Europos Komisijos skaitmeninio švietimo veiksmų plane [8]. Studentų akademiniai pasiekimai yra svarbus studijų kokybės rodiklis ir universiteto konkurencinio pranašumo faktorius. Mokslinėje literatūroje [9, 10] nurodoma, kad akademinų rezultatų prognozavimas yra susijęs su aukštosios mokyklos ankstyvojo įspėjimo sistema, kurios pagrindinis tikslas – identifikuoti besimokantįjį, kuriam gresia prasti mokymosi rezultatai, studijų dalyko neišlaikymas ar net iškritimas iš studijų. Šią sistemą taip pat sudaro aukštosios mokyklos numatytos akademinės nesėkmės prevencijos strategijos (studento įtraukimas į švietimo institucijos bendruomenę, mentoriavimas, kuravimo programų taikymas, mokymosi pagalbos teikimas, parengiamųjų kursų organizavimas ar kt.) ir akademinės nesėkmės intervencijos programos, lydinčios besimokantįjį į aukštesnius studijų rezultatus, mokymosi tęsimą bei sėkmingą studijų užbaigimą. Pagal C. Burgos et al. [11] atlikta preliminaria akademinės nesėkmės ir pavojaus iškristi prognoze bei ja paremtu prevenciniu modeliu, aukštoji mokykla iškritimo mastus iš nuotolinių studijų sumažino 14 procentų. E. Seidel ir S. Kutieleh [12] pažymi, kad ankstyvasis akademinės nesėkmės numatymas ir identifikuotiems studentams taikyta „Studentų mokymosi sėkmės“ programa sumažino pirmakursių studijų dalykų neišlaikymą ir pagerino jų akademinus rezultatus.

Remiantis VšĮ „Investuok Lietuvoje“ ir asociacijos „Infobalt Lietuva“ 2020 m. atliktos analizės duomenimis [7], akademinės nesėkmės prevencijos priemonių plėtojimas Lietuvos aukštosiose mokyklose yra neefektyvus, jos taiko skirtingas studentų nubyrėjimo mažinimo priemones, joms vykdyti nėra skiriami ištekliai, neturima išsamios ir patikimos informacijos apie studijų nutraukimo priežastis, akademinų pasiekimų gerinimo ir iškritimo iš studijų mažinimo veiklos yra per mažos apimties, epizodinės ir nepasiekiamos visiems studentams. Taip pat atskleista, kad dauguma Lietuvos aukštųjų mokyklų neturi įdiegtos ankstyvojo įspėjimo sistemos, apimančios studentų pažangos stebėseną. Taigi baigiamajame projekte **sprendžiama problema** – besimokantieji Lietuvos aukštosiose mokyklose patiria akademinę nesėkmę.

Teigiama [3, 10, 13], jog prognozuoti studentų akademinę sėkmę nuotolinėse studijose galima keliais būdais: bendraujant su besimokančiais, atliekant apklausas, taikant duomenų tyrybą. Remiantis mokslinės literatūros apžvalgomis [3, 4, 10, 14, 15] galima teigti, jog duomenų tyrybą atlieka vis daugiau užsienio švietimo institucijų. Ši technologija suteikia galimybę gauti vertingų įžvalgų, nes gali atvaizduoti besimokančiųjų mokymosi tendencijas ir kitą su mokymusi susijusią informaciją. Duomenų tyryba padeda švietimo institucijoms mažinti studentų nubyrėjimą [11], gerinti mokymosi

kokybę [16], gerinti besimokančiųjų mokymosi pasiekimus [12, 17] bei tobulinti visą mokymosi procesą [18]. Pasak U. I. Usman et al. [19], akademinės sėkmės prognozavimas yra sudėtingas uždavinys aukštojo mokslo institucijoms dėl skirtingai vykdomos duomenų saugojimo praktikos, duomenų gausos, jų įvairovės bei dėl duomenų tyrybos modeliavimo, kurio metu ieškoma tiksliausias prognozes pateikiančio metodo ir algoritmo. Siekiant sėkmingai gauti naudingos informacijos iš sukauptų švietimo duomenų, kuo tiksliau numatyti akademinis pasiekimus ir tinkamai parengti ankstyvąją įspėjimo sistemą aukštajai mokyklai, būtina ne tik gerai suprasti duomenų tyrybos procesą, taikomus metodus ir programines sistemas, bet ir išanalizuoti duomenų tyrybos taikymo galimybes aukštojoje mokykloje.

Taigi šio baigiamojo projekto **tikslas** – taikant duomenų tyrybos technologiją ir siekiant sumažinti studentų nubyrijimą sudaryti sąlygas besimokančiųjų nuotoliniu būdu akademinėi sėkmei prognozuoti. Tikslui pasiekti keliami **uždaviniai**:

1. apžvelgti duomenų tyrybos taikymą švietime siekiant prognozuoti studentų akademinę sėkmę;
2. išanalizuoti duomenų tyrybos taikymo galimybes siekiant prognozuoti KTU nuotoliniu būdu organizuojamos antrosios pakopos studijų programos „Nuotolinio mokymosi informacinės technologijos“ studentų akademinę sėkmę;
3. parengti studentų akademinę sėkmę nuotolinėse studijose prognozuojantį modelį ir įvertinti jo kokybę;
4. ištestuoti parengtą studentų akademinę sėkmę prognozuojantį modelį ir išanalizuoti pokyčius sprendžiant studentų nubyrijimo problemą.

Darbo **objektas** – studentų duomenys ir duomenų tyrybos metodai bei algoritmai.

Darbo **rezultatas** – sudarytos sąlygos prognozuoti besimokančiųjų akademinę sėkmę nuotolinėse studijose sukurta ankstyvojo įspėjimo sistema.

Darbo **produktas** – besimokančiųjų akademinės sėkmės prognozavimo sistemos modelis. Šio modelio diegimą KTU nuotoliniu būdu organizuojamose antrosios pakopos studijų programoje „Nuotolinio mokymosi informacinės technologijos“ patvirtinanti pažyma pateikiama 18 priede.

Baigiamąjį projektą sudaro įvadas, 4 skyriai, išvados, literatūros sąrašas ir priedai. Projekto apimtis yra 53 puslapiai, 12 lentelių ir 15 paveikslų. Literatūros sąrašas yra 73 šaltiniai. Projekto pabaigoje pateikta 18 priedų.

Pirmame skyriuje atlikta SSGG analizė siekiant išsiaiškinti, kokios yra duomenų tyrybos taikymo galimybės prognozuoti studentų akademinę sėkmę KTU nuotoliniu būdu organizuojamose antrosios pakopos studijų programoje „Nuotolinio mokymosi informacinės technologijos“.

Antrame skyriuje atlikta literatūros apžvalga apie studentų akademinės sėkmės nuotolinėse studijose prognozavimo būdus. Čia apibūdinama duomenų tyrybos technologija ir apžvelgiami studentų akademinėi sėkmei prognozuoti naudojami švietimo duomenys, jų analizei taikomi duomenų tyrybos metodai bei algoritmai.

Trečiame skyriuje pateikiamas studentų akademinę sėkmę nuotolinėse studijose prognozuojantis modelis ir įvertinama jo kokybė. Čia taip pat pateikiamas akademinės sėkmės prognozavimui

naudojamos duomenų tyrybos programinės sistemos palyginimas ir tinkamiausios sistemos pasirinkimas.

Ketvirtame skyriuje analizuojami akademinės sėkmės prognozavimo modelio testavimo rezultatai ir pateikiamos rekomendacijos akademinės sėkmės prognozavimo modelio tobulinimui.

1. Problemos analizė

Problemos analizėje remiamasi KTU politiniais dokumentais [20, 21], studijų programos modulių apžvalga KTU IF Moodle virtualiojoje mokymosi aplinkoje, KTU akademinės informacinės sistemos apžvalga, paskaitų stebėjimu, studijų programos studentų pasisakymais uždaroje socialinėje grupėje Facebook, atlikto sociologinio pobūdžio tyrimo rezultatais (žr. 2 priedą) bei pokalbio su studijų programos kuratoriumi ir KTU studijų departamento direktore duomenimis (žr. 3 priedą). Siekiant išanalizuoti duomenų tyrybos taikymo galimybes prognozuoti studentų akademinę sėkmę KTU antrosios pakopos nuotolinėse studijose „Nuotolinio mokymosi informacinės technologijos“ buvo atlikta SSGG analizė, kuri pateikiama 1 lentelėje.

1 lentelė. Duomenų tyrybos taikymo galimybių KTU antrosios pakopos nuotolinėse studijose SSGG analizė

STIPRYBĖS	<ul style="list-style-type: none">-KTU strategijos prioritetingos veiklos-Naudojama virtualioji mokymosi aplinka-Akademinė informacinė sistema-Patirtis diegiant ankstyvojo išpėjimo sistemą-Aukštos kvalifikacijos ir kompetentingi dėstytojai KTU
SILPNYBĖS	<ul style="list-style-type: none">-Trūksta informacijos apie besimokančiųjų situaciją dabartyje-Netolygus besimokančiųjų vertinimas-Netolygi besimokančiųjų pažangos stebėseną-Besimokančiųjų nubyrejimas-Besimokantieji patiria įtampą semestro pabaigoje
GALIMYBĖS	<ul style="list-style-type: none">-Naudoti nuasmenintus administracinius ir mokymosi proceso duomenis-Skaitmenizuoti besimokančiųjų pažangos stebėseną-Optimizuoti didžiųjų švietimo duomenų panaudojimą-Tobulinti akademinės paramos teikimo sistemą-Įgyvendinti EK numatytus veiklos prioritetus („tobulinti švietimo sistemas geriau analizuojant duomenis ir prognozuojant“)
GRĖSMĖS	<ul style="list-style-type: none">-Besimokančiojo duomenų apsaugos, privatumo ir konfidencialumo užtikrinimas-Duomenų tyrybos metu ištrauktos informacijos eikvojimo rizika-Moodle serverio apkrova ištraukiant duomenis iš duomenų bazės

KTU strateginiuose dokumentuose [20, 21], nurodoma, kad viena iš prioritetingų universiteto veiklų yra universiteto infrastruktūros modernizavimas. Siekdamas palaikyti nepertraukiamą inovacijų diegimą organizacijos viduje naudojamose sistemose ir technologijose, universitetas planuoja tobulinti ir skaitmenizuoti veiklos procesus. Institucijos dokumentuose taip pat didelis dėmesys skiriamas studijų kokybei bei universiteto įvaizdžiui. Besimokančiųjų akademiniai pasiekimai yra svarbus studijų kokybės rodiklis, o geri akademiniai rezultatai, kaip ir sėkmingas studijų baigimas, palankiai veikia švietimo institucijos reputaciją. Pasak studijų programos kuratoriaus, 2020 m. studijų programą rudens semestre nutraukė 9 pirmakursiai. Programos dėstytojai nežino, kokia yra situacija su pirmakursiais 2021 m. rudens semestre, nes dalis magistrantų neprisijungia į nuotolines paskaitas, neatsiskaito laboratorinius darbus ir t. t. Pavyzdžiui, modulyje „Algoritmai ir objektinis programavimas“ 5 besimokantieji iš 12 semestro pabaigoje nėra atsiskaitę nė vienos užduoties, jie neatsako į e. paštu siunčiamus dėstytojų laiškus. Analizuojant studijų programos modulius nustatyta, kad besimokančiųjų vertinimas moduluose yra netolygus, kaip netolygi šiuo metu yra besimokančiųjų pažangos stebėseną. Studijų programos besimokantieji praėjus pirmajai semestro

pusei nežino savo mokymosi įvertinimo, kaupiamojo balo, nes dalis dėstytojų vėluoja surašyti įvertinimus į Moodle ar akademinę informacinę sistemą. Be to, moduliuose kaip „Nuotolinio mokymosi teorijos ir sistemos“, „Tiriamasis projektas 1“ pagrindiniai atsiskaitymai numatyti tik semestro pabaigoje, o kaupiamąjį balą sudaro viena, tačiau didelę procentinę vertę turinti užduotis. Šiuo atveju sudėtinga prognozuoti besimokančiojo mokymosi rezultatus ir laiku suteikti akademinę paramą, nes apie besimokančiojo akademinę sėkmę / nesėkmę sužinoma tik semestru baigiantis, kai studentai pateiks / nepateiks modulių užduotis. Svarbu pažymėti, kad dalis pirmakursių jaučia įtampą dėl semestro pabaigoje susikaupusių užduočių ir apie tai dalinasi studijų programos socialinėje grupėje. Pavyzdžiui: „Jau toj realiai verksiu ir be muzikinio... kiek visiems visko reikia padaryti... ir visiems viskas paciam gale sukrauta“, „Verksim abi, nes ir man jau pradeda panika kilti“. Atsižvelgiant į tai programos dėstytojams rekomenduojama tobulinti kaupiamojo balo sistemą ir užduočių atsiskaitymo tvarkaraštį, mažinant įtampą semestru baigiantis bei skatinant sistemingą ir nuoseklų mokymąsi viso semestro metu.

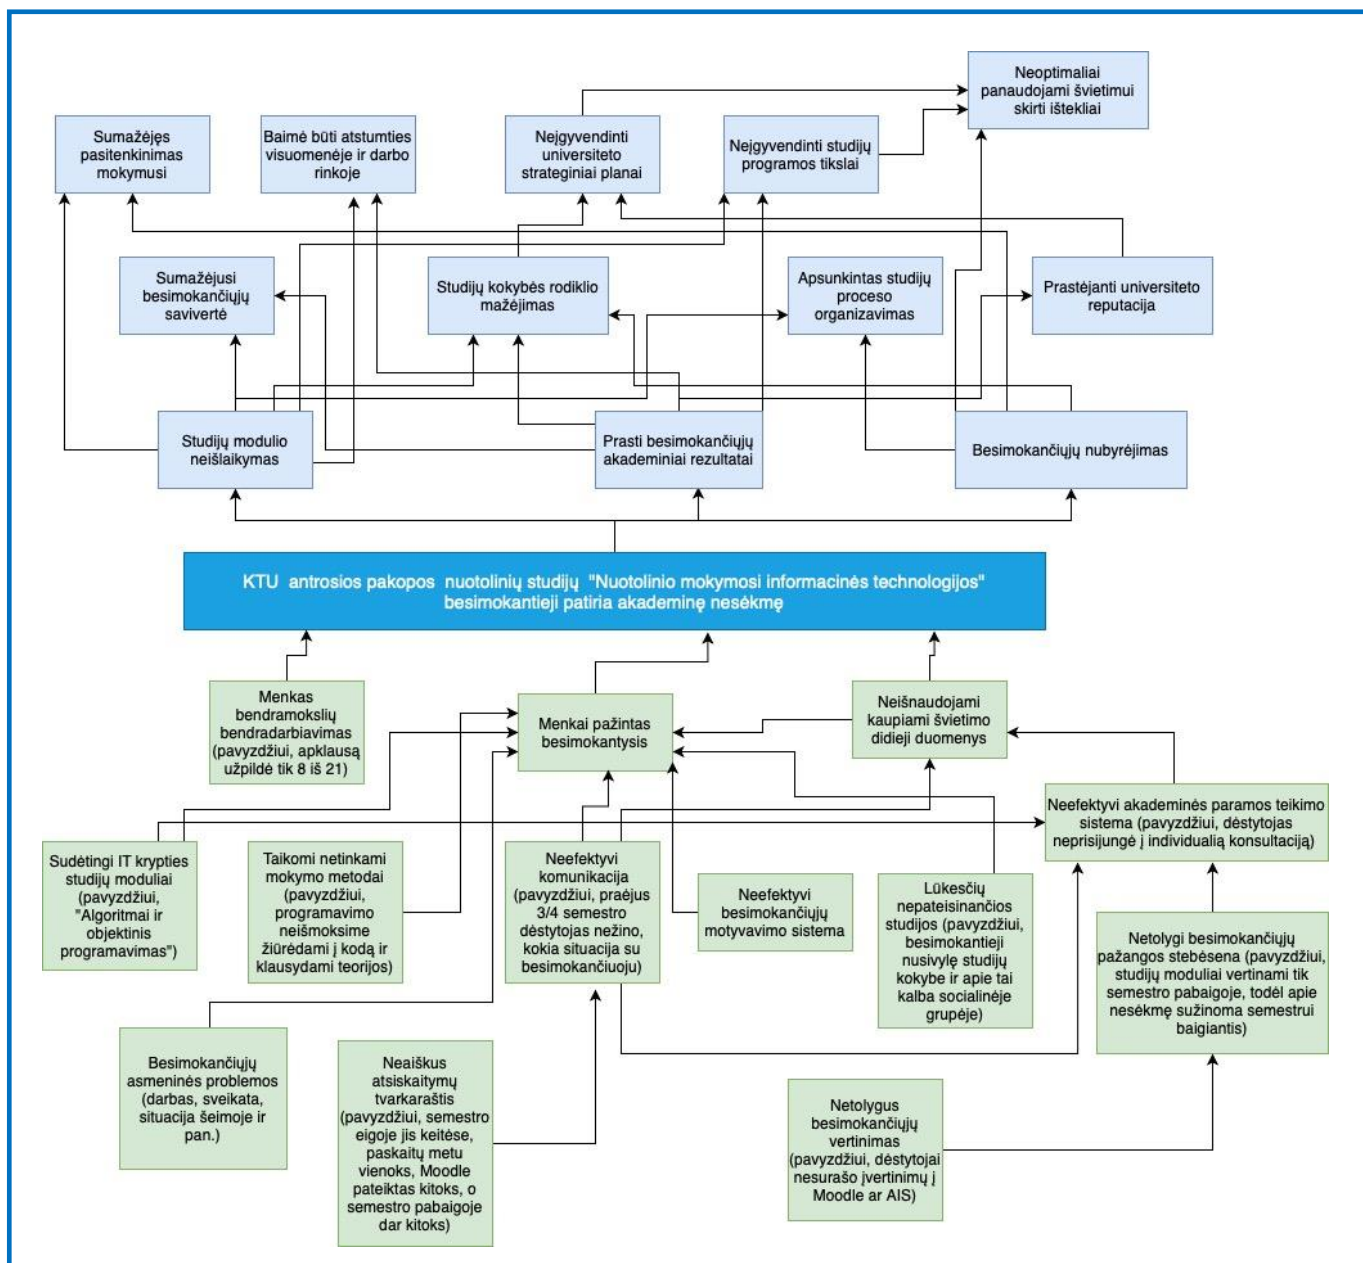
KTU nuotolinėms studijoms realizuoti naudojama virtualioji mokymosi aplinka Moodle. Moodle duomenų bazėje saugomi įvairūs besimokančiųjų mokymosi proceso duomenys: besimokančiojo prisijungimų laikas, dažnumas, atliktos veiklos, gauti įvertinimai ir kt. Moodle sistemoje studijų programos kuratoriams ir dėstytojams sudaryta galimybė gauti įvairias ataskaitas, kurias analizuojant galima įvertinti besimokančiųjų pasiektus mokymosi rezultatus, sekti besimokančiųjų pažangumą, aktyvumą ir pan. KTU akademinėje informacinėje sistemoje yra kaupiami administraciniai duomenys apie besimokančiųjų. Studijų programos virtualiojoje mokymosi aplinkoje ir akademinėje informacinėje sistemoje švietimo didieji duomenys yra kaupiami, tačiau dėstytojų neanalizuojami. Šiuos duomenis tikslinga analizuoti taikant duomenų tyrybos technologiją, nes duomenų tyryba įgalina optimaliai panaudoti didžiuosius švietimo duomenis ir išgauti iš jų naudingos informacijos. KTU tikslinga kurti ir įsidiesti prevencinę ankstyvojo išpėjimo sistemą, paremtą švietimo duomenų tyrybos technologija. Ankstyvojo išpėjimo sistema apima nuoseklią ir skaitmenizuotą studentų pažangos stebėseną, padedančią identifikuoti su studijų sunkumais susiduriančius studentus ir taikyti ankstyvosios intervencijos ir (ar) prevencijos priemones.

Didžiųjų švietimo duomenų išgavimas iš Moodle duomenų bazės apkrauna serverį ir sulėtina virtualiosios mokymosi aplinkos darbą. Todėl norint išvengti studijų proceso trikdžių duomenis iš duomenų bazės reikia paimti naktį, kai virtualiojoje mokymosi aplinkoje yra mažiausiai prisijungusių besimokančiųjų. Dirbant su švietimo duomenimis būtina užtikrinti besimokančiojo duomenų apsaugą, besimokančiojo privatumą ir konfidencialumą. Duomenų tyrybos metu išgauta informacija turi būti naudojama laikantis etikos principų. Pirminis KTU duomenų valdytojas pirmiausia turi atlikti besimokančiojo duomenų pseudonimizaciją ir kiekvieno besimokančiojo duomenims sukurti raktą. Raktas apsaugo besimokančiojo identifikaciją kuriant ankstyvąją išpėjimo sistemą, o ją sukūrus ir įdiegus vidinis raktas įgalina tik studijų programos administraciją identifikuoti sunkumus patiriančius besimokančiuosius.

Pasak KTU studijų departamento direktorės Kristinos Ukvalbergienės [7], 2016 m. KTU vykdė projektą, kurio pagrindinis tikslas buvo sumažinti studentų nubyrijimo procentą. Projekto metu buvo sukurta ankstyvojo išpėjimo sistema, stebinti ir analizuojanti studentų studijų pasiekimus ir daromą pažangą. Universitete taip pat dirba aukštos kvalifikacijos ir kompetentingi dėstytojai, kaip pavyzdžiui, Tomas Ruzgas, Vytautas Janilionis, Irena Patašienė ir kt., kurie specializuojasi duomenų tyrybos srityje ir dalyvauja universiteto mentorystės programoje. Vadinasi, universitetas turi kompetentingų ir bendradarbiauti pasirengusių specialistų bei gerosios patirties kuriant ir diegiant

ankstyvojo išpėjimo sistemą, apimančią studentų pažangos stebėseną. Mentorių įtraukimas į ankstyvosios išpėjimo sistemos kūrimą prisideda prie universiteto ilgalaikio strateginio tikslo įgyvendinimo – sąveikos tarp kompetentingų dėstytojų ir motyvuotų studentų. Šio projekto atveju – sąveikos tarp KTU mentorių ir magistrinio baigiamąjį projektą rengiančiojo.

SSGG analizė atskleidė, kad besimokantieji KTU antrosios pakopos studijose „Nuotolinio mokymosi informacinės technologijos“ patiria akademinę nesėkmę. Pagrindinės problemos priežastys ir pasekmės pateikiamos problemų medyje (žr. 1 paveikslą).



1 pav. KTU antrosios pakopos nuotolinių studijų problemų medis

Taigi studijų programoje kaupiamus švietimo duomenis reikia išnaudoti optimaliai, todėl tikslinga juos analizuoti taikant duomenų tyrybos technologiją. KTU sudarytos palankios politikos sąlygos taikyti duomenų tyrybą ir jos pagalba prognozuoti besimokančiųjų akademinę sėkmę. Universitetas taip pat turi techninį pagrindą ir žmogiškųjų išteklių, sustiprinančių duomenų tyrybos realizaciją.

Studijų programai svarbu sukurti ir įdiegti prevencinę ankstyvojo išpėjimo sistemą (žr. 1 priedą), kuri apima nuoseklią studentų pažangos stebėseną ir yra paremta švietimo duomenų tyrybos technologija.

2. Literatūros apžvalga

2.1. Duomenų tyryba

Duomenų tyrybos terminas atsirado 1978-aisiais, tačiau didelį populiarumą įgijo 1990-aisiais, kaip nauja duomenų analizės ir informacijos gavimo technologija. Iki to laiko duomenų apdorojimas ir analizė buvo atliekami naudojant taikomosios statistikos metodus ir nedideles duomenų bazes. Mokslinėje literatūroje kaip sinonimai taip pat vartojami terminai „duomenų gavyba“, „duomenų kasyba“.

Duomenų tyrybą įvairūs autoriai apibrėžia skirtingai. Pavyzdžiui, O. Niakšu [22 p. 10] duomenų tyrybą apibrėžia kaip „duomenų analizę, siekiant atrasti nežinomus dėsningumus ir aprašyti (apibendrinti) duomenis suteikiant naujų žinių“. G. Bazilevičius [23 p. 97] duomenų tyrybą apibūdina kaip „tendencijų, šablonų, ryšių ir kategorijų aptikimo procesą, naudojant šablonus bei mašininis mokymosi algoritmus. Šio proceso metu, naudojant šablonų atpažinimo protokolus ir taikant statistinius bei matematinius metodus, išsamiai tiriama duomenys“. Anot D. Kaklauskienės [24 p. 155], „duomenų tyryba – daugiareikšmė sąvoka: ją galima apibrėžti kaip struktūrų (modelių, ryšių, statistinių modelių, šablonų) radimą duomenų bazėse, kaip statistikos pritaikymą tiriamųjų duomenų analizės ir prognozuojamų modelių formai, siekiant atrasti modelius ir kryptingumus dideliuose duomenų rinkiniuose, ir kaip didelių duomenų kiekių tyrinėjimą ir analizę automatizuotu arba pusiau automatizuotu būdu, siekiant rasti naudingus modelius ir taisykles“.

A. V. Manjarres et al. [25] teigimu, į duomenų tyrybą galima žiūrėti, kaip į metodų ir procedūrų rinkinį, kuris skirtas įvairiose duomenų saugyklose ar duomenų bazėse saugomiems didiesiems duomenims analizuoti, pavyzdžiui: pervedimų transakcijoms, mokslinių tyrimų duomenims, asmens sveikatos duomenims, vaizdo įrašams ir nuotraukoms, palydovų registruojamiems duomenims ir pan. Pagrindinė duomenų tyrybos paskirtis yra iš daugybės duomenų išrinkti svarbiausius duomenis minimizuojant laiko sąnaudas ir technologinius išteklius. Ji padeda tyrėjams efektyviai panaudoti kaupiamus duomenis ir priimti tinkamus, mažesnę klaidos tikimybę turinčius sprendimus [26]. Pavyzdžiui, sveikatos sektoriuje paciento duomenų tyryba įgalina spręsti tokius uždavinius, kaip antai: greitesnė pacientų diagnostika, optimalaus gydymo parinkimas, gydymo trukmės ir rezultatų prognozavimas, komplikacijų rizikos nustatymas, sveikatos priežiūros įstaigos išteklių optimizavimas ir kt. [22].

Duomenų tyryba, tai dirbtinio intelekto technologija, galinti optimaliai apdoroti duomenis ir atskleisti praktiškai naudingus atsakymus [27]. Pavyzdžiui, prekybos tinklas kaupia pirkėjų finansinių operacijų duomenis, kuriuos apdorojant ir analizuojant galima išgauti reikšmingos informacijos apie pirkėjų apsipirkimo ypatumus, prekių paklausą ir pan. Prekybos tinklas, kuris pažįsta savo klientą ir analizuoja jo elgseną, įgauna konkurencinį pranašumą bei pridėtinę vertę, nes remdamasis sukauptais duomenimis ir vykdydamas jų analizę gali efektyviau išnaudoti savo biudžetą, parinkti rinkodaros strategiją ir pasiekti geresnių rezultatų lyginant su konkurentais [26].

Duomenų tyrybos terminas klasikinėje statistikoje vartojamas seniai. Pasak J. Srivastava ir A. Srivastava [28], duomenų tyrybos atsiradimą iš vienos pusės sąlygojo klasikinės statistikos metodų netobulumas, iš kitos – pažangumas dirbtinio intelekto ir mašininio mokymosi srityje. Ši technologija primena statistiką, kadangi statistika ir duomenų tyryba yra į duomenų analizę orientuoti procesai, kuriems būtinas pirminių duomenų sutvarkymas, tačiau mokslinės literatūros apžvalgoje [28] pabrėžiama, kad duomenų tyrybos nereikėtų tapatinti su statistika. Statistika dažniausiai taikoma

pirminei duomenų analizei, o duomenų tyryba – antrinei duomenų analizei. Mokslinėje literatūroje [22; 28] yra pateikiama ir kitų reikšmingų skirtumų:

1. statistikoje suformuluota hipotezė testuojama naudojant statistinius metodus, o duomenų tyryboje taikomi indukcijos metodai, formuluojant hipotezes iš turimų duomenų;
2. statistikoje dažniausiai analizuojama populiacijos imtis, o duomenų tyryboje – dažniausiai visi populiacijos duomenys;
3. statistikoje taikomi formalūs matematiniai metodai ir vengiama naudoti netikslus euristinius metodus, tuo tarpu duomenų tyrybos metodai grindžiami matematika, kur taip pat plačiai taikomos euristikos, lokalaus sprendimo paieškos ir kiti panašūs metodai, kurie nukreipti į uždavinius su didele duomenų imtimi, kategoriniais kintamaisiais arba prasta tiriamų duomenų kokybe.

Taigi duomenų tyryba yra šiuolaikinė duomenų analizės technologija, kuri suteikia galimybę iš sukauptų didžiųjų duomenų išgauti naudingos informacijos, tinkamos analizuojamai veiklai valdyti, problemos analizei, sprendimams priimti, ateities prognozėms ir pan. Pagrindinė šios technologijos paskirtis yra iš daugybės sukauptų duomenų išrinkti svarbiausius duomenis minimizuojant laiko sąnaudas ir technologinius išteklius. Ji suteikia galimybę tyrėjams efektyviai panaudoti renkamus duomenis ir priimti mažesnę klaidos tikimybę turinčius sprendimus.

2.2. Duomenų tyrybos metodai švietime

Duomenų tyryboje taikomi tam tikri mašininio mokymosi metodai, pagal kuriuos nestruktūrizuoti duomenys yra organizuojami ir klasifikuojami [29]. Renkantis duomenų tyrybos metodą ir algoritmą atsižvelgiama į turimus duomenis, tyrimo tikslą ir siektinus rezultatus [30].

Švietimo duomenų tyryba yra apibūdinama kaip naujos informacijos išgavimas iš didžiųjų švietimo duomenų, renkamų švietimo aplinkoje ir saugomų švietimo duomenų bazėse [31]. Mokslinėje literatūroje [31, 32] nurodoma, kad švietimo duomenų tyryboje dažniausiai naudojamas klasifikavimas, regresija, klasterizavimas. Taip pat taikomas asociacijų taisyklių metodas, sekų nustatymo tyrybos metodas bei duomenų vizualizavimo metodas, leidžiantis duomenis atvaizduoti suprantamai ir aiškiai. Švietimo duomenų tyrybos metodų apžvalga pateikiama 2 lentelėje.

2 lentelė. Duomenų tyrybos metodai švietime [sudaryta autoriaus, remiantis 31, 33]

Kategorija	Tikslas	Metodas	Teorinis taikymas	Praktinis pavyzdys
Prognozavimo	Numatyti vieno kintamojo reikšmes (pasekmes) remiantis kitais kintamaisiais	Klasifikavimas	Prognozuoti besimokančiųjų tikimybę išlaikyti/neišlaikyti egzaminą, užbaigti/neužbaigti modulį, kursą ar studijas	R. Trakunphutthirak et al. [34] naudoja besimokančiųjų mokymosi proceso duomenis ir taiko klasifikavimo metodą prognozuodami besimokančiųjų tikimybę neužbaigti kursą
		Regresinė analizė	Prognozuoti besimokančiųjų įvertinimus	R. R. Rajalaxmi et al. [35] naudoja duomenis apie inžinerijos studentų praleistą laiką virtualiojoje mokymosi aplinkoje ir taiko tiesinės regresijos metodą prognozuodami

				besimokančiųjų akademinius rezultatus
Grupavimo	Identifikuoti panašių požymių grupes	Klasterizavimas	Grupuoti besimokančiuosius pagal jų elgsenos mokymosi aplinkoje profilius	S. Križanič [36] naudoja besimokančiųjų mokymosi proceso duomenis ir taiko klasterizavimą, kad nustatytų, kokią mokymosi medžiagą reikėtų tobulinti ir kokią mokymosi medžiagą turėtų rinktis besimokantieji ruošdamiesi egzaminams
Sąryšio	Rasti ryšį tarp kintamųjų ir to ryšio taisykles	Asociacijų taisyklių metodas	Nustatyti, kokias mokymosi temas siūlyti esant tam tikroms sąlygoms	J. Chen ir J. Zhao [37] naudoja besimokančiųjų mokymosi proceso duomenis ir taiko asociacijų taisyklių metodą siekiant nustatyti, kokie mokymosi įpročiai padeda mokytis anglų kalbos
		Sekų nustatymas	Apibrėžti besimokančiųjų elgsenos modelius, kurie lemia tam tikrą mokymosi rezultatą	E. Doko et al. [38] naudoja besimokančiųjų mokymosi proceso duomenis ir taiko sekų nustatymo metodą identifikuojant svarbiausias ir sudėtingiausias mokymosi temas naudojantis mobiliosiomis technologijomis
Asistavimo	Pateikti duomenis suprantamesniu būdu pasitelkiant papildomus elementus	Duomenų vizualizavimas	Naudojantis diagramomis pavaizduoti, kaip greitai yra išmokstama tam tikra mokymosi medžiaga ir padėti suprasti besimokančiojo mokymosi modelius, rezultatus ir pan.	R. Paiva et al. [39] atlikusiai švietimo duomenų tyrybai panaudojo duomenų vizualizavimą. Gauti rezultatai atskleidė, kad 84 % švietėjų duomenų vizualizavimas padėjo suprasti duomenų tyrybos rezultatus
Konstravimo	Naudoti kelis modelius, kurie sprendžia kelis uždavinius	Konstruktų modeliavimas	Modelį, atskleidžiantį besimokančiojo pasitenkinimą mokymusi, taikyti prognozuojant jo elgsenai	Almasi et al. [40] pirmiausiai taiko klasterizavimą, kad suskirstytų besimokančiuosius į grupes, o vėliau naudoja klasifikavimą, kad prognozuotų besimokančiųjų pasiekimus

Taigi švietimo duomenų tyryboje taikomas klasifikavimas, regresija, klasterizavimas, asociacijų taisyklių metodas, sekų nustatymo tyrybos metodas bei duomenų vizualizavimo metodas. Kiekvienai švietimo problemai spręsti reikia parinkti tinkamą duomenų tyrybos metodą ir tinkamus duomenų

rinkinius. Švietimo duomenų tyrybai galima pritaikyti po keletą metodų, kurie veikdami skirtingai, padeda gauti skirtingus rezultatus ir leidžia į situaciją pažvelgti įvairiapusiškai.

2.3. Akademinės sėkmės prognozavimas ir prognozavimui naudojami duomenys

Mokslinėje literatūroje [14, 41] akademinė sėkmė yra apibrėžiama, kaip daugialypė sąvoka, apimanti akademinis pasiekimus, išitraukimą į mokymosi procesą, patiriamą pasitenkinimą mokymusi, mokymosi metu įgytas kompetencijas ir išsiugdytus įgūdžius, mokymosi sunkumų įveikimą ir mokymosi tęsimą, palankiai susiklosčiusią profesinę karjerą, pasiektus mokymosi tikslus.

Prognozuoti besimokančiųjų akademinę sėkmę nuotolinėse studijose galima bendraujant su besimokančiais, atliekant apklausas ir įvertinimus, taikant duomenų tyrybą [2, 9, 12]. Bendravimo ar vertinimo veiklos nuotolinėse studijose organizuojamos ir įgyvendinamos virtualiojoje mokymosi aplinkoje, kaip pavyzdžiui, Moodle, Chamilo, Google Classroom, itslearning, Blackboard, ILIAS ir kt. Bendravimo su besimokančiais VMA metu besimokantieji gali patys įspėti dėstytojus apie studijų nutraukimą. Atliekant apklausas ir įvertinimus VMA galima surinkti informaciją apie besimokančiųjų demografinius duomenis ir įvertinti besimokančiųjų psichologinius ypatumus, kurie yra reikšmingi akademinėi sėkmei. Moksliniai tyrimai [42, 43] atskleidžia, kad besimokantieji, kurie pasižymi aukštu akademinio saviveiksmingumu gauna geresnius įvertinimus ir sėkmingai baigia studijas, todėl teigiama, kad akademinis saviveiksmingumas yra vienas svarbiausių psichologinių ypatumų, leidžiančių prognozuoti akademinę sėkmę. VMA vykstantis nuotolinio mokymosi procesas sugeneruoja daugybę švietimo duomenų, kuriuos tikslinga analizuoti taikant duomenų tyrybos technologiją ir tokiu būdu išgauti naudingos informacijos, atskleidžiančios apie besimokančiojo akademinę sėkmę. Atsižvelgiant į akademinės sėkmės prognozavimo būdus sudaryta akademinės sėkmės prognozavimo KTU nuotolinėse studijose ontologija (žr. 9 priedą).

Prognozuojant besimokančiųjų akademinę sėkmę analizuojami įvairūs besimokančiųjų duomenys (besimokančiųjų veiksmai virtualiojoje mokymosi aplinkoje, psichologinių apklausų atsakymai, demografinės charakteristikos ir pan.) ir ieškoma informacijos apie akademinės nesėkmės riziką. Apžvelgus mokslinėje literatūroje [11, 15, 16, 44] aprašomus tyrimus, galima išskirti du duomenų tipus, kurie yra naudojami akademinės sėkmės prognozavimui, t. y. administraciniai duomenys ir mokymosi proceso duomenys. Literatūros apžvalgoje [45] taip pat akcentuojama, kad naudingiausia informacija taikant duomenų tyrybą išgaunama tada, kai tiriamų švietimo duomenų rinkiniuose yra abiejų tipų duomenų. Duomenys išsamiau apžvelgiami 3 lentelėje.

3 lentelė. Akademinėi sėkmei prognozuoti naudojami duomenys [sudaryta autoriaus, remiantis 11, 15, 16, 44]

Duomenų tipas	Duomenų potipis	Duomenys
Administraciniai duomenys	Ankstesnių mokymosi pasiekimų rezultatai	Mokymosi rezultatai vidurinio ugdymo mokykloje, brandos egzaminų įvertinimai, konkursinis balas stojant, stojamojo egzamino įvertinimas, semestro pažymių vidurkis, semestro dalykų (modulių) pažymiai
Administraciniai duomenys	Demografiniai duomenys	Lytis, amžius, etninė grupė, pilietybė, socioekonominis statusas (tėvų išsilavinimas ir užimamos pareigos, gyvenamoji vieta, šeimos dydis ir uždarbis)
Administraciniai duomenys	Mokymosi programų/dalykų (modulių) ar kursų duomenys	Semestro trukmė, studijų programos tipas, kursas
Administraciniai ir mokymosi proceso duomenys	Psichologinės charakteristikos	Laisvalaikio pomėgiai, elgesys studijų metu, streso, nerimo lygis, savireguliacija, motyvacija ir pan.

Mokymosi proceso duomenys	Virtualiojoje mokymosi aplinkoje (toliau VMA) renkami individualizuoti duomenys	Bendras aktyvumas	Kiek paspaudimų atlikta VMA, kiek laiko besimokantysis buvo aktyvus VMA, kada prisijungta prie VMA, kiek kartų prisijungta, koks prisijungimų dažnumas
		Peržiūros	Kiek paskaitų įrašų peržiūrėta, kiek kartų jungtasi į paskaitas, kiek VMA įkeltų dokumentų, failų ir kt. mokymosi medžiagos peržiūrėta
		Individualios užduotys	Kiek užduočių buvo atlikta ir pateikta, kiek laiko skirta užduotims, kiek kartų lankytasi užduoties skiltyje, koks įvertinimas gautas
		Grupinės užduotys	Kada prisijungta prie grupinių užduočių, kada prisijungta prie grupės, kiek laiko praleista grupinės užduoties skiltyje
		Testai	Kiek testų laikyta, kiek išlaikyta, kiek neišlaikyta, kiek laiko skirta testams atlikti, kiek taškų surinkta teste ir koks gautas įvertinimas
		Forumai	Kiek komentarų palikta forume, kiek laiko praleista forume
		Įvertinimas	Koks studijų dalyko įvertinimas

Taigi prognozuoti besimokančiųjų akademinę sėkmę nuotolinėse studijose galima bendraujant su besimokančiais, atliekant apklausas ir įvertinimus, taikant duomenų tyrybos technologiją. Akademinės sėkmės prognozavimui naudojami duomenys: ankstesnių mokymosi pasiekimų rezultatai, demografiniai duomenys, studijų dalykų (modulių), programų, kursų duomenys, psichologinės besimokančiųjų charakteristikos bei virtualiojoje mokymosi aplinkoje renkami besimokančiųjų aktyvumo duomenys.

2.3.1. Akademinės sėkmės prognozavimo procesas taikant duomenų tyrybą

Prognozuojant besimokančiųjų akademinę sėkmę taikant duomenų tyrybą rekomenduojama [46, 47, 48] remtis duomenų tyrybos modeliu – CRISP-DM (angl. Cross Industry Standard Process for Data Mining). Pagal CRISP-DM modelį duomenų tyrybos procesą sudaro šeši etapai [22]:

1. veiklos supratimas. Šiame etape svarbu suprasti duomenų tyrybos taikymo tikslą ir išsiaiškinti dalykinės srities reikalavimus. Čia parengiamas planas, kaip bus siekiama tikslo ir formuluojama problema – duomenų tyrybos uždavinys;

2. duomenų supratimas. Šiame etape sudaromos aktualių duomenų prielaidos, nustatomos galimos duomenų kokybės problemos ir surenkami pirminiai duomenys;

3. duomenų parengimas. Duomenų parengimo etape pirminiai duomenys ruošiami galutiniam duomenų rinkiniui. Čia atliekamas duomenų normalizavimas, kintamųjų transformacija, kategorizavimas, triukšmų šalinimas, diskretizavimas;

4. modeliavimas. Modeliavimo etape parenkami duomenų tyrybos metodai, algoritmai arba jų deriniai. Tam pačiam duomenų tyrybos uždaviniui spręsti galima parinkti kelis metodus, algoritmus;

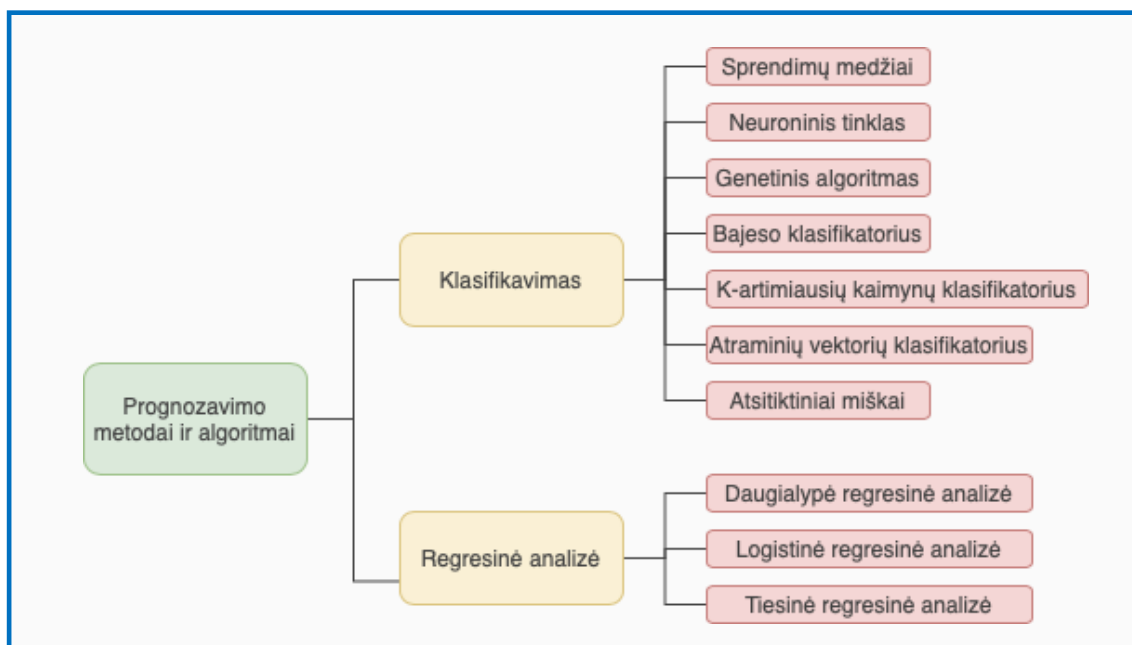
5. įvertinimas. Čia svarbu formaliai įvertinti parengto modelio kokybę, peržiūrėti modelio konstravimo žingsnius, įsitikinti, kad veiklos tikslai yra pasiekti tinkamai;

6. diegimas. Šiame etape panaudojami duomenų tyrybos rezultatai.

Duomenų tyryba yra ištisas problemų sprendimo procesas, kuris vyksta nuosekliai etapais. Nuoseklumas užtikrina tyrybos proceso kokybišką eigą, vientisumą ir sumažina klaidų tikimybę. Norint duomenų tyrybos procesą atlikti kokybiškai reikia tuos pačius veiksmus kartoti po keletą kartų.

Šis procesas reikalauja kruopštaus ir tikslingo pasiruošimo. Sėkmingai švietimo duomenų tyrybai svarbu kokybiškai paruošti duomenis ir parinkti tinkamus metodus [49].

Literatūroje [14, 50, 51] nurodoma, kad akademinėi sėkmei prognozuoti taikomi duomenų tyrybos metodai yra klasifikavimas ir regresinė analizė. Klasifikavimas naudojamas siekiant objektus priskirti iš anksto numatytoms klasėms, pavyzdžiui, studijų dalyko išlaikymas / neišlaikymas. Regresinė analizė, tai metodas, kuris aprašo priklausomojo (pasekmės) kintamojo vidutinių reikšmių priklausomybę nuo vieno ar kelių nepriklausomųjų (priežasties) kintamųjų reikšmių ir kartu prognozuoja šio kintamojo reikšmes, pavyzdžiui, remiantis duomenimis apie studento lytį, I, II, III semestrų rezultatais ir mokymosi programos tipu prognozuojami akademiniai rezultatai IV semestru [52]. Klasifikavimo ir regresinės analizės metodų realizacijai parenkami įvairūs algoritmai. Algoritmo parinkimas priklauso nuo duomenų tyrybos rinkinių sudarančių duomenų, todėl nėra vieno universalios akademinę sėkmę prognozuojančio algoritmo. Dažniausiai taikomų algoritmų apžvalga pavaizduota 2 paveiksle.



2 pav. Akademinės sėkmės prognozavimui taikomi duomenų tyrybos metodai ir algoritmai [sudaryta autoriaus, remiantis 14, 50]

Taigi prognozuojant besimokančiųjų akademinę sėkmę taikant duomenų tyrybą remiamasi modeliu CRISP-DM. Pagal šį modelį prognozavimas vyksta nuosekliai etapais: veiklos supratimas, duomenų supratimas, duomenų parengimas, modeliavimas, įvertinimas ir diegimas. Sėkmingai švietimo duomenų tyrybai svarbu parinkti tinkamus metodus. Prognozuojant besimokančiųjų akademinę sėkmę taikomi duomenų tyrybos metodai yra klasifikavimas ir regresinė analizė.

2.4. Akademinės sėkmės prognozavimo ir akademinio saviveiksmingumo sąsajos

Saviveiksmingumas yra vienas pagrindinių žmogaus elgesio veiksnių, kuris gali daryti įtaką pasiekimams tiesiogiai ir netiesiogiai per kitus žmogaus vidinius psichologinius aspektus, kaip pavyzdžiui, asmens suvokiamus tikslus, lūkesčius, kylančias reakcijas į rezultatus ir pan. [53]. Saviveiksmingumas apibūdina asmens įsitikinimą, kad jis geba mobilizuoti vidinę energiją kryptingai veiklai. Saviveiksmingumas taip pat išreiškia asmens aktyvumą, ryžtingumą siekti savo tikslų, įveikti

sunkumus ir kliūtis. Saviveiksmingumas yra dinamiškas elgesio veiksnys, kuris mokantis ir kaupiant patirtį gali keistis [54].

Egzistuoja skirtingų asmens saviveiksmingumo dimensijų, susijusių su konkrečiomis žmogaus gyvenimo sritimis. Vienas jų yra akademinis saviveiksmingumas. T. Honicke ir J. Broadbent [55] teigimu, vertinant asmens gebėjimus akademinėse srityse, matuojami ne tik objektyvūs akademiniai pasiekimai (įvertinti pažymiais), bet svarbus ir asmens subjektyvus savo galimybių vertinimas. Tokiu būdu įvertinami individo įsitikinimai apie savo gebėjimus sėkmingai atlikti akademinės užduoties pasirinktos specialybės kontekste. Taigi akademinis saviveiksmingumas, tai besimokančiojo tikėjimas savo gebėjimais atlikti akademinę užduotį [56]. Akademinis saviveiksmingumas yra susijęs su besimokančiųjų įgūdžiais studijose, pavyzdžiui, gebėjimu vengti trikdžių, pasitikėti dėstytojais, prašyti pagalbos ir bendradarbiauti su dėstytojais bei bendramoksliais, gebėjimu atlikti pristatymus bendraamžių grupėje, laikyti egzaminus ir pan. Nustatyta [55, 57, 58], kad akademinis saviveiksmingumas ir mokymosi pasiekimai akademinėje veikloje yra susiję.

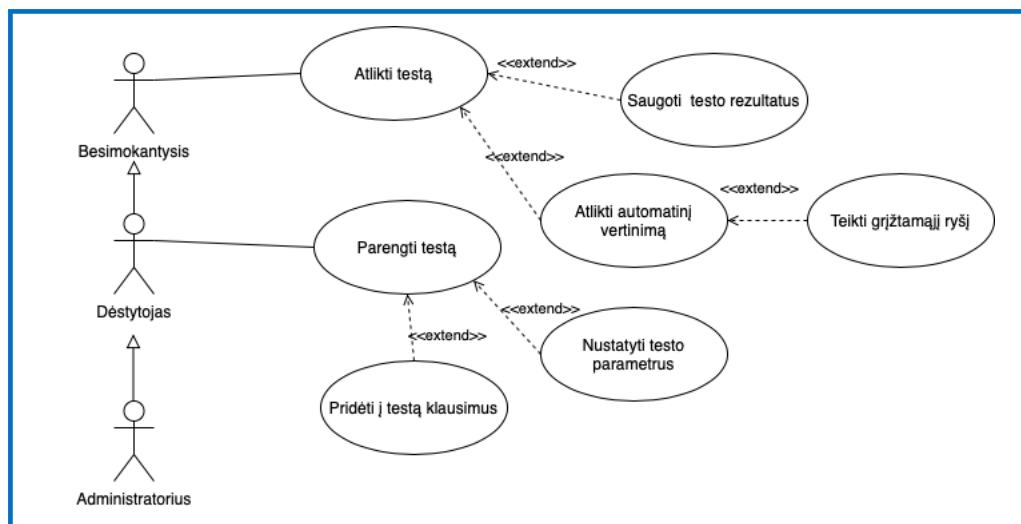
Aukštesnio saviveiksmingumo besimokantieji gauna geresnius įvertinimus už atliktas užduotis. Geri akademiniai pasiekimai yra susiję su didesniu pasitikėjimu savimi ir skatina besimokančiuosius prisimti didesnę atsakomybę, kad užduotis būtų sėkmingai atlikta. Besimokantieji, kurių akademiniai rezultatai yra žemesni, dažniausiai pasižymi žemesniu akademinio saviveiksmingumo lygiu, o tie, kurių aukštesni, labiau pasitikimi savimi ir labiau vertina mokymosi procesą [42, 43]. Pasiekimų ir nesėkmių patirtys siejasi su įvairiu akademinio saviveiksmingumo lygiu ir leidžia prognozuoti pažangių studentų pasiekimus. Akademinio saviveiksmingumo tyrimų apžvalga atskleidžia [55, 59], kad saviveiksmingumas yra vienas svarbiausių elementų, leidžiančių prognozuoti akademinis pasiekimus. Kai saviveiksmingumas yra įtraukiamas į psichologinius modelius, nagrinėjančius besimokančiųjų akademinis pasiekimus, kitų kintamųjų reikšmingumas akademiniam pasiekimams sumažėja. Tačiau svarbu pažymėti, kad bendrasis saviveiksmingumas yra mažiau susijęs su akademiniais pasiekimais, nei akademinis saviveiksmingumas [60].

Akademiniam saviveiksmingumui įvertinti naudojama „Studentų akademinio saviveiksmingumo skalė“ (angl. CASES – College Academic Self-Efficacy Scale) [61]. Skalė yra sudaryta iš 33 teiginių, kurie nurodo bendrą ir specifinį elgesį akademinėje aplinkoje. Teiginiai yra vertinami Likerto skalėje nuo 1 iki 5, kur 1 nurodo labai mažą pasitikėjimo lygį atlikti tam tikrą veiksmą, o 5 – didelį pasitikėjimo lygį. „Studentų akademinio saviveiksmingumo skalė“ pasižymi aukštu teiginių vidiniu suderinamumu – Cronbacho α svyruoja nuo 0,81 iki 0,91. Leidimą naudoti laisvai internete prieinama metodika yra patvirtinęs prof. Owen rašytiniame sutikime (žr. 4 priedą), o į lietuvių kalbą išversta metodika pasidalino vertimo autorė dr. J. Misiūnienė (žr. 4 priedą).

Edukacine prasme vertinimas yra studijų proceso sudedamoji dalis, todėl VMA yra numatyta galimybė vertinti besimokančiuosius ir pateikti įvertinimą, kaip pavyzdžiui, galima parengti testą su įvairiais klausimais (vienas pasirinkimas, keli pasirinkimai ir pan.), kurį atlikęs besimokantysis gali matyti galutinį įvertinimą. Nors VMA vertinimo posistemis apima veiklas, susijusias su besimokančiojo žinių ir gebėjimų patikrinimu bei įvertinimu, vis dėlto VMA vertinimo priemonės galima pritaikyti akademinio saviveiksmingumo įvertinimui. Atsižvelgiant į tai, sudaryti funkciniai ir nefunkciniai reikalavimai VMA vertinimo posistemiiui (žr. 4 lentelę) ir panaudojimo atvejų diagrama (žr. 3 paveikslą).

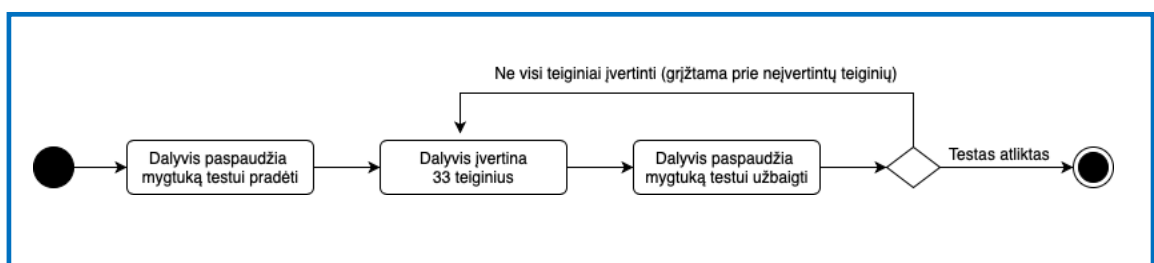
4 lentelė. Virtualiosios mokymosi aplinkos vertinimo posistemio reikalavimai

VMA VERTINIMO POSISTEMIS	
Funkciniai reikalavimai	Nefunkciniai reikalavimai
<ul style="list-style-type: none"> • Parengti testą • Nustatyti testo parametrus • Pridėti į testą klausimus • Valdyti testą • Atlikti testą • Atlikti automatinį įvertinimą • Teikti grįžtamąjį ryšį • Saugoti įvertinimo rezultatus 	<ul style="list-style-type: none"> • Prieinama visą parą • Lengvai ir nesudėtingai parengiama • Nesudėtingai atliekama • Prieinama Android ir iOS mobiliesiems įrenginiams • Prieinama visiems registruotiems sistemos dalyviams • Lietuvių kalbos palaikymas • Atitikimas „Studentų akademinio saviveiksmingumo skalė“ metodikos formai



3 pav. VMA vertinimo posistemio panaudojimo atvejų diagrama

Panaudojimo atvejai detalizuojami ir aprašomi lentelėse (žr. 5 priedą), sudaroma panaudojimo atvejo veiklos diagrama (žr. 4 paveikslą).



4 pav. Panaudojimo atvejo „Atlikti testą“ veiklos diagrama

Taigi akademinis saviveiksmingumas suprantamas, kaip besimokančiojo tikėjimas savo gebėjimais atlikti akademinę užduotį. Saviveiksmingumas yra susijęs su besimokančiųjų akademinė sėkme ir laikomas vienu iš svarbiausių psichologinių ypatumų, leidžiančių prognozuoti besimokančiojo

akademinis pasiekimus. Akademiniam saviveiksmingumui įvertinti naudojama „Studentų akademinio saviveiksmingumo skalė“, kurią galima parengti VMA vertinimo priemonėmis.

2.5. Akademinės sėkmės prognozavimas ir bendravimas virtualiojoje mokymosi aplinkoje

Įvairių mokslo krypčių teorijos pabrėžia, kad mokymosi procese svarbią ir reikšmingą vietą užima bendravimas. Tai prigimtinis žmogaus poreikis ir ypatinga žmonių tarpusavio sąveikos forma, atverianti galimybes pasidalyti informacija ir jausmais, pažinti vieniems kitus, patirti įvairias verbalinių ir neverbalinių ryšių prasmes [62].

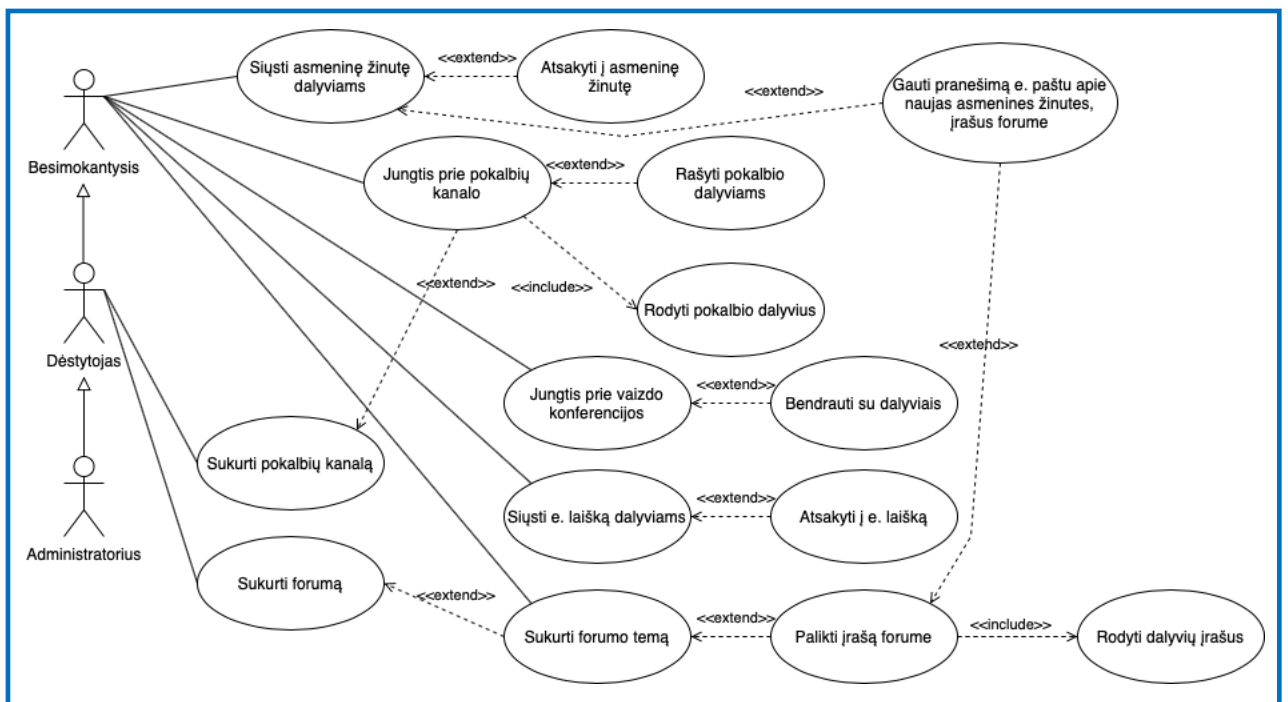
Nuotoliniame mokymesi skiriamas sinchroninis ir asinchroninis bendravimas. Sinchroninis bendravimas, tai procesas, apimantis dviejų ar daugiau dalyvių tarpusavio suvokimą, keitimąsi informacija ir sąveiką realiu laiku. Tačiau kai dalyvių tarpusavio interakcija vyksta ne tuo pačiu metu, toks bendravimas vadinamas asinchroniniu. Didžiąją savo studijų laiko dalį nuotolinių kursų besimokantieji praleidžia mokydamiesi savarankiškai ir su bendramoksliais, dėstytojais ar kurso kuratoriais bendraudami tik per atstumą. Nuotoliniame mokymesi bendravimas užtikrinamas taikant įvairias IKT priemones ir bendravimo būdus VMA:

- asmenines žinutes, kurios siunčiamos asmeniškai studijų dalyviams;
- pokalbių kanalus, kuriuose studijų dalyviai gali bendrauti realiu laiku, naudojant kokią nors ženklų sistemą;
- forumus, kuriuose keičiamasi nuomonėmis;
- e. paštas, kuriuo galima kurti, siųsti ir gauti žinutes per elektronines ryšio sistemas;
- vaizdo konferencijas, kuriuose dalyviai gali tarpusavyje bendrauti vaizdu ir balsu.

Nuotolinių kursų dėstytojui svarbu žinoti, kaip studentams sekasi ir su kokiais sunkumais jie susiduria. Šiuos ir panašius su besimokančiųjų akademinė sėkme susijusius klausimus dėstytojas gali kelti VMA skirtingais scenarijais, kaip pavyzdžiui, asmenine žinute ar e. paštu paklausti besimokančiojo apie jo sumažėjusio aktyvumo priežastis, vaizdo konferencijos metu teirautis besimokančiojo, kaip jam sekasi, sukurti forumo temą ar pokalbio kanalą, skirtą diskutuoti ir kalbėtis apie studijų sunkumus. Tokiu būdu surinkta informacija dėstytojui suteikia galimybę derinti mokymo strategijas, tenkinti studentų poreikius, atlikti reikšmingus sprendimus, lydinčius besimokančiuosius į akademinę sėkmę. Pažymėtina, kad besimokantysis VMA gali pats įspėti dėstytojus apie studijų nutraukimą, kaip pavyzdžiui, asmenine žinute ar e. paštu parašyti dėstytojui. Atsižvelgiant į dėstytojo ir besimokančiojo poreikį bendrauti, sudaryti funkciniai ir nefunkciniai VMA bendravimo posistemio reikalavimai (žr. 5 lentelę) ir panaudojimo atvejų diagrama (žr. 5 paveikslą).


5 lentelė. Virtualiosios mokymosi aplinkos bendravimo posistemio reikalavimai

VMA BENDRAVIMO POSISTEMIS	
Funkciniai reikalavimai	Nefunkciniai reikalavimai
<ul style="list-style-type: none"> • Siųsti asmeninę žinutę dalyviams • Palikti įrašą forume • Atsakyti į asmeninę žinutę, įrašą forume • Sukurti pokalbių kanalą • Prisijungti prie pokalbių kanalo ir bendrauti jame su dalyviais • Rodyti pokalbių kanalo dalyvius • Sukurti forumą • Sukurti temą forume • Palikti įrašą forume • Rodyti dalyvių įrašus forume • Siųsti e. laišką dalyviams • Gauti pranešimą e. paštu apie naujas asmenines žinutes, įrašus forume • Jungtis prie vaizdo konferencijos 	<ul style="list-style-type: none"> • Prieinama visą parą • Nemokama • Lengvai ir nesudėtingai naudojama • Prieinama Android ir iOS mobiliesiems įrenginiams • Prieinama visiems registruotiems sistemos dalyviams • Lietuvių kalbos palaikymas

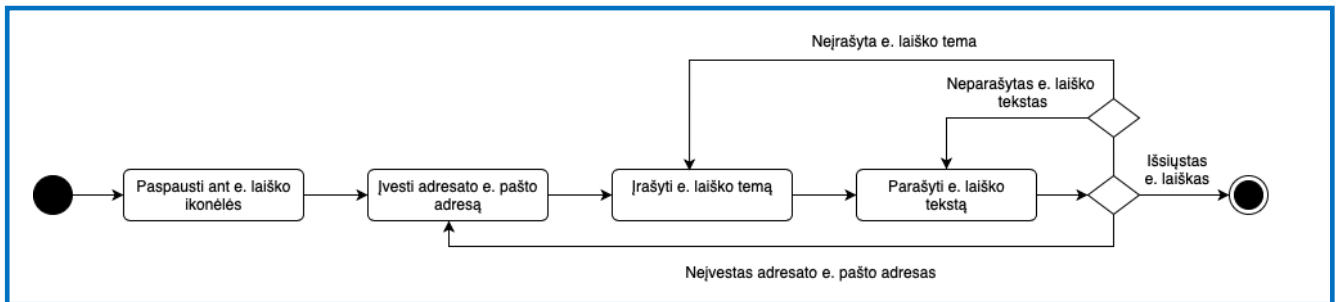


5 pav. VMA bendravimo posistemio panaudojimo atvejų diagrama

Panaudojimo atvejai detalizuojami ir aprašomi lentelėse (žr. 6 priedą). Sudaromos asmeninės žinutės siuntimo (žr. 6 paveikslą) ir e. laiško siuntimo panaudojimo atvejų veiklos diagramos (žr. 7 paveikslą).



6 pav. Panaudojimo atvejo „Asmeninės žinutės siuntimas“ veiklos diagrama





7 pav. Panaudojimo atvejo „E. laiško siuntimas“ veiklos diagrama

Taigi nuotoliniame mokymesi bendravimas užtikrinamas panaudojant įvairias IKT priemones ir bendravimo būdus VMA, kuriais su besimokančiųjų akademinė sėkme susijusi informacija gali būti perduota realiu arba užtęstu laiku.

2.6. Programinė įranga aktualiai virtualiajai mokymosi aplinkai įgyvendinti

Prognozuoti besimokančiųjų akademinę sėkmę nuotolinėse studijose galima bendraujant su besimokančiais, atliekant psichologinius įvertinimus ar taikant duomenų tyrybą. Bendravimo ar vertinimo veiklos nuotolinėse studijose organizuojamos ir įgyvendinamos VMA, kaip pavyzdžiui, Moodle arba Chamilo. Pastarosios VMA skiriasi viena nuo kitos savo grafinėmis vartotojų sąsajomis, realizuojamų veiklų pasirinkimo galimybėmis ir kitais aspektais. Tačiau Moodle ir Chamilo taip pat turi panašumų, kaip pavyzdžiui, Windows ir OS X operacinių sistemų palaikymas, atviras prieinamumas vartotojui ir pan. Vis dėlto renkantis tinkamiausią iš šių aplinkų atsižvelgiama į VMA funkcinės galimybes ir ypatybes realizuoti bendravimo ir vertinimo veiklas, kurių tikslas – besimokančiojo akademinės sėkmės prognozavimas. Plačiau Moodle ir Chamilo palyginimas apžvelgiamas 6 lentelėje.

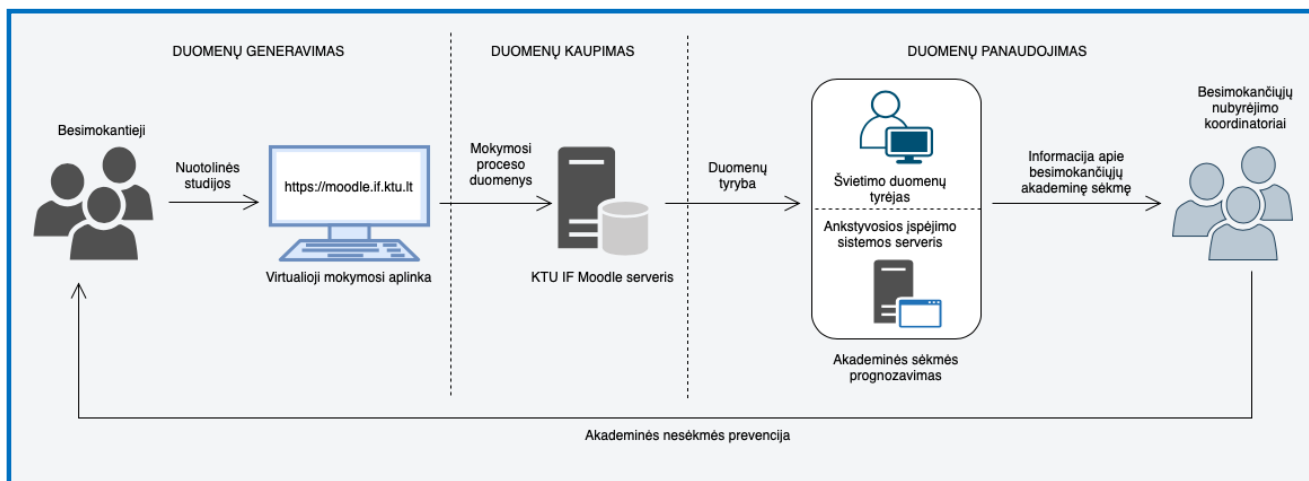
6 lentelė. Moodle ir Chamilo VMA palyginimas

					
Funkciniai reikalavimai ir jų realizavimas VMA	<i>Bendravimo posistemė</i>	Siųsti asmeninę žinutę dalyviams	✓	✓	
		Atsakyti į asmeninę žinutę	✓	✓	
		Sukurti forumą	✓	✓	
		Sukurti temą forume	✓	✓	
		Palikti įrašą forume	✓	✓	
		Atsakyti į įrašą forume	✓	✓	
		Rodyti dalyvių įrašus forume	✓	✓	
		Sukurti pokalbių kanalą	✓	✓	
		Prisijungti prie pokalbių kanalo ir bendrauti jame su dalyviais	✓	✓	
		Rodyti pokalbių kanalo dalyvius	✓	✓	
		Gauti pranešimą e. paštu apie naujas asmenines žinutes, įrašus forume	✓	✓	
		Jungtis prie vaizdo konferencijos	✓	✓	
		Atsakyti į įrašą forume	✓	✓	
		Rodyti dalyvių įrašus forume	✓	✓	
		Sukurti pokalbių kanalą	✓	✓	
	<i>Vertinimo posistemė</i>	Parengti testą	✓	✓	
		Nustatyti testo parametrus	✓	✓	
		Pridėti į testą klausimus	✓	✓	
		Valdyti testą	✓	✓	
		Atlikti testą	✓	✓	
		Atlikti automatinį įvertinimą	✓	✓	
		Teikti grįžtamąjį ryšį	✓	✓	
		Saugoti testo rezultatus	✓	✓	
	Nefunkciniai reikalavimai ir jų realizavimas VMA	<i>Bendravimo posistemė</i>	Prieinama visą parą	✓	✓
			Nemokama	✓	✓
			Lengvai ir nesudėtingai naudojama	✓	✓
			Prieinama Android ir iOS mobiliesiems įrenginiams	✗	✓
			Prieinama registruotiems sistemos dalyviams	✓	✓
Lietuvių kalbos palaikymas			✗	✓	
<i>Vertinimo posistemė</i>		Prieinama visą parą	✓	✓	
		Nemokama	✓	✓	
		Lengvai ir nesudėtingai naudojama	✓	✓	
		Prieinama Android ir iOS mobiliesiems įrenginiams	✗	✓	
		Prieinama registruotiems sistemos dalyviams	✓	✓	
		Lietuvių kalbos palaikymas	✗	✓	
		Atitikimas „Studentų akademinio saviveiksmingumo skalė“ metodikos formai	✓	✓	

Moodle ir Chamilo palyginimas atskleidžia, kad abiejuose VMA galima realizuoti bendravimo ir vertinimo posistemiams keliamus funkcinius reikalavimus. Akademinės sėkmės prognozavimui parengtos veiklos Moodle ir Chamilo aplinkose pateikiamos 7 priede. Lyginant nefunkcinių reikalavimų tenkinimą pažymėtina, kad Chamilo VMA neturi programinės įrangos, palaikančios iOS išmaniuosius telefonus. Be to, Chamilo VMA nėra užtikrintas lietuvių kalbos palaikymas. Aplinkos parametruose galima nurodyti lietuvių kalbą, tačiau grafinėje vartotojo sąsajoje dalis elementų lieka anglų kalba (žr. 8 priedą). Atsižvelgiant į nefunkcinių reikalavimų tenkinimą, Moodle VMA yra tinkamesnė negu Chamilo VMA realizuoti besimokančiųjų akademinės sėkmės prognozavimą.

3. Ankstyvosios įspėjimo sistemos projektavimas

KTU nuotolinėms studijoms realizuoti naudojama virtualioji mokymosi aplinka Moodle, kurios duomenų bazėje kaupiami įvairūs besimokančiųjų mokymosi proceso duomenys. Šiuos duomenis tikslinga analizuoti taikant duomenų tyrybos technologiją, nes duomenų tyryba įgalina optimaliai išnaudoti didžiuosius švietimo duomenis ir išgauti iš jų naudingos informacijos. Siekiant prognozuoti nuotolinių studijų besimokančiųjų akademinę sėkmę ir sumažinti besimokančiųjų nubyrežimą projektuojama ankstyvojo įspėjimo sistema, kuri paremta duomenų tyrybos technologija (žr. 8 paveikslą).



8 pav. KTU antrosios pakopos nuotolinių studijų ankstyvojo įspėjimo sistema

Taigi projektuojama sistema apima nuoseklią ir skaitmenizuotą studentų pažangos stebėseną, padedančią kuo anksčiau identifikuoti su studijų sunkumais susiduriančius studentus ir išpėti apie juos aukštąją mokyklą.

3.1. Duomenų paėmimas iš KTU IF Moodle duomenų bazės


Prieš pradėdant taikyti duomenų tyrybą sukaupitiems mokymosi proceso duomenims, juos reikia paimti iš duomenų bazės ir atitinkamai paruošti. Nuotolinių studijų „Nuotolinio mokymosi informacinės technologijos“ besimokančiųjų mokymosi proceso duomenys kaupiami ir saugomi KTU IF Moodle duomenų bazės lentelėse. Moodle turi daugiau nei 400 įvairių lentelių, kurios yra susietos reliaciniais ryšiais. Norint paimti duomenis iš Moodle duomenų bazės taikoma SQL užklausa kalba. Duomenų paėmimui parengiamos SQL užklausos, kuriomis paimami duomenys apie studentų prisijungimus prie studijų programos pagrindinių I semestro modulių „Virtualiojo mokymosi pagrindai“, „Tiriamasis projektas 1“ ir studentų atliktus paspaudimus šiuose moduluose. Naudotos SQL užklausos pateiktos 10 priede. SQL užklausos pirmiausia testuojamos asmeninėje Moodle duomenų bazėje, veikiančioje MySQL serveryje. Tikrinant užklausių teisingumą sulyginami duomenys gauti iš karto po jos įvykdymo.

Kaip buvo minėta 2.3.1. poskyryje, norint taikyti duomenų tyrybos metodus ištrauktiems duomenims, reikalingas duomenų parengimas. Šio etapo metu neapdoroti duomenys buvo filtruojami, pervadinami ir sujungiami. Duomenų parengimui naudoti programiniai kodai pateikti 11 priede. Duomenų parengimas užbaigiamas sudarant galutinį duomenų rinkinį (žr. 12 priedą), kuris naudojamas akademinės sėkmės prognozavimo modelio apmokymui. Duomenų rinkinio struktūra aprašyta 7 lentelėje.

7 lentelė. Akademinės sėkmės prognozavimo modelio apmokymui sudaryto duomenų rinkinio struktūra

KINTAMASIS	APRAŠYMAS
TP1_access_week	Studento prisijungimų prie modulio „Tiriamasis projektas 1“ skaičius
TP1_clicks_week	Studento paspaudimų skaičius modulyje „Tiriamasis projektas 1“
VMP_access_week	Studento prisijungimų prie modulio „Virtualiojo mokymosi pagrindai“ skaičius
VMP_clicks_week	Studento paspaudimų skaičius modulyje „Virtualiojo mokymosi pagrindai“
key	Raktas, studento identifikacijai pseudonimizuoti (125 studentai)
success	Klasės kintamasis, kurio reikšmė N žymi akademinę nesėkmę, o T rodo akademinę sėkmę

Dirbant su duomenimis svarbu užtikrinti studento duomenų apsaugą, jo privatumą ir konfidencialumą. Todėl KTU IF Moodle duomenų valdytojas visų pirma atlieka duomenų pseudonimizaciją (žr. 9 paveikslą) ir kiekvieno besimokančiojo duomenims sukuria raktą. Raktas apsaugo besimokančiojo identifikaciją rengiant akademinę sėkmę prognozuojantį modelį, o jį sukūrus ir įdiegus raktas įgalina studijų programos administraciją identifikuoti sunkumus patiriančius besimokančiuosius.






9 pav. Studento duomenų pseudonimizacija

Projektuojant ankstyvąją išpėjimo sistemą numatyti du duomenų paėmimo iš Moodle duomenų bazės scenarijai. Pirmuoju atveju švietimo duomenų tyrėjas pasirinktais laiko momentais ištraukia duomenis iš duomenų bazės ir perkelia juos duomenų tyrybai. Pasak Ortiz-Lozano et al. [63], pirmieji studijų metai ir ypač pirmosios 6-7 studijų savaitės laikomos reikšmingomis akademinės nesėkmės prevencijai. Antruoju atveju numatyta parengti duomenų tyrybos serverį, kuris automatiškai paimtų duomenis iš KTU IF Moodle duomenų bazės, atliktų studentų akademinės sėkmės prognozavimą ir informuotų apie tai studijų programos administraciją.

3.2. Akademinės sėkmės prognozavimui naudojamos duomenų tyrybos programinės sistemos parinkimas

Akademinės sėkmės prognozavimo uždavinio sprendimui galima taikyti įvairias duomenų tyrybos programines sistemas, kaip pavyzdžiui, Weka, Orange arba SPSS. Pastarosios programinės sistemos sukurtos panaudojant skirtingas programavimo kalbas, skiriasi viena nuo kitos grafinėmis vartotojų sąsajomis, papildymo galimybėmis ir pan. Tačiau Weka, Orange ir SPSS taip pat turi panašumų. Plačiau programinių sistemų palyginimas apžvelgiamas 8 lentelėje.

8 lentelė. Duomenų tyrybos programinių sistemų Weka, Orange ir SPSS palyginimas [sudaryta autoriaus, remiantis 64, 65, 66, 67]

EIL. NR.	PROGRAMINĖS SISTEMOS SAVYBĖS	 WEKA	 ORANGE	 SPSS
1.	Sukūrimo data	1993	1996	1968
2.	Programavimo kalba, kuria sukurta programinė sistema	Java	C++, Python	Java
3.	Dabartinė stabili versija	3.8	3.31.1	28.01
4.	Programos atnaujinimas	Palaikoma ir atnaujinama	Palaikoma ir atnaujinama	Palaikoma ir atnaujinama
5.	Komercinė/atviroji	Atviroji	Atviroji	Komercinė
6.	Diegimo poreikis/prieiga per naršyklę	Reikalingas diegimas	Reikalingas diegimas	Reikalingas diegimas
7.	Suderinamumas su OS	Windows, OS X, Linux	Windows, OS X, Linux	Windows, OS X, Linux
8.	Minimalūs reikalavimai įrangai	Java 8 arba naujesnė, ~ 1 GB laisvos atminties diske	~ 1,5 GB laisvos atminties diske	Jungiantis reikalingas interneto ryšys, ~ 4 GB laisvos atminties diske
9.	Naudojimo sudėtingumas	Paprasta naudotis, nereikalauja programavimo žinių	Paprasta naudotis, tačiau reikia mokėti programuoti norint prijungti papildomą funkcionalumą	Nesudėtinga naudotis
10.	Galimybė konfigūruoti ir išsaugoti darbo aplinką	Sudaryta galimybė	Sudaryta galimybė	Sudaryta galimybė
11.	Universalumas (galimybė tiems patiems duomenims taikyti kelis skirtingus duomenų tyrybos metodus)	Universali	Universali	Universali
12.	Galimybė prijungti papildomą funkcionalumą	Nėra galimybės	Yra galimybė	Yra galimybė
13.	Vizualizavimo galimybė	Galimybė vizualizuoti duomenis ir rezultatus 2D forma	Galimybė vizualizuoti duomenis ir rezultatus 2D forma	Galimybė vizualizuoti duomenis ir rezultatus 2D, 3D forma
14.	Galimybė spręsti duomenų tyrybos uždavinius	Sudaryta galimybė klasifikavimo, klasterizavimo, prognozavimo, susietumo taisyklių paieškos uždavinių sprendimui	Sudaryta galimybė klasifikavimo, klasterizavimo, prognozavimo, susietumo taisyklių paieškos uždavinių sprendimui	Sudaryta galimybė klasifikavimo, klasterizavimo, prognozavimo, susietumo taisyklių paieškos uždavinių sprendimui
15.	Galimybė parengti duomenis	Yra galimybė	Yra galimybė	Yra galimybė
16.	Darbo komandoje galimybė	Nėra galimybės bendrinti	Nėra galimybės bendrinti	Nėra galimybės bendrinti
17.	Palaikomi duomenų failo nuskaitymo formatai	.arff, .csv, .xls, .json, .xrff formatais	.csv, .xls, .xlsx, .pkl, .basket, .bsk, .tab formatais	.sav, .xls, .xlsx, .dbf, .dta, .csv formatais
18.	Darbo sekos sudarymo galimybė	Sudaryta galimybė	Sudaryta galimybė	Sudaryta galimybė

19.	Pakankamas mokymuisi skirtos dokumentacijos kiekis	Išsami dokumentacija oficialiame tinklalapyje, sukurtas naudotojo vadovas ir atviras kursas	Išsami dokumentacija oficialiame tinklalapyje, naudojimo instrukcija programinėje sistemoje ir YouTube platformoje	Neišsami dokumentacija, trūksta palaikymo sprendžiant švietimo duomenų tyrybos uždavinius
20.	Oficialus tinklapis	https://orangedatamining.com	https://waikato.github.io/weka-wiki/	https://www.ibm.com/products/spss-statistics

Renkantis duomenų tyrybos programinę sistemą besimokančiųjų akademinės sėkmės prognozavimui svarbu atsižvelgti į šias programinės sistemos savybes:

- *sistemas OS palaikymą*. Akademinės sėkmės prognozavimo modelis sudaromas OS X, o diegiamas KTU IF Moodle duomenų valdytojo kompiuteryje, kuris veikia Windows OS arba KTU IF Moodle serveryje su Linux. Dėl to duomenų tyrybos programinės sistemos suderinamumas su OS X, Linux ir Windows OS yra aktualus. Weka, Orange ir SPSS veikia minėtose OS;
- *sistemas prieinamumą naudotojui*. Akademinės sėkmės prognozavimo modelis sudaromas ir taikomas akademiniais tikslais. Dėl to baigiamąjį magistro projektą rengiančiajam svarbu, kad duomenų tyrybos programinė sistema yra atvirosios prieigos. SPSS yra komercinė programinė sistema, kuri nemokamai yra prieinama tik 30 dienų. Orange ir Weka yra nemokamos ir atvirai prieinamos duomenų tyrybos programinės sistemos;
- *sistemoje realizuojamų klasifikavimo algoritmų įvairovę*. Akademinės sėkmės prognozavimui taikomi įvairūs klasifikavimo algoritmai ir ieškomi tiksliausias prognozes pateikiantys algoritmai. Pažymėtina [64], kad Weka, lyginant su kt. duomenų tyrybos programinėmis sistemomis, pasižymi didesne klasifikavimo algoritmų įvairove. Programinių sistemų tyrimų rezultatai taip pat atskleidžia [65, 66], kad Weka realizuojami klasifikavimo algoritmai pateikia tikslesnes prognozes, lyginant su Orange;
- *duomenų parengimo galimybę*. Akademinės sėkmės prognozavimui būtinas pradinių duomenų parengimas. Weka, Orange ir SPSS sistemose yra sudaryta galimybė iš neapdorotų duomenų rinkinio išrinkti aktualius duomenis, o neaktualius duomenys pašalinti, surasti trūkstamų duomenų įrašus, juos užpildyti ir pan.;
- *prognozavimo modelio išsaugojimo galimybę*. Akademinės sėkmės prognozavimo modelis rengiamas ir diegiamas skirtingose OS, todėl galimybė išsaugoti parengtą modelį yra aktuali. Lyginamose duomenų tyrybos programinėse sistemose galima išsaugoti akademinės sėkmės prognozavimo modelį.

Taigi Weka, Orange ir SPSS yra duomenų tyrybos programinės sistemos, kuriomis paprasta naudotis sprendžiant klasifikavimo, prognozavimo, klasterizavimo, susietumo taisyklių paieškos uždavinius. Šios sistemos palaikomos OS X, Linux ir Windows OS, pasižymi duomenų parengimo ir prognozavimo modelio išsaugojimo galimybėmis. Weka ir Orange yra nemokamos ir atvirai prieinamos duomenų tyrybos programinės sistemos, o SPSS yra komercinės klasės programinė sistema. Sprendžiant prognozavimo uždavinius ieškoma tiksliausias prognozes pateikiančio algoritmo, todėl didesnis algoritmų pasirinkimas ir galimybė juos taikyti Weka programinėje sistemoje yra privalumas. Atsižvelgiant į programinių sistemų savybes, Weka yra tinkamesnė besimokančiųjų akademinės sėkmės prognozavimui negu Orange ar SPSS.

3.2.1. Programinės sistemos diegimo dokumentacija

Besimokančiųjų akademinės sėkmės prognozavimui parinkta duomenų tyrybos programinė sistema Weka 3.8, kuri yra atvirosios licencijos. Šią versiją skirtingoms operacinėms sistemoms galima

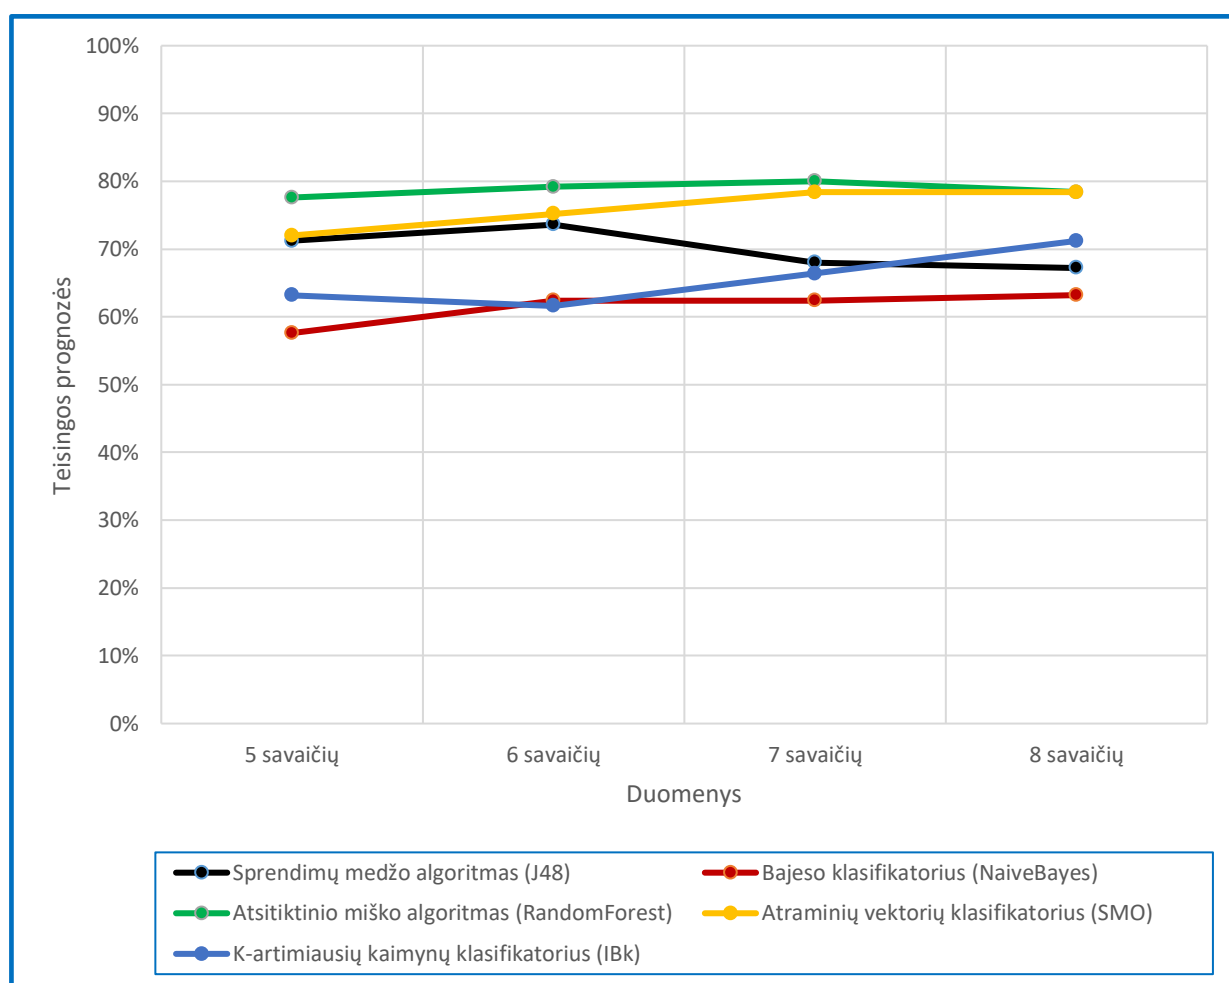
nemokamai parsisiūsti iš oficialaus Weka tinklalapio: https://waikato.github.io/weka-wiki/downloading_weka/.

Prieš Weka diegimą svarbu, kad kompiuteryje būtų įrašyta Java 8 arba naujesnė jos versija. Diegimo failas užima apie 200 MB, o įdiegta programinė sistema užima apie 500 MB, todėl prieš diegimą taip pat reikia pasirūpinti, kad kompiuterio diske būtų pakankamai laisvos vietos. Detalus Weka diegimas Windows 10 OS pateikiamas 13 priede.

3.3. Akademinės sėkmės prognozavimo modeliavimas

Projektuojama ankstyvojo išpėjimo sistema remiasi duomenų tyrybos modeliu CRISP-DM, kuri sudaro šeši etapai (pristatyti 2.3.1. poskyryje). Šiame poskyryje aprašomas modeliavimo ir įvertinimo etapas. Modeliavimas vykdomas Weka programinėje sistemoje (žr. 14 priedą), kurioje buvo parinkti sprendimo medžio algoritmas („J48“), Bajeso klasifikatorius („NaiveBayes“), atsitiktinio miško algoritmas („RandomForest“), atraminių vektorių klasifikatorius („SMO“) ir K-artimiausių kaimynų klasifikatorius („IBk“).

Prognozavimas atliekamas keliais etapais atsižvelgiant į rezultatų pokyčius: su 5 savaitių duomenimis, su 6 savaitių duomenimis, su 7 savaitių duomenimis ir su 8 savaitių duomenimis. Programinėje sistemoje įvykdžius prognozavimą visų pirma lyginami algoritmų teisingų prognozių rezultatai (žr. 10 paveikslą). Paveiksle matyti, kad atsitiktinio miško algoritmas pateikė daugiausiai



10 pav. Pirminiame akademinės sėkmės prognozavimo modelyje taikomų algoritmų rezultatai


teisingų prognozių visais taikomų duomenų atvejais, lyginant su kitais algoritmais. Atsitiktinio miško algoritmas aukščiausius rezultatus pasiekė naudojant 7 savaitių duomenis, t. y. prognozavo 80 procentų atvejų teisingai.

Toliau įvertinami algoritmų kokybės rezultatai ir tarpusavyje palyginami šie rodikliai: tikslumas, atkūrimas, F-įvertis ir ROC kreivės įvertis (žr. 9 lentelę).

9 lentelė. Pirminiame akademinės sėkmės prognozavimo modelyje taikomų algoritmų rodikliai

Algoritmas	Duomenys	Tikslumas	Atkūrimas	F-įvertis	ROC įvertis	Klasė
Sprendimų medis (J48)	5 savaitių	0,5	0,278	0,357	0,531	N
		0,752	0,888	0,814	0,531	T
	6 savaitių	0,556	0,417	0,476	0,676	N
		0,786	0,865	0,824	0,676	T
	7 savaitių	0,441	0,417	0,429	0,592	N
		0,769	0,787	0,778	0,592	T
	8 savaitių	0,429	0,417	0,423	0,598	N
		0,767	0,775	0,771	0,598	T
Bajeso klasifikatorius (NaiveBayes)	5 savaitių	0,361	0,611	0,454	0,646	N
		0,781	0,562	0,654	0,646	T
	6 savaitių	0,418	0,778	0,544	0,716	N
		0,862	0,562	0,68	0,716	T
	7 savaitių	0,41	0,694	0,515	0,737	N
		0,828	0,596	0,693	0,737	T
	8 savaitių	0,414	0,667	0,511	0,735	N
		0,821	0,618	0,705	0,733	T
Atsitiktinio miško (RandomForest)	5 savaitių	0,9	0,25	0,391	0,648	N
		0,765	0,989	0,863	0,648	T
	6 savaitių	0,857	0,333	0,48	0,734	N
		0,784	0,978	0,87	0,734	T
	7 savaitių	0,824	0,389	0,528	0,772	N
		0,796	0,966	0,873	0,772	T
	8 savaitių	0,765	0,361	0,491	0,716	N
		0,787	0,955	0,863	0,716	T
Atraminių vektorių klasifikatorius (SMO)	5 savaitių	0,556	0,139	0,222	0,547	N
		0,733	0,955	0,829	0,547	T
	6 savaitių	0,692	0,25	0,367	0,603	N
		0,759	0,955	0,846	0,603	T
	7 savaitių	0,737	0,389	0,509	0,666	N
		0,792	0,944	0,862	0,666	T
	8 savaitių	0,737	0,389	0,509	0,666	N
		0,792	0,944	0,862	0,666	T
K-artimiausių kaimynų klasifikatorius (IBk)	5 savaitių	0,381	0,444	0,41	0,561	N
		0,759	0,708	0,733	0,561	T
	6 savaitių	0,357	0,417	0,385	0,539	N
		0,747	0,697	0,721	0,539	T
	7 savaitių	0,425	0,472	0,447	0,613	N
		0,776	0,742	0,759	0,613	T
	8 savaitių	0,5	0,5	0,5	0,655	N
		0,798	0,798	0,798	0,655	T

Iš algoritmų kokybės rezultatų lentelės matyti, kad atsitiktinio miško ir atraminių vektorių klasifikatoriaus kokybės rodikliai išsiskiria labiausiai. Tarpusavyje palyginus šių algoritmų rodiklius (gautus su 7 savaitių duomenimis) galima sakyti, kad atsitiktinio miško algoritmas visgi buvo pranašesnis prognozuodamas akademinę sėkmę (priskirdamas reikšmę T) negu atraminių vektorių klasifikatoriaus. Atsižvelgiant į rezultatus sudaromas galutinis akademinės sėkmės prognozavimo modelis, kuriame taikomas atsitiktinio miško algoritmas (žr. 11 paveikslą).



11 pav. Studentų akademinės sėkmės prognozavimo modelis Weka programinėje sistemoje

Akademinės sėkmės prognozavimo modelį sudaro šie komponentai:

- „CSVLoader“ komponentas, kuris skirtas užkrauti duomenų rinkinį, kurio formatas CSV (.csv);
- „ClassAssigner“ komponentas, kuriame nurodomas klasės kintamojo indeksas (šiuo atveju kintamojo „success“, kurio indeksas yra „last“);
- „ClassValuePicker“ komponentas, kuris nurodo klasės kintamojo reikšmę (šiuo atveju reikšmę „N“, kuri yra „/first“);
- „CrossValidationFoldMaker“ komponente nurodoma, kiek kartų ir į kiek dalių skaidomas duomenų rinkinys. Tikslas – dalį duomenų skirti apmokymui ir dalį testavimui;
- „RandomForest“ komponentas rodo, kad modelyje taikomas atsitiktinio miško algoritmas;
- „ClassifierPerformanceEvaluator“ komponentas skirtas prognozavimo rezultatų suformavimui;
- „TextViewer“ komponentas skirtas peržiūrėti rezultatus teksto formatu.


Taigi projektuojamoje ankstyvojo išpėjimo sistemoje parengtas studentų akademinės sėkmės prognozavimo modelis, kuriame taikomas atsitiktinio miško algoritmas.

3.4. Akademinės sėkmės prognozavimo modelio naudojimo dokumentacija

Akademinės sėkmės prognozavimui naudojami apmokymo ir testavimo duomenų rinkiniai. Visų pirma šiuos duomenis reikia parengti Weka programinėje sistemoje (žr. 10 lentelę).

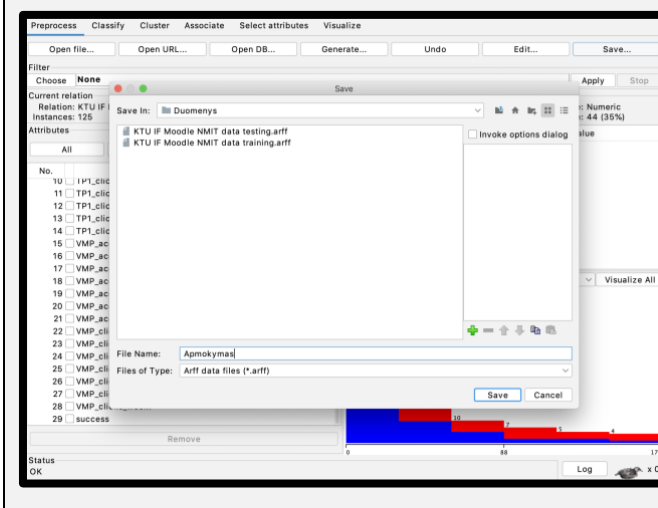
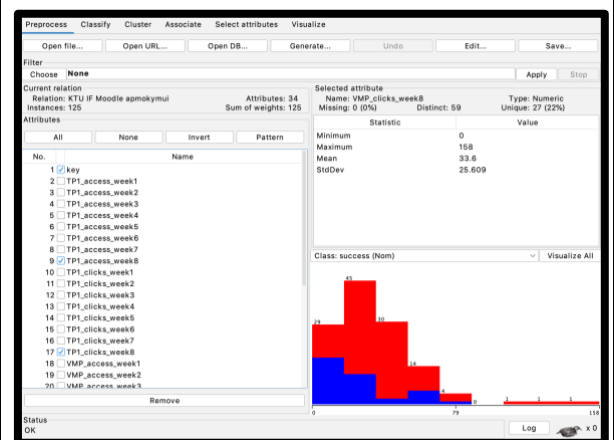
10 lentelė. Apmokymo ir testavimo duomenų rinkinio parengimas Weka programinėje sistemoje

<p>1. Paleisti Weka programinę sistemą ir pagrindiniame lange pasirinkti „Explorer“ aplinką.</p>	
--	--



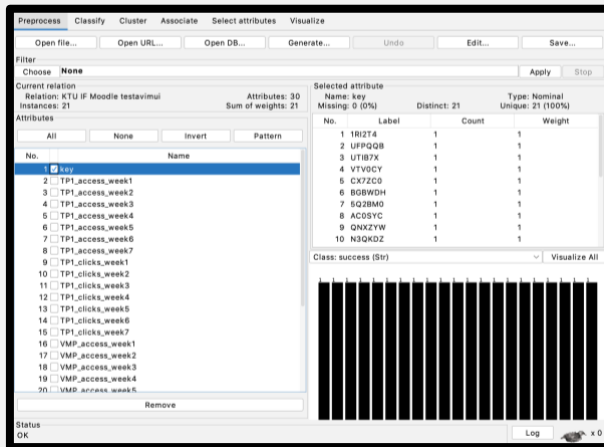

2. Pasirinkti „Open file...“, atsidariusiame lange surasti duomenis, kurie yra skirti prognozavimo modelio apmokymui ir spausti „Open“. Tokiu būdu duomenų rinkinys užkraunamas Weka programinėje sistemoje.

3. Užkrovus duomenis kintamųjų sąraše pasirinkti key, TP1_access_week8, TP1_clicks_week8, VMP_access_week8, VMP_clicks_week8 kintamuosius ir juos pašalinti. Pašalinimui spaudžiamas mygtukas „Remove“.



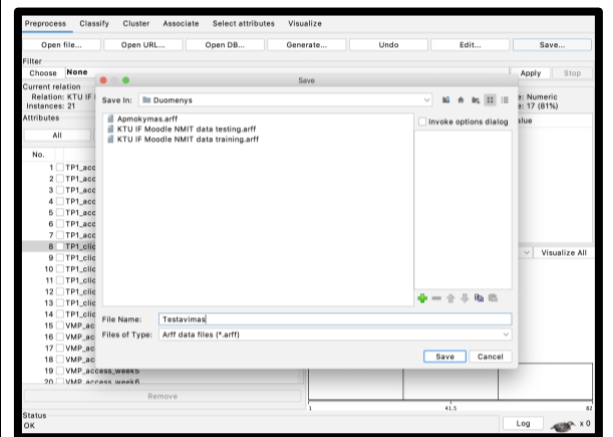
4. Po pašalinimo lieka 29 kintamieji, kuriuos reikia išsaugoti .arff formatu. Spausti „Save...“, atsidariusiame lange pavadinti failą ir spausti „Save“.

5. Toliau parengiami testavimui skirti duomenys. Pasirinkti „Open file...“, atsidariusiame lange surasti testavimo duomenis ir spausti „Open“.



6. Užkrovus duomenis kintamųjų sąrašė pasirinkti key ir spausti „Remove“. Po pašalinimo lieka 29 kintamieji.

7. Po kintamojo pašalinimo spausti „Save...“, atsidariusiame lange pavadinti failą ir spausti „Save“. Failo išsaugojimo formatas turi būti .arff



```

@relation 'KTU IF Moodle_testavimu-weka.filters.unsupervised.attribute.Remove-R1'
@attribute TP1_access_week1 numeric
@attribute TP1_access_week2 numeric
@attribute TP1_access_week3 numeric
@attribute TP1_access_week4 numeric
@attribute TP1_access_week5 numeric
@attribute TP1_access_week6 numeric
@attribute TP1_access_week7 numeric
@attribute TP1_clicks_week1 numeric
@attribute TP1_clicks_week2 numeric
@attribute TP1_clicks_week3 numeric
@attribute TP1_clicks_week4 numeric
@attribute TP1_clicks_week5 numeric
@attribute TP1_clicks_week6 numeric
@attribute TP1_clicks_week7 numeric
@attribute VMP_access_week1 numeric
@attribute VMP_access_week2 numeric
@attribute VMP_access_week3 numeric
@attribute VMP_access_week4 numeric
@attribute VMP_access_week5 numeric
@attribute VMP_access_week6 numeric
@attribute VMP_access_week7 numeric
@attribute VMP_clicks_week1 numeric
@attribute VMP_clicks_week2 numeric
@attribute VMP_clicks_week3 numeric
@attribute VMP_clicks_week4 numeric
@attribute VMP_clicks_week5 numeric
@attribute VMP_clicks_week6 numeric
@attribute VMP_clicks_week7 numeric
@attribute success {N,T}

@data
25,0,10,140,39,1,49,1,0,10,103,26,1,36,1,0,0,5,0,0,0,1,0,0,5,0,0,0,7
77,13,13,26,27,32,2,37,13,13,20,22,26,2,25,18,33,62,21,44,42,22,18,25,54,21,41,34,?
79,10,22,41,32,18,2,49,10,22,35,27,12,2,32,3,39,57,22,34,34,29,3,35,48,21,28,30,?
122,58,50,54,22,27,16,82,53,44,49,22,21,16,61,39,80,65,110,27,57,58,39,71,55,110,27,46,?
38,34,24,36,14,39,17,14,28,21,36,14,27,17,38,29,50,60,51,32,57,35,29,45,52,46,29,40,?
58,23,11,54,2,2,20,28,23,11,38,2,2,12,42,17,37,32,3,25,31,39,17,25,25,3,21,23,?
78,18,31,39,9,39,5,48,13,25,29,9,28,5,60,27,90,70,34,22,53,57,27,77,55,34,22,45,?
32,49,28,22,52,14,4,8,34,21,17,35,13,4,26,8,31,14,27,31,18,23,8,27,10,23,31,14,?
105,38,52,21,43,65,3,63,38,47,15,32,46,3,26,22,46,38,19,26,45,23,22,37,31,19,20,37,?
51,0,3,0,0,0,21,0,3,0,0,0,0,15,0,0,0,0,12,0,0,0,0,0,7
87,20,31,38,2,9,20,45,20,31,27,2,9,14,24,15,41,32,21,29,69,21,13,28,21,21,26,56,?
45,5,13,28,2,23,1,15,5,13,22,2,17,1,18,12,57,28,17,44,44,15,12,48,20,17,36,36,?
56,36,12,58,29,27,44,26,31,7,52,29,23,38,49,12,31,45,49,16,76,46,12,23,40,43,16,68,?
59,47,64,73,10,49,14,29,47,59,62,10,43,14,62,4,54,78,24,43,125,59,4,45,69,23,40,117,?
65,1,0,0,0,0,55,1,0,0,3,0,0,23,0,0,0,0,0,20,0,0,0,0,0,7
69,38,15,37,2,18,0,35,34,13,37,2,14,0,26,3,12,65,7,0,26,23,3,12,51,5,0,22,7
44,6,0,58,0,28,0,29,6,0,43,0,20,0,32,0,25,7,0,1,0,29,0,17,7,0,1,0,?
93,21,31,15,29,37,2,51,16,26,15,22,27,2,44,11,46,39,5,23,40,41,11,35,32,5,20,32,?
103,16,93,26,99,53,58,81,16,68,18,72,44,37,20,98,145,89,44,100,22,25,98,134,82,41,108,18,?
28,0,0,0,0,0,4,0,0,0,0,0,0,4,0,0,0,0,0,4,0,0,0,0,0,?
75,32,11,22,18,39,4,35,27,11,16,13,32,4,19,6,25,26,15,11,33,16,6,17,19,14,8,25,?


```

8. Teksto redaktoriui atidaryti testavimui skirtą duomenų rinkinį, kuris buvo išsaugotas 7-ame žingsnyje ir kintamųjų eilutę „@attribute success string“ pakeisti eilute „@attribute success {N,T}“. Išsaugoti pakeitimus.

Parengus duomenų rinkinius vykdomas akademinės sėkmės prognozavimas, kurio eiga aprašoma 11 lentelėje.

11 lentelė. Akademinės sėkmės prognozavimas Weka programinėje sistemoje


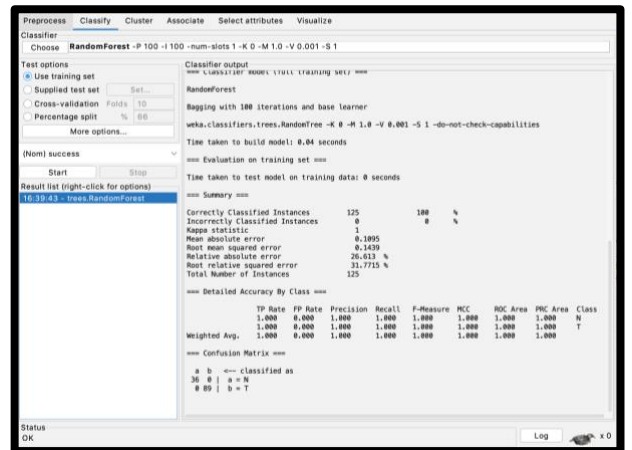
1. Paleisti Weka programinę sistemą ir pagrindiniame lange pasirinkti „Explorer“ aplinką.



2. Pasirinkti „Open file...“, atsidariusiame lange surasti duomenų failą .arff formatu, kuris yra skirtas prognozavimo modelio apmokymui ir spausiti „Open“. Tokiu būdu duomenų rinkinius užkraunamas Weka programinėje sistemoje.

- Užkrovus duomenis viršutinėje meniu juostoje pasirinkti „Classify“. Tokiu būdu pereinama į klasifikavimo metodo langą. Atsidariusiame lange spausti „Choose“ ir pasirinkti „trees>RandomForest“ algoritmą.

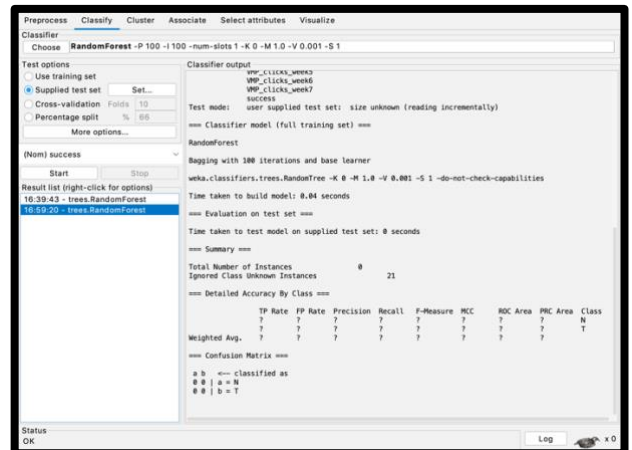
„Test options“ juostoje pasirinkti „Use training set“, nurodyti „(Nom) success“ ir spausti „Start“. Taip nurodoma, kad duomenų rinkinys naudojamas akademinės sėkmės prognozavimo apmokymui ir įvykdomas apmokymas.



- Po apmokymo „Test options“ juostoje pasirinkti „Supplied test set“ ir spausti „Set...“. Atsidariusiame lange pasirinkti testavimui skirtą duomenų failą ir spausti „Open“.

„Class“ eilutėje nurodyti „(Nom) success“ ir spausti „Close“.

- Įvykdyti prognozavimą su testavimo duomenų rinkiniu. Tai atliekama paspaudus „Start“.



3.5. Akademinės nesėkmės prevencija KTU

KTU Studijų departamento dokumente [68] nurodoma, kad kiekviename KTU fakultete veikia besimokančiųjų nubyrežimo koordinatoriai. Su besimokančiuoju, kuriam gresia studijų nutraukimas nubyrežimo koordinatorius susisiekiama, primena jam studijų tvarką, aiškinasi kilusių sunkumų priežastis ir pan. Nubyrežimo koordinatorius, bendradarbiaudamas su studijų prodekanu ir studijų programos vadovu gali priskirti besimokančiajam akademinį mentorių (dėstytoją). Akademinis mentorius padeda besimokančiajam išnaudoti studijų potencialą, padeda susidaryti individualųjį studijų planą, įvertina dalykinės pagalbos poreikį, rekomenduoja efektyvius problemų sprendimo būdus, padeda surasti atsakymus į rūpimus klausimus. Kitos taikomos akademinės nesėkmės prevencinės priemonės:

- teikiama socialinė-psichologinė pagalba;
- teikiama akademinė pagalba studijų metu per mentorystės programą;
- tutoriaus konsultacijos;
- besimokančiųjų įtraukimas į KTU bendruomenes;
- studijų pritaikymo galimybės pagal individualiuosius ugdymosi poreikius;
- finansinė parama;
- studijų modulių konsultacijos (konsultaciniai seminarai, individualios konsultacijos, laboratorinių darbų konsultacijos);
- organizuojamos neformaliojo švietimo veiklos: besimokantieji gali dalyvauti neformaliojo švietimo programose, trumpalaikiuose renginiuose, studijuoti pageidaujamus studijų modulius, turint klausytojo statusą.

Taigi siekiant, kad studentai sėkmingai studijuotų ir baigtų studijas projektuojamoje ankstyvojo išpėjimo sistemoje numatytos įvairios prevencinės priemonės: socialinės, psichologinės, finansinės ir akademinės.

4. Parengtos ankstyvojo išpėjimo sistemos tyrimas

KTU antrosios pakopos nuotolinių studijų „Nuotolinio mokymosi informacinės technologijos“ besimokančiųjų nubyreėjimo problemai spręsti buvo parengta ankstyvojo išpėjimo sistema. Siekiant išanalizuoti sistemos tinkamumą studijų programoje, atliktas tyrimas, kurį sudarė du etapai: SQL užklausų testavimas KTU IF Moodle duomenų bazėje ir akademinės sėkmės prognozavimo modelio testavimas.

4.1. SQL užklausų rezultatai

Duomenų paėmimui buvo parengtos SQL „SELECT“ tipo užklausos, kurių vykdymo metu išrenkami duomenys iš Moodle duomenų bazės. Šios užklausos parašytos asmeniniame duomenų bazės serveryje, o testuojamos KTU IF Moodle duomenų bazėje. Duomenų bazės serverių techniniai duomenys pateikiami 12 lentelėje.

12 lentelė. Duomenų bazės serverių techniniai duomenys

Asmeninis Moodle duomenų bazės serveris	KTU IF Moodle duomenų bazės serveris
macOS X	Debian Linux 10
Apache (2.2.23)	Apache (2.4.38)
PHP (7.4.2)	PHP (7.4.33)
MySQL (5.7.26)	MariaDB (10.4.28)

Užklausos testavimo pavyzdys parodytas 12 paveiksle. Testuojant SQL užklausas atsižvelgiama, ar KTU IF Moodle duomenų bazėje jos veikia be sintaksės klaidų ir gražina tikslūs duomenis. Testavimas atliekamas paimant duomenis apie 2021 m. ir 2022 m. įstojusių studentų prisijungimus prie studijų programos modulių „Virtualiojo mokymosi pagrindai“, „Tiriamasis projektas 1“ ir jų atliktus paspaudimus šiuose moduluose. Gauti rezultatai pateikiami 15 priede.

The screenshot shows the phpMyAdmin interface for the 'moodle' database. A SQL query is executed, and the results are displayed in a table. The query filters for course ID 566 and year 2021. The results table has the following data:

userid	firstname	lastname	week_number	access_count
			37	2
			40	1
			51	20
			37	162

12 pav. SQL užklausos testavimo pavyzdys paimant duomenis apie 2021 m. įstojusių studentų prisijungimus prie modulio „Tiriamasis projektas 1“

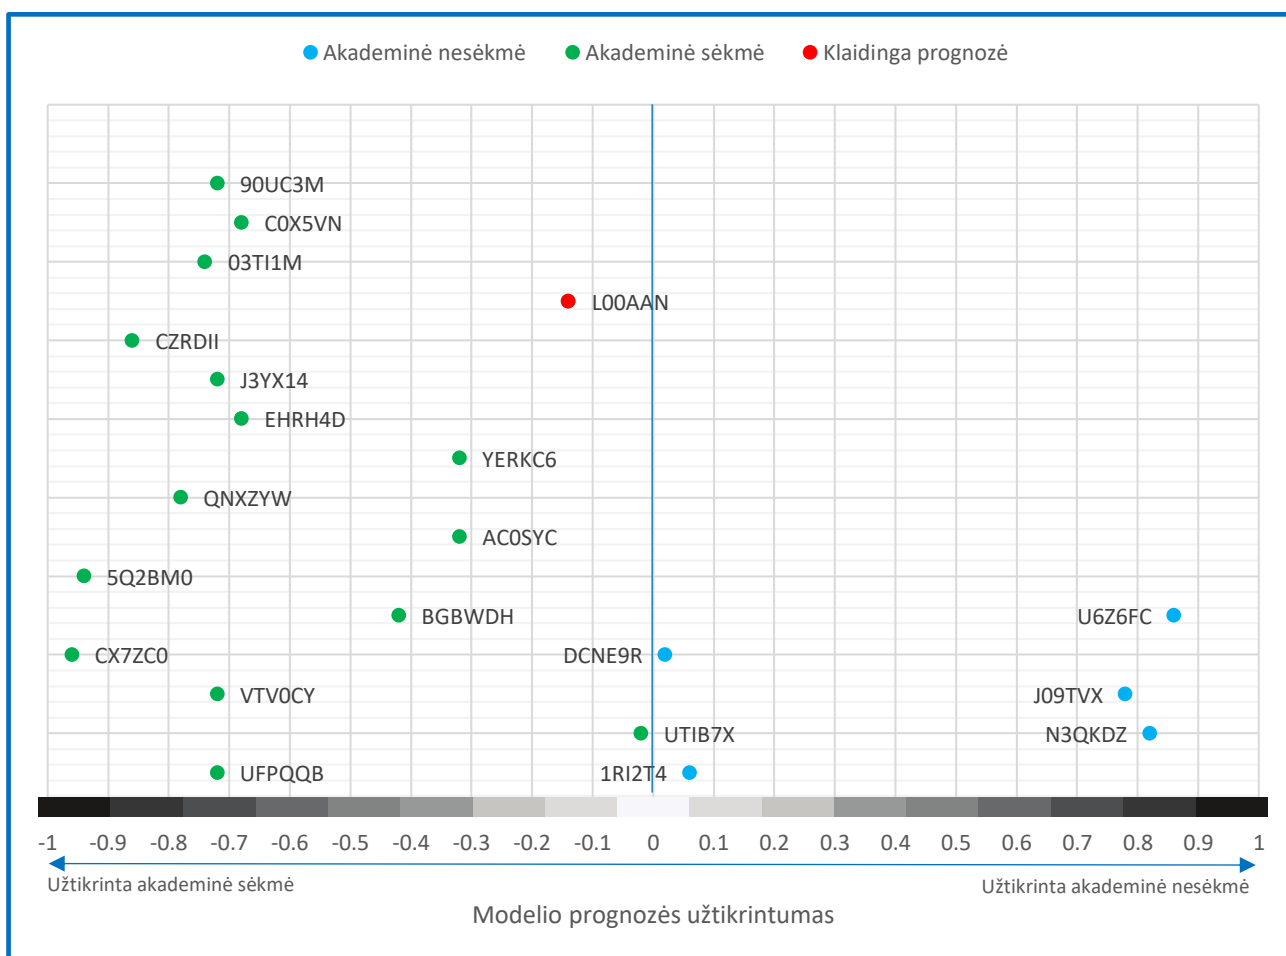
Iš testavimo rezultatų matyti, kad parašytos SQL užklausos tinkamai veikia KTU IF Moodle duomenų bazėje ir išrenka reikiamus duomenis. Taigi paimti duomenys toliau parengiami akademinės sėkmės prognozavimo modelio testavimui.

4.2. Akademinės sėkmės prognozavimo rezultatai

Akademinės sėkmės prognozavimo modelio testavimo tikslas – nustatyti, kuriems studentams gresia studijų nutraukimas. Testuojant akademinės sėkmės prognozavimo modelį panaudoti trys duomenų rinkiniai (žr. 12, 16 priedą):


1. modelio apmokymui parengtas duomenų rinkinys (aprašytas 3.1. skyriuje);
2. modelio testavimui parengtas duomenų rinkinys su 2021 m. įstojusiųjų duomenimis (21 studentas);
3. modelio testavimui parengtas duomenų rinkinys su 2022 m. įstojusiųjų duomenimis (74 studentai).

Visų pirma analizuojami rezultatai, gauti prognozuojant 2021 m. studentų akademinę sėkmę (žr. 13 paveikslą). Suprojektuotas modelis prognozuoja, kad 5-iems besimokantiesiems gresia studijų nebaigimas. Šiems studentams modelis priskyrė reikšmę N. Atsižvelgiant į užtikrintumo įverčius galima sakyti, kad modelio prognozė dėl 2-jų studentų akademinės nesėkmės yra neužtikrinta, nes gautas užtikrintumo rodiklis yra mažesnis už 0,1. Prognozė dėl dar 2-jų studentų akademinės sėkmės taip pat mažai tikėtina, nes užtikrintumo rodiklis yra mažesnis už -0,2.



13 pav. Akademinės sėkmės prognozės 2021 m. įstojusiems studentams

Toliau analizuojami 2022 m. studentų akademinės sėkmės prognozavimo rezultatai (žr. 14 paveikslą).



14 pav. Akademinės sėkmės prognozės 2022 m. įstojusiems studentams

Rezultatai atskleidžia, kad 10-čiai iš 74-ių studentų gresia studijų nutraukimas. Jiems priskirta reikšmė N. Šiuo atveju modelio užtikrintumas buvo silpnas priskiriant 1-ą studentą prie reikšmės N, o dar 1-no studento galimybes nutraukti arba tęsti studijas modelis įvertino vienodai (užtikrintumo įvertis lygus 0). Atsižvelgiant į modelio užtikrintumą priskiriant reikšmę T išskiriami 5 studentai, kurių užtikrintumo įverčiai buvo mažesni už -0,2.

Akademinės sėkmės prognozavimo rezultatais buvo pasidalinta su studijų programos administracija, kad patikrinti, kokia iš tikrųjų yra situacija su šiais besimokančiais. Atsižvelgiant į gautą informaciją apie besimokančiųjų mokymosi situaciją 2021 m. ir 2022 m. akademinės sėkmės prognozių lentelės buvo papildytos (žr. 17 priedą), o modelio padarytos klaidos vizualizuotos 13 ir 14 paveiksluose. Palyginus modelio pateiktas prognozes ir iš universiteto gautą informaciją galima sakyti, kad modelis daugelį atvejų teisingai priskyre N reikšmę, t. y. 11-ai iš 15-os studentų prognozavo, kad jie nutrauks studijas. Svarbu pažymėti, kad atvejais, kai modelis buvo neužtikrintas (5 atvejai) arba suklydo (3 atvejai) studentai pasižymėjo akademinės nesėkmės bruožais: akademinė skola, žemais akademiniais pasiekimais arba paskaitų nelankymu. Rezultatai taip pat parodė, kad 15 studentų, kuriems buvo prognozuojamas studijų tęsimas (priskirta reikšmė T), dėl įvairių asmeninių priežasčių nutraukė studijas arba išėjo akademinį atostogų. Todėl akademinės sėkmės prognozavimo modelį svarbu tobulinti, kad sumažinti klaidos tikimybę ir padidinti prognozavimo tikslumą.

Taigi gauti rezultatai atskleidė, kad panaudojant Moodle VMA kaupiamus studentų mokymosi proceso duomenis ir jų analizei taikant duomenų tyrybos technologiją galima numatyti, kuriems studentams gresia studijų nutraukimas.

4.3. Rekomendacijos sukurtos ankstyvojo išpėjimo sistemos tobulinimui

Rekomendacijos grindžiamos darbe atlikta literatūros apžvalga ir suprojektuotos ankstyvosios išpėjimo sistemos tyrimo rezultatais:

1. ankstyvąją išpėjimo sistemą papildyti besimokančiųjų akademinio saviveiksmingumo įvertinimu. Nuotolinių studijų „Nuotolinio mokymosi informacinės technologijos“ programos Moodle VMA parengti „Studentų akademinio saviveiksmingumo skalę“ (žr. 7 priedą) ir įvadinės studijų savaitės laikotarpiu atlikti besimokančiųjų įvertinimą;
2. akademinės sėkmės prognozavimo modelį papildyti naujais kintamaisiais ir duomenimis apie studentų prisijungimus prie studijų modulio „Nuotolinio mokymosi teorijos ir sistemos“, šiame modulyje atliktus paspaudimus. Papildžius naujais kintamaisiais ištestuoti modelio veikimą taikant klasifikavimo algoritmus;
3. modelio apmokymui sudarytą duomenų rinkinį kasmet papildyti naujais duomenimis apie studentus, kurie baigė / nutraukė studijas. Papildžius naujais duomenimis ištestuoti modelio veikimą taikant klasifikavimo algoritmus.

Išvados

1. Duomenų tyryba yra šiuolaikinė duomenų analizės technologija, kuri suteikia galimybę iš sukauptų didžiųjų švietimo duomenų nustatyti su studijų sunkumais susidursiančius besimokančiuosius. Akademinės sėkmės prognozavimui naudojami duomenys: ankstesnių mokymosi pasiekimų rezultatai, demografiniai duomenys, studijų modulių, programų, kursų duomenys, psichologinės besimokančiųjų charakteristikos ir virtualiojoje mokymosi aplinkoje renkami besimokančiųjų aktyvumo duomenys. Prognozuojant besimokančiųjų akademinę sėkmę taikant duomenų tyrybą remiamasi modeliu CRISP-DM. Pagal šį modelį prognozavimas vyksta nuosekliai etapais: veiklos supratimas, duomenų supratimas, duomenų parengimas, modeliavimas, įvertinimas ir diegimas. Sėkmingai švietimo duomenų tyrybai svarbu parinkti tinkamus metodus. Prognozuojant besimokančiųjų akademinę sėkmę taikomi duomenų tyrybos metodai yra klasifikavimas ir regresinė analizė.
2. KTU antrosios pakopos nuotolinėse studijose „Nuotolinio mokymosi informacinės technologijos“ besimokančiųjų akademinės nesėkmės prevencija yra neefektyvi, besimokančiųjų pažangos stebėseną yra nenuosekli, neišnaudojami kaupiami didieji švietimo duomenys, besimokantieji patiria akademinę nesėkmę ir studijas nutraukia. Tačiau KTU sudarytos palankios politikos sąlygos taikyti duomenų tyrybą ir jos pagalba prognozuoti besimokančiųjų akademinę sėkmę. Universitetas taip pat turi techninį pagrindą ir žmogiškųjų išteklių, sustiprinančių duomenų tyrybos realizaciją.
3. Sprendžiant prognozavimo uždavinius ieškoma tiksliausias prognozes pateikiančio algoritmo, todėl didesnis algoritmų pasirinkimas ir galimybė juos taikyti Weka programinėje sistemoje yra privalumas. Įvertinus duomenų tyrybos programinių sistemų savybes, Weka yra tinkamesnė besimokančiųjų akademinės sėkmės prognozavimui negu Orange ar SPSS. Weka parengtame akademinės sėkmės prognozavimo modelyje taikomas atsitiktinio miško algoritmas, kuris įvertinus algoritmų kokybės rezultatus buvo pranašesnis lyginant su kitais.
4. Atlikus akademinės sėkmės prognozavimo modelio tinkamumo studijų programoje tyrimą buvo nustatyta, kad akademinės sėkmės prognozavimo modeliu panaudojant studentų mokymosi proceso duomenis ir jų analizei taikant duomenų tyrybą, galima numatyti, kuriems studentams gresia studijų nutraukimas, tačiau modelį svarbu tobulinti, kad sumažinti klaidų tikimybę ir padidinti prognozavimo tikslumą. Atsižvelgiant į tyrimo rezultatus parengtos rekomendacijos ankstyvosios įspėjimo sistemos tobulinimui.

Literatūros sąrašas

1. CACHIA, Moira, Siobhan LYNAM, and Rosemary STOCK. Academic success: Is it just about the grades? *Higher education pedagogies*, 2018, 3(1), 434-439. Prieiga per: <https://www.tandfonline.com/doi/full/10.1080/23752696.2018.1462096>
2. BAWA, Papia. Retention in Online Courses: Exploring Issues and Solutions – A Literature Review. *SAGE Open*. 2016, 1-11. Prieiga per: <https://journals.sagepub.com/doi/pdf/10.1177/2158244015621777>
3. XAVIER, Marlon and Julio MENESES. Dropout in Online Higher Education: A scoping review from 2014 to 2018. *Barcelona: eLearn Center, Universitat Oberta De Catalunya*. 2020, 1-61. Prieiga per: <https://femrecerca.cat/meneses/publication/dropout-online-higher-education-scoping-review/dropout-online-higher-education-scoping-review.pdf>
4. KOWALSKI, Alcimar Roberto et al. Student Dropout in Distance Education in Higher Education: literature review in Portuguese. *EaD em Foco*. 2020, 10(2), 1-24. Prieiga per: https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKewiq7_rc4_fzAhVBzaQKHfUgDG0QFnoECAMQAQ&url=https%3A%2F%2Feademfoco.cecierj.edu.br%2Findex.php%2FRevista%2Farticle%2Fdownload%2F983%2F591%2F6065&usq=AOvVaw3HYTHZFYkglVKl0KvTn6x
5. SOSU, Edward and Pichyada PHEUNPHA. Trajectory of University Dropout: Investigating the Cumulative Effect of Academic Vulnerability and Proximity to Family Support. *Front. Educ.* 2019, 4(6), 1-10. Prieiga per: https://www.researchgate.net/publication/331040381_Trajectory_of_University_Dropout_Investigating_the_Cumulative_Effect_of_Academic_Vulnerability_and_Proximity_to_Family_Support
6. BEHR, Andreas et al. Dropping out of university: a literature review. *Review of Education*. 2020, 8(2), 614-652. Prieiga per: <https://bera-journals.onlinelibrary.wiley.com/doi/epdf/10.1002/rev3.3202>
7. NOREIKAITĖ, Birutė ir Kristijonas VAICEKAUSKAS. *Nuo abituriento suolo iki karjeros IRT profesijose*. 2020. Prieiga per: <https://www.investlithuania.com/wp-content/uploads/Nuo-abituriento-suolo-iki-karjeros-IRT-profesijose.pdf>
8. EUROPOS KOMISIJA. *Komisijos komunikatas Europos Parlamentui, Tarybai, Europos Ekonomikos ir socialinių reikalų komitetui ir regionų komitetui dėl skaitmeninio švietimo veiksmų plano*: 2018. [žiūrėta 2021-09-27] Prieiga per: <https://eur-lex.europa.eu/legal-content/LT/TXT/?uri=COM%3A2018%3A22%3AFIN>
9. KHASANAH, Annisa, Uswatun and HARWATI. A comparative study to predict student's performance using educational data mining techniques. *IOP Conf. Ser.: Mater. Sci. Eng.* 2017, 215, 1-17. Prieiga per: <https://iopscience.iop.org/article/10.1088/1757-899X/215/1/012036/pdf>
10. NAMOUN, Abdallah and Abdullah ALSHANQITI. Predicting student performance using data mining and learning analytics techniques: a systematic literature review. *Applied Sciences*, 2021, 11(1), 237, 1-28. Prieiga per: <https://www.mdpi.com/2076-3417/11/1/237>
11. BURGOS, Concepcion et al. Data mining for modeling students' performance: A tutoring action plan to prevent academic dropout. *Computers & Electrical Engineering*, 2018, 66, 541-556. Prieiga per: <https://www.sciencedirect.com/science/article/abs/pii/S0045790617305220?via%3Dihub>
12. SEIDEL, Ewa and Salah KUTIELEH. Using predictive analytics to target and improve first year student attrition. *Australian Journal of Education*, 2017, 61(2), 200-218. Prieiga per: <https://journals.sagepub.com/doi/abs/10.1177/0004944117712310>

13. ROTEM, Nir, Gad YAIR and Elad SHUSTAK. Dropping out of master's degrees: objective predictors and subjective reasons. *Higher education research & development*, 2021, 40(5), 1070-1084. Prieiga per: <https://www.tandfonline.com/doi/epub/10.1080/07294360.2020.1799951?needAccess=true>
14. ALYAHYAN, Eyman and Dilek DUSTEGOR. Predicting academic success in higher education: literature review and best practices. *International Journal of Educational Technology in Higher Education*, 2020, 17(3), 1-21. Prieiga per: https://www.researchgate.net/publication/338717237_Predicting_Academic_Success_in_Higher_Education_Literature_Review_and_Best_Practices
15. HELLAS, Arto et al. Predicting academic performance: a systematic literature review. *In Proceedings Companion of the 23rd Annual ACM Conference on Innovation and Technology in Computer Science Education*, 2018, 175-199. Prieiga per: https://helda.helsinki.fi/bitstream/handle/10138/315998/Predicting_Academic_Performance.pdf?sequence=1
16. KARABULUT, Bergen and Seyma CIHAN. Educational data mining application for increasing quality in engineering education. *The Online Journal of Quality in Higher Education*, 2018, 5(3), 7-12. Prieiga per: <http://tojkih.net/journals/tojkih/articles/v05i03/v05i03-02.pdf>
17. MAHDI, Alyaa. Educational Data Mining to Improve the Academic Performance in Higher Education. *Cihan University-Erbil Scietific Journal*, 2020, 4(2), 13-18. Prieiga per: <https://journals.cihanuniversity.edu.iq/index.php/cuesj/article/view/269/162>
18. ACHESON, Lingma Lu and Xia NING. Enhance E-Learning through Data Mining for Personalized Intervention. *Proceedings of the 10th International Conference on Computer Supported Education*, 2018, 461-465. Prieiga per: <https://www.scitepress.org/Papers/2018/67933/67933.pdf>
19. USMAN, Umar et al. Evaluating Ensemble Techniques for Predicting Students' Grades Based on their Interaction with Learning Management System. The Role of Computing in the Evolution and Development of Emergent and Alternative Technologies. *2nd International Conference of the IEEE Nigeria Computer Chapter: IEEEnigCmputConf'19*. 2019, 100-108. Prieiga per: https://www.google.lt/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKEwix_7Us5_zAhWk-ioKHetyBfQ4ZBAWegQIFBAB&url=http%3A%2F%2Frepository.futminna.edu.ng%3A8080%2Fjspui%2Fbitstream%2F123456789%2F12373%2F1%2F69%252670.pdf&usg=AOvVaw29jFv81P3tYxkLUCMSANQA
20. *Kauno Technologijos Universiteto 2021-2023 metų strateginis veiklos planas*. Prieiga per: <https://ktu.edu/wp-content/uploads/2021/02/Strateginis-veiklos-planas-2021-2023.pdf>
21. *KTU strategija 2021-2025*. Prieiga per: <https://ktu.edu/wp-content/uploads/2021/03/KTU-strategija-2021-2025.pdf>
22. NIAKŠU, Olegas. Duomenų tyryba medicinoje: taikymas, problemos ir galimybės. *Visuomenės sveikata*, 2014, 4(67), 9-19. Prieiga per: [https://www.hi.lt/uploads/pdf/visuomenes%20sveikata/2014.4\(67\)/VS%202014%204\(67\)%20LIT%20A%20Duomenu%20tyryba.pdf](https://www.hi.lt/uploads/pdf/visuomenes%20sveikata/2014.4(67)/VS%202014%204(67)%20LIT%20A%20Duomenu%20tyryba.pdf)
23. BAZILEVIČIUS, Gediminas. Mobiliosios duomenų tyrybos paslaugų analizė. *Informacijos mokslai*, 2013, 65, 96-102. Prieiga per: <https://www.journals.vu.lt/IM/article/view/2051/1279>

24. KAKLAUSKIENĖ, Danutė. Duomenų tyrybos programinių įrankių galimybių analizė. *Profesinės studijos: teorija ir praktika*, 2015, 15, 155-160. Prieiga per: <https://svako.lt/uploads/pstp-15-2015-21.pdf>
25. MANJARRES, Andres Villanueva, Luis Gabriel Moreno SANDOVAL and Martha Janneth Salinas SUAREZ. *Digital Education Review*, 2018, 33, 235-266. Prieiga per: https://www.researchgate.net/publication/327134062_Data_mining_techniques_applied_in_educational_environments_Literature_Review
26. SAVULIONIENE, Loreta ir Leonidas SAKALAUSKAS. Modifikuoto stochastinio dažnų poseikių paieškos algoritmo tikimybinės charakteristikos. *XVI kompiuterinių konferencijos mokslo darbai*, 2013, 75-87. Prieiga per: <https://www.zara.lt/e-knygos/e-KoDi-2013-MD.pdf>
27. ALGARNI, Abdulmohsen. Data mining in Education. *International Journal of Advanced Computer Science and Applications*, 2016, 7, 6, 456-461. Prieiga per: https://www.researchgate.net/publication/304808426_Data_Mining_in_Education
28. SRIVASTAVA, Jaya and Abhay Kumar SRIVASTAVA. Understanding Linkage between Data Mining and Statistics. *International Journal of Engineering Technology, Management and Applied Sciences*, 2015, 3, 10, 4-12. Prieiga per: <http://www.ijetmas.com/admin/resources/project/paper/f201510081444298793.pdf>
29. POLITAITĖ, Simona ir Jolanta SABAITYTĖ. Didžiųjų duomenų naudojimas klientui pažinti. *Mokslas – Lietuvos ateitis*, 2018, 10, 1-10. Prieiga per: <https://journals.vilniustech.lt/index.php/MLA/article/view/932/2892>
30. LIEPONIENĖ, Jurgita. E. Mokymosi kursų duomenų analizė, taikant duomenų gavybos metodus. *Aukštųjų mokyklų vaidmuo visuomenėje: iššūkiai, tendencijos ir perspektyvos*, 2014, 1, 3, 115-122. Prieiga per: https://alytauskolegija.lt/Dokumentai/2014/18_Lieponiene.pdf
31. ROMERO, Cristobal and Sebastian VENTURA. Educational data mining and learning analytics: an updated survey. *WIREs Data Mining and Knowledge Discovery*, 2020, 10, 1-21. Prieiga per: <https://bookdown.org/chen/la-manual/files/Romero%20and%20Ventura%20-%202020.pdf>
32. STUMBRIENĖ, Dovilė ir Audronė Jakaitienė. Švietimo duomenų tyryba: apžvalga ir tyrimų kryptys. *Lietuvos matematikos rinkinys*, 2015, 56, 41-45. Prieiga per: <https://www.zurnalai.vu.lt/LMR/article/view/17706/16874>
33. PENTEADO, Bruno Elias et al. Toward Better Outcomes in Audiology Distance Education: An Educational Data Mining Approach. *American Journal of Audiology*, 2018, 27, 513-525. Prieiga per: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7018450/>
34. TRAKUNPHUTTHIRAK, Ruangsak, Yen CHEUNG and Vincent C. S. LEE. A Study of Educational Data Mining: Evidence from a Thai University. *The Thirty-Third AAAI Conference on Artificial Intelligence*, 33, 1, 734-741. Prieiga per: <https://ojs.aaai.org/index.php/AAAI/article/view/3851>
35. .RAJALAXMI, R. et al. Regression Model for Predicting Engineering Students Academic Performance. *International Journal of Recent Technology and Engineering*, 2019, 7, 71-75. Prieiga per: https://www.researchgate.net/profile/N-Krishnamoorthy/publication/333102911_Regression_Model_for_Predicting_Engineering_Students_Academic_Performance/links/5cdb8ce2299bf14d959880ab/Regression-Model-for-Predicting-Engineering-Students-Academic-Performance.pdf

36. KRIŽANIČ, Snježana. Educational data mining using cluster analysis and decision tree technique: A case study. *International Journal of Engineering Business Management*, 2020. 12, 3, 1-9. Prieiga per: <https://journals.sagepub.com/doi/full/10.1177/1847979020908675>
37. CHEN Jianhui and Jing ZHAO. An Educational Data Mining Model for Supervision of Network Learning Process. *International Journal of Emerging Technologies in Learning*, 2018, 13(11), 67-77. Prieiga per: https://www.researchgate.net/publication/328845180_An_Educational_Data_Mining_Model_for_Supervision_of_Network_Learning_Process
38. DOKO, Edona et al. Sequential Pattern Mining Model to Identify the Most Important or Difficult Learning Topics via Mobile Technologies. *International Journal of Interactive Mobile Technologies*, 2018, 12(4), 109-122. Prieiga per: https://www.researchgate.net/publication/327320748_Sequential_Pattern_Mining_Model_to_Identify_the_Most_Important_or_Difficult_Learning_Topics_via_Mobile_Technologies
39. PAIVA, Ranilson et al. Visualizing Learning Analytics and Educational Data Mining Outputs. *Artificial Intelligence in Education*, 2018, 251-256. Prieiga per: https://www.researchgate.net/publication/327062241_Visualizing_Learning_Analytics_and_Educational_Data_Mining_Outputs
40. ALMASRI, Ammar, Rami S ALKHAWALDEH and Erbug CELEBI. Clustering-Based EMT Model for Predicting Student Performance. *Arabian Journal for Science and Engineering*, 2020. Prieiga per: <http://eacademic.ju.edu.jo/r.alkhawaldeh/Lists/Published%20Research/DispForm.aspx?ID=11&ContentTypeId=0x01040001D9C92763AEF84CAEB5B80458B898DA>
41. ARULKADACHAM, Lilani et al. General and unique predictors of student success in online courses: A systematic review and focus group. *Journal of University Teaching & Learning Practice*, 2021, 18, 8, 4. Prieiga per: <https://ro.uow.edu.au/cgi/viewcontent.cgi?article=2674&context=jutlp>
42. YOKOYAMA, Satoru. Academic Self-Efficacy and Academic Performance in Online Learning: A Mini Review. *Front. Psychol.*, 2019, 9, 1-4. Prieiga per: <https://www.frontiersin.org/articles/10.3389/fpsyg.2018.02794/full>
43. DOMENECH-BETORET, Fernando, Laura ABELLAN-ROSELLO and Amparo GOMEZ-ARTIGA. Self-Efficacy, Satisfaction, and Academic Achievement: The Mediator Role of Students' Expectancy-Value Beliefs. *Front. Psychol.*, 2017, 8, 1-12. Prieiga per: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5513915/pdf/fpsyg-08-01193.pdf>
44. QUINN, Rory Joseph and Geraldine GRAY. Prediction of student academic performance using Moodle data from a Further Education setting. *Irish Journal of Technology Enhanced Learning*, 2020, 5(1), 1-19. Prieiga per: <https://journal.ilta.ie/index.php/telji/article/view/57/87>
45. NATIONAL ACADEMY OF EDUCATION. *Big Data in Education: Balancing the Benefits of Educational Research and Student Privacy: Workshop Summary*. Washington, DC: National Academy of Education, 2017. Prieiga per: <https://files.eric.ed.gov/fulltext/ED574440.pdf>
46. YILDIZ, Muhammed and Caner BOREKCI. Predicting Academic Achievement with Machine Learning Algorithms. *Journal of Educational Technology & Online Learning*, 2020, 3(3), 372-392. Prieiga per: <https://dergipark.org.tr/en/download/article-file/1214052>
47. PHAUK, Sökkhey and Takeo OKAZAKI. Integration of Educational Data Mining Models to a Web-Based Support System for Predicting High School Student Performance. *World Academy of Science*,

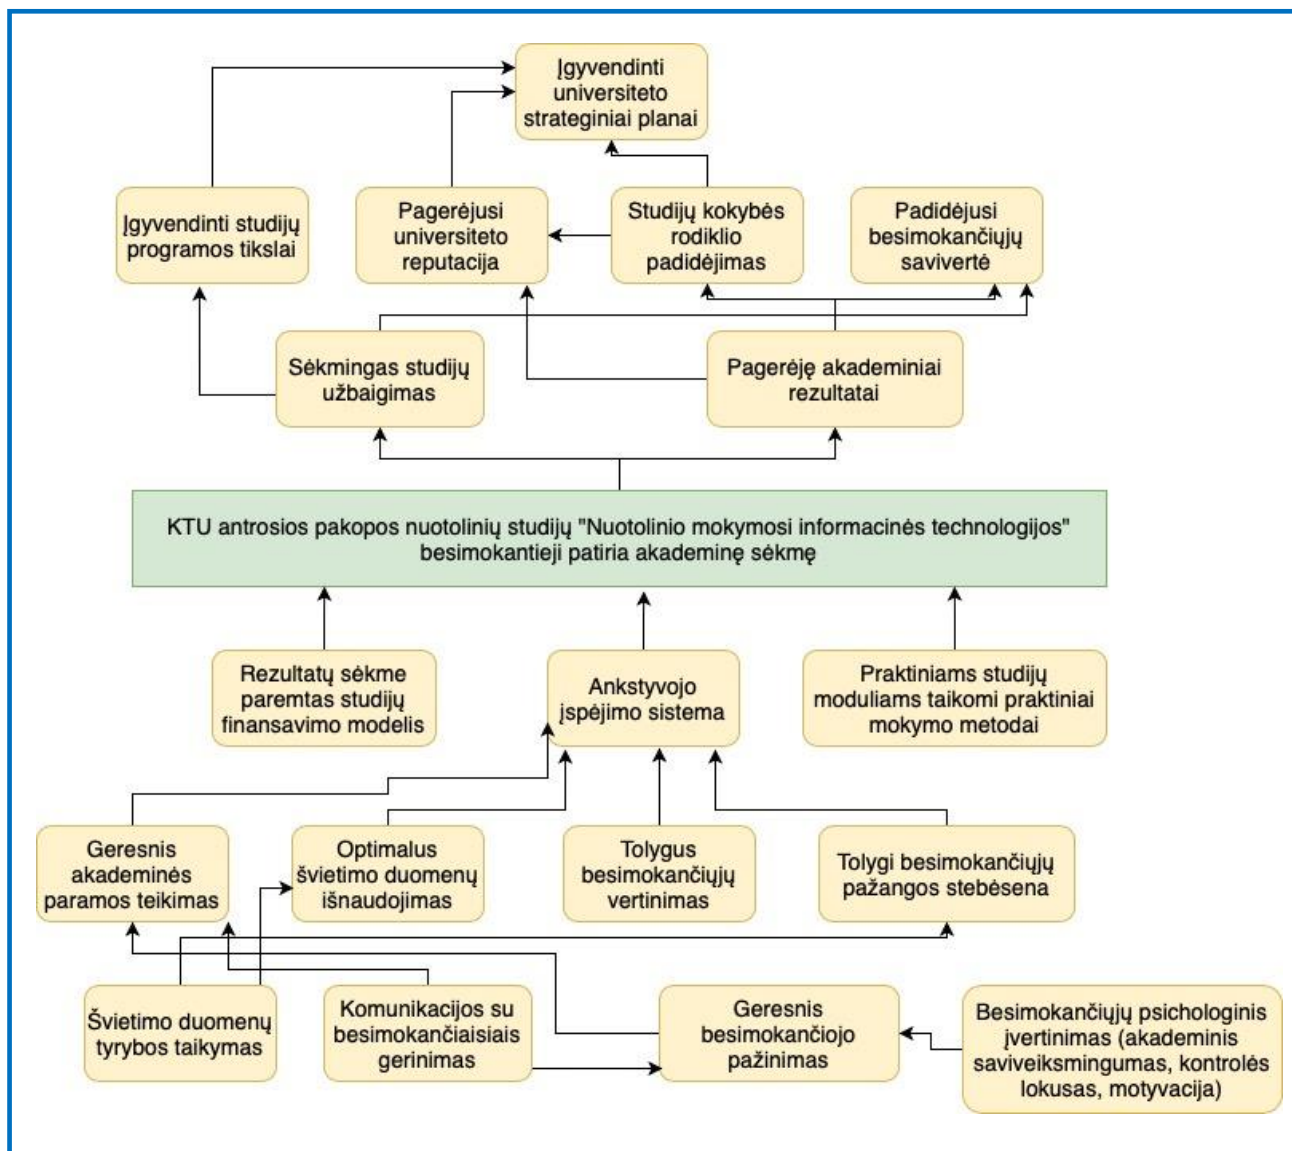
- Engineering and Technology International Journal of Computer and Information Engineering*, 2021, 15(2), 131-144. Prieiga per: https://www.researchgate.net/publication/349226410_Integration_of_Educational_Data_Mining_Models_to_a_Web-Based_Support_System_for_Predicting_High_School_Student_Performance
48. KARABULUT, Bergen and Seyma CIHAN. Educational data mining application for increasing quality in engineering education. *The Online Journal of Quality in Higher Education*, 2018, 5(3), 7-12. Prieiga per: <http://tojqih.net/journals/tojqih/articles/v05i03/v05i03-02.pdf>
 49. GUDAS, Saulius ir Audrius LOPATA. *Žiniomis grindžiama sistemų inžinerija*. Mokomoji knyga, 2011. Prieiga per: http://www.esparama.lt/documents/10157/490675/Ziniomis_grindziama_sistemu_inzinerija.pdf/03ad468b-aa2f-4d0f-a79b-56302fcebe4b
 50. MACARINI, Luiz Antonio Buschetto et al. Predicting students success in blended learning – evaluating different interactions inside learning management systems. *Applied Sciences*, 2019, 9(24), 1-23. Prieiga per: <https://www.mdpi.com/2076-3417/9/24/5523/htm>
 51. FIGUEROA-CANAS, Josep and Teresa SANCHO-VINUESA. Early Prediction of Dropout and Final Exam Performance in an Online Statistics Course. *IEEE Revista Iberoamericana De Tecnologias Del Aprendizaje*, 2020, 15, 2, 86-94. Prieiga per: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9064814>
 52. AMIRHHAJLOU, Leila et al. Application of data mining techniques for predicting residents' performance on pre-board examinations: A case study. *Journal of Education and Health Promotion*, 2019, 1-7. Prieiga per: https://www.jehp.net/temp/JEduHealthPromot81108-5909332_162453.pdf
 53. BANDURA, Albert. Self-Efficacy. *Encyclopedia of human behavior*, 1994, 4, 71-81. Prieiga per: <https://www.uky.edu/~eushe2/Bandura/Bandura1994EHB.pdf>
 54. ŽUKAUSKAITĖ, Irena, Dalia BAGDŽIŪNIENĖ ir Rita Rekašiūtė BALSINĖ. Darbuotojų profesinio saviveiksmingumo, struktūrinio įgalinimo ir įsitraukimo į darbą sąsajos. *Psichologija*, 2019, 59, 37-52. Prieiga per: <https://www.journals.vu.lt/psichologija/article/view/13346/12283>
 55. HONICKE, Toni and Jaclyn BROADBENT. The influence of academic self-efficacy on academic performance: A systematic review. *Educational Research Review*, 2016, 17, 63-84. Prieiga per: <https://reader.elsevier.com/reader/sd/pii/S1747938X15000639?token=D974E13B547430B88D844AE4D160AD0D7BBD610DC0271DBB3A72CDFDA582BED3B0E7EE4C35B3AB095B07A4E6CD9835DF&originRegion=eu-west-1&originCreation=20211125140323>
 56. KONCEVIČIENĖ, Jolanta. Atidėliojimas, saviveiksmingumas ir laiko valdymas akademinėje veikloje. *Psichologija*, 2016, 54, 87-97. Prieiga per: <https://etalpykla.lituanistikadb.lt/fedora/objects/LT-LDB-0001:J.04~2016~1493991554064/datastreams/DS.002.0.01.ARTIC/content>
 57. SHILENKOVA, Luidmila. Self-efficacy in the educational process (review of foreign studies). *Journal of Modern Foreign Psychology*, 2020, 9(3), 69-78. Prieiga per: https://psyjournals.ru/files/116346/jmfp_2019_n3_Shilenkova.pdf
 58. TALSMA, Kate et al. I believe, therefore I achieve (and vice versa): A meta-analytic cross-lagged panel analysis of self-efficacy and academic performance. *Learning and Individual Differences*, 2018, 61, 136-150. Prieiga per: <https://www.sciencedirect.com/science/article/abs/pii/S104160801730211X>

59. NASIR, Maliha and Sarwat IQBAL. Academic Self Efficacy as a Predictor of Academic Achievement of Students in Pre-Service Teacher Training Programs. *Bulletin of Education and Research*, 2019, 41(1), 33-42. Prieiga per: <https://files.eric.ed.gov/fulltext/EJ1217900.pdf>
60. FELDMAN, David and Maximilian KUBOTA. Hope, self-efficacy, optimism, and academic achievement: Distinguishing constructs and levels of specificity in predicting college grade-point average. *Learning and Individual Differences*, 2015, 37, 210-216. Prieiga per: <https://www.sciencedirect.com/science/article/abs/pii/S1041608014002349?via%3Dihub>
61. OWEN, Steven V. and Robin D. FROMAN. *Development of a College Academic Self-Efficacy Scale*, 1988. Prieiga per: https://www.researchgate.net/publication/234580139_Development_of_a_College_Academic_Self-Efficacy_Scale
62. KRAUJUTAITYTĖ, Linutė ir Justinas Sigitas PLEČKAITIS. *Nuotolinių studijų organizavimas: strategijos ir technologijos*. Monografija, 2003. Prieiga per: https://repository.mruni.eu/bitstream/handle/007/15445/Kraujut_peck.pdf?sequence=1
63. ORTIZ-LOZANO, Jose Maria et al. University student retention: Best time and data to identify undergraduate students at risk of dropout. *Innovations in Education and Teaching International*, 2020, 57, 1, 74-85. Prieiga per: https://www.researchgate.net/publication/326946991_University_student_retention_Best_time_and_data_to_identify_undergraduate_students_at_risk_of_dropout
64. RATRA, Ritu and Preeti GULIA. Experimental Evaluation of Open Source Data Mining Tools (WEKA and Orange). *International Journal of Engineering Trends and Technology*, 2020, 68(8), 30-35. Prieiga per: https://www.researchgate.net/publication/345203774_Experimental_Evaluation_of_Open_Source_Data_Mining_Tools_WEKA_and_Orange
65. RATRA, Ritu, Preeti GULIA and Nasib Singh GILL. Performance Analysis of Classification Techniques in Data Mining using WEKA. *Proceedings of the International Conference on Innovative Computing & Communication (ICICC)*, 2021. Prieiga per: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3879610#references-widget
66. WAHBEH, Abdullah et al. A Comparison Study between Data Mining Tools over some Classification Methods. *International Journal of Advanced Computer Science and Applications, Special Issue on Artificial Intelligence*, 2011, 18-26. Prieiga per: <https://thesai.org/Downloads/SpecialIssueNo3/Paper%204-A%20Comparison%20Study%20between%20Data%20Mining%20Tools%20over%20some%20Classification%20Methods.pdf>
67. *IBM SPSS Statistics*. Prieiga per: <https://www.ibm.com/products/spss-statistics>
68. *Kauno technologijos universiteto ankstyvojo išpėjimo sistema*, 2022. Prieiga per KTU intranetą: <https://ktuedu.sharepoint.com/Informacija%20Studentams/Dokumentai/Ankstyvojo%20spjimo%20sistema/Forms/AllItems.aspx?id=%2FInformacija%20Studentams%2FDokumentai%2FAnkstyvojo%20spjimo%20sistema%2FAnkstyvojo%20ispėjimo%20sistema%2Epdf&parent=%2FInformacija%20Studentams%2FDokumentai%2FAnkstyvojo%20spjimo%20sistema>
69. PUNDZAITĖ, Ugnė. *Studentų akademinio saviveiksmingumo sąsaja su akademiniais pasiekimais (psichologijos bakalauro darbas)*. Mokslinis vadovas dr. J. Misiūnienė. Kaunas: Vytauto Didžiojo universitetas, 2019. – 43 p. [Rankraštis]. Saugomas Psichologijos katedroje.

70. BANERES, David et al. An early warning system to detect at-risk students in online higher education. *Applied Sciences*, 2020, 10, 4427, 1-28. Prieiga per: <https://www.mdpi.com/2076-3417/10/13/4427>
71. AKCAPINAR, Gokhan, Arif ALTUN and Petek ASKAR. Using learning analytics to develop early-warning system for at-risk students. *International Journal of Educational Technology in Higher Education*, 2019, 16, 40, 1-20. Prieiga per: <https://educationaltechnologyjournal.springeropen.com/track/pdf/10.1186/s41239-019-0172-z.pdf>
72. *Asmens duomenys besikeičiančiame pasaulyje: praktinis straipsnių rinkinys*. Prieiga per: https://uploads-ssl.webflow.com/620293c6dcb4af6b7f572917/62c6f17f37ccc6823cd1ab75_Asmens%20duomenys%20besikeičiame%20pasaulyje_praktinis%20straipsnių%20rinkinys.pdf
73. KONDRATAVIČIENĖ, Renata. Virtualios mokymosi aplinkos naudojimas pradiniam ugdyme besikeičiančios edukacinės paradigmos kontekste. *Aukštųjų mokyklų vaidmuo visuomenėje: iššūkiai, tendencijos ir perspektyvos*, 2016, 1, 5, 113-119. Prieiga per: <https://alytauskolegija.lt/wp-content/uploads/2014/09/2016-konferencijos-leidinys-G.pdf>

Priedai

1 priedas. Tikslų medis



15 pav. KTU antrosios pakopos nuotolinių studijų tikslų medis

Besimokančiųjų akademinės sėkmės nuotolinėse studijose prognozavimo tyrimas

Gerbiamasis (-oji),

Kreipiuosi į Jus su prašymu dalyvauti tyrime apie akademinės sėkmės nuotolinėse studijose prognozavimą. Tyrimo vykdytoju esu aš - KTU "Nuotolinio mokymosi informacinės technologijos" studijų programos magistrantas Artūras Kukštys.

Tyrimas yra anoniminis ir truks apie 5 min.

Su tyrimo rezultatais supažindinsiu Jus sesijos metu.

Iškilius klausimams/neaiškumams, susisiekite e-paštu: a.kukstys@gmail.com

*Privaloma

Demografiniai duomenys

1. 1. Jūsų lytis: *

Pažymėkite tik vieną ovalą.

Vyras

Moteris

2. 2. Jūsų gyvenamoji vieta: *

Pažymėkite tik vieną ovalą.

Miestas

Kaimas

3. 3. Jūsų šeiminei padėtis: *

Pažymėkite tik vieną ovalą.

- Vedęs/Ištekėjusi
- Nevedęs/netekėjusi
- Išsiskyręs/išsiskyrusi
- Našlys/našlė
- Gyvenu partnerystėje
- Kita

4. 4. Jūsų užimtumas (pasirinkite Jums tinkamus atsakymų variantus): *

Pažymėkite viską, kas tinka.

- Studijuoju
- Dirbu pilnu etatu
- Dirbu nepilnu etatu
- Nedirbu

Kita: _____

5. 5. Jūsų amžius: *

Pažymėkite tik vieną ovalą.

- 18 m. - 25 m.
- 26 m. - 35 m.
- 36 m. - 45 m.
- 46 m. - 55 m.
- 56 m. - 65 m.
- 66 m. ir daugiau

Mokymosi pasiekimų duomenys

6. Jūsų pirmosios pakopos (bakalauro) studijų pažymių vidurkis: *

Pažymėkite tik vieną ovalą.

- iki 5
- nuo 5 iki 5.9
- nuo 6 iki 6.9
- nuo 7 iki 7.9
- nuo 8 iki 8.9
- nuo 9 iki 10

7. Jūsų bakalauro baigiamojo darbo įvertinimas: *

Pažymėkite tik vieną ovalą.

- 5
- 6
- 7
- 8
- 9
- 10

8. Jūsų rudens semestro pažymių vidurkis (praėjus 1/2 semestro): *

Pažymėkite tik vieną ovalą.

- iki 5
- nuo 5 iki 5.9
- nuo 6 iki 6.9
- nuo 7 iki 7.9
- nuo 8 iki 8.9
- nuo 9 iki 10
- Sunku atsakyti, nes dar negavau nė vieno įvertinimo
- Sunku atsakyti, nes nežinau savo įvertinimų
- Nežinau, nes nebestudijuojau

Saviveiksmingumo
įvertinimas

Žemiau pateikiami teiginiai apie Jūsų tikėjimą savo kompetencija atlikti tam tikras užduotis ir pasiekti užsibrėžtus tikslus. Pažymėkite, kiek Jūs sutinkate su teiginiais. Kiekvienam teiginiui pasirinkite vieną iš keturių vertinimo variantų: "Visiškai nesutinku", "Nesutinku", "Sutinku", "Visiškai sutinku". Įvertinkite visus teiginius.

9. Teiginiai *

Kiekvienoje eilutėje pažymėkite tik vieną ovalą.

	Visiškai nesutinku	Nesutinku	Sutinku	Visiškai sutinku
Visada galiu įveikti sunkias problemas, jei tik pakankamai pasistengiu.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Jei kas nors man nepitaria, aš galiu rasti būdus ir priemones, kaip gauti tai, ko noriu.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Man lengva siekti užsibrėžto tikslo ir įgyvendinti numatytus uždavinius.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Esu tikras (-a), kad galėčiau tinkamai veikti netikėtais atvejais.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Savo sumanumo (išradingumo) dėka aš žinau, kaip elgtis netikėtose situacijose.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Aš galiu įveikti daugumą problemų, jei tam skirčiau pakankamai jėgų ir laiko.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Susidūręs (-usi) su sunkumais galiu išlikti ramus(-i), nes pasitikiu savo sugebėjimu įveikti sunkumus.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Iškilius problemai, paprastai galiu rasti keletą jos sprendimo būdų.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Patekęs (-usi) į bėdą, paprastai randu išeitį.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Paprastai aš galiu susitvarkyti su viskuo, kas man nutinka.	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Kad pateikti atsakymus, paspauskite "Pateikti"

Dėkoju už Jūsų atsakymus

Šio turinio „Google“ nekūrė ir nepatvirtino.

3 priedas. Ištrauka iš pokalbio su KTU studijų departamento direktore Kristina Ukvalbergiene



Kristina Ukvalbergiene <kristina.ukvalbergiene@ktu.lt>

Sun 10/10/2021 7:29 PM

To: Kukštys Artūras

Laba diena,

Taip, universitete veikia ankstyvojo įspėjimo sistema, kurioje stebimi tam tikri studentų mokymosi rezultatai ir lankomumas. Deja, sistemos demonstravimą riboja asmens duomenų apsaugos klausimai, nes sistemoje matomi studentų duomenys, taip pat yra ribotas sistemos pasiekiamumas, nes studentai negali turėti prieigos. Jeigu būtų įdomu – galėtume pademonstruoti sistemą „gyvo“ susitikime metu.



4 priedas. Leidimai naudotis „Studentų akademinio saviveiksmingumo skalė“ metodika [61, 69]

11 October 2015

Dear Researcher,

Thank you for your inquiry about the College Academic Self-Efficacy Scale (CASES). You are welcome to use CASES. I've included a copy of the scale below. Here are a few summary points about the scale.

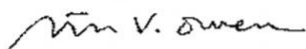
Items are scored as A (“quite a lot”) = 5...E (“very little”) = 1. On the other hand, because we read from left to right, data entry is faster letting A = 1, and E = 5. If you enter data with A = 1, then let the computer recode the values so that A becomes 5, B becomes 4, etc. In calculating an overall CASES score, we prefer calculating a mean rather than a sum.

You may wish to modify questionnaire instructions to best fit your application. For example, if you need informed consent, you might say something like “Filling out this questionnaire is completely voluntary and confidential. There are no penalties for not participating, and you may quit at any time.”

The next page shows the CASES items. Following that is a conversation about scoring CASES, plus some normative data.

Best wishes in your research.

Sincerely,



Steven V. Owen, Professor (retired)
Department of Epidemiology & Biostatistics
University of Texas Health Science Center at San Antonio
7703 Floyd Curl Dr., MC 7802
San Antonio, TX 78229-3900

Internet: svo@vbbn.com

OR steven.owen@uconn.edu

dėl akademinio saviveiksmingumo klausimyno

📎 2 📄



Kukštys Artūras

Labas vakaras, Esu KTU II pakopos studijų „Nuotolinio mokymosi informacinės technologijos“ studentas. Šiuo metu rengiu baigiamąjį magi...

Thu 5/12/2022 10:48 PM



Translate message to: English | Never translate from: Lithuanian



Jurga Misiūnienė <jurga.misiuniene@vdu.lt> [in](#)

👍 ↶ ↷ 📧 ...

To: Kukštys Artūras

Mon 5/16/2022 8:03 PM



2 attachments (220 KB) ☁ Save all to OneDrive - Kaunas University of Technology 📄 Download all

Labas vakaras,

Siunčiu jums failą su Ugnės Pundzaitės darbe naudota skale ir kitą failą, kurį gavome iš autoriaus kartu su sutikimu skalę versti ir modifikuoti.

Būtų įdomu sužinoti, kaip jums seksis ir ar skalę naudosite darbe, tad būčiau dėkinga už pasidalinimą.

--

Pagarbiai / Regards,

dr. Jurga Misiūnienė

Lektorė, Mokyklinės psichologijos programos komiteto vadovė / Lecturer, Head of the School Psychology Programme Committee

Psichologijos katedra / Department of Psychology
Socialinių mokslų fakultetas / Faculty of Social Sciences
Vytauto Didžiojo universitetas / Vytautas Magnus University
Jonavos g. 66-329, Kaunas LT-44191 / Jonavos st. 66-329, Kaunas LT-44191
Lietuva / Lithuania

5 priedas. VMA vertinimo posistemio panaudojimo atvejų specifikacija

Panaudojimo atvejis	Nr. 1	Parengti testą
Tikslas		Parengti testą pagal „Studentų akademinio saviveiksmingumo skalė“ metodiką.
Dalyviai		Dėstytojas, administratorius.
Ryšiai su kitais panaudojimo atvejais		Nustatyti testo parametrus. Pridėti į testą klausimus.
Nefunkciniai reikalavimai		Prieinama visą parą, prieinama mobiliesiems įrenginiams, parengiama nesudėtingai, prieinama visiems registruotiems sistemos dalyviams.
Prieš-sąlygos		Dalyvis turi pasirinkti testo kūrimo veiklą.
Sužadinimo sąlyga		Dalyvis paspaudžia testo kūrimo mygtuką.
Po-sąlyga		Parengiamas testas, kuriuo galima įvertinti studentų akademinį saviveiksmingumą.
Pagrindinis scenarijus		Dalyvis pasirenka testo kūrimo veiklą. Paspaudžiamas testo kūrimo mygtukas. Testas kuriamas teiginių forma pagal „Studentų akademinio saviveiksmingumo skalė“ metodiką. Teiginių iš viso 33. Kiekvienam teiginiui vertinti parengiama skalė nuo 1 iki 5.
Alternatyvūs scenarijai		Gaunamas pasiūlymas į testą įtraukti klausimus iš klausimų banko.

Panaudojimo atvejis	Nr. 2	Atlikti testą
Tikslas		Atlikti testą, kuris yra parengtas pagal „Studentų akademinio saviveiksmingumo skalė“ metodiką.
Dalyviai		Besimokantysis, dėstytojas, administratorius.
Ryšiai su kitais panaudojimo atvejais		Saugoti testo rezultatus. Atlikti automatinį vertinimą. Teikti grįžtamąjį ryšį.
Nefunkciniai reikalavimai		Prieinama visą parą, prieinama mobiliesiems įrenginiams, atliekama nesudėtingai, prieinama visiems registruotiems sistemos dalyviams.
Prieš-sąlygos		Dalyvis turi pasirinkti testą „Studentų akademinio saviveiksmingumo skalė“.
Sužadinimo sąlyga		Dalyvis paspaudžia mygtuką <i>Pradėti</i> .
Po-sąlyga		Testas „Studentų akademinio saviveiksmingumo skalė“ užbaigiamas.
Pagrindinis scenarijus		Dalyvis pasirenka testą „Studentų akademinio saviveiksmingumo skalė“ ir paspaudęs mygtuką <i>Pradėti</i> įvertina 33 teiginius skalėje nuo 1 iki 5. Įvertinęs visus teiginius, dalyvis paspaudžia testo užbaigimo mygtuką.
Alternatyvūs scenarijai		Gaunamas pranešimas, kad ne visi 33 teiginiai įvertinti.

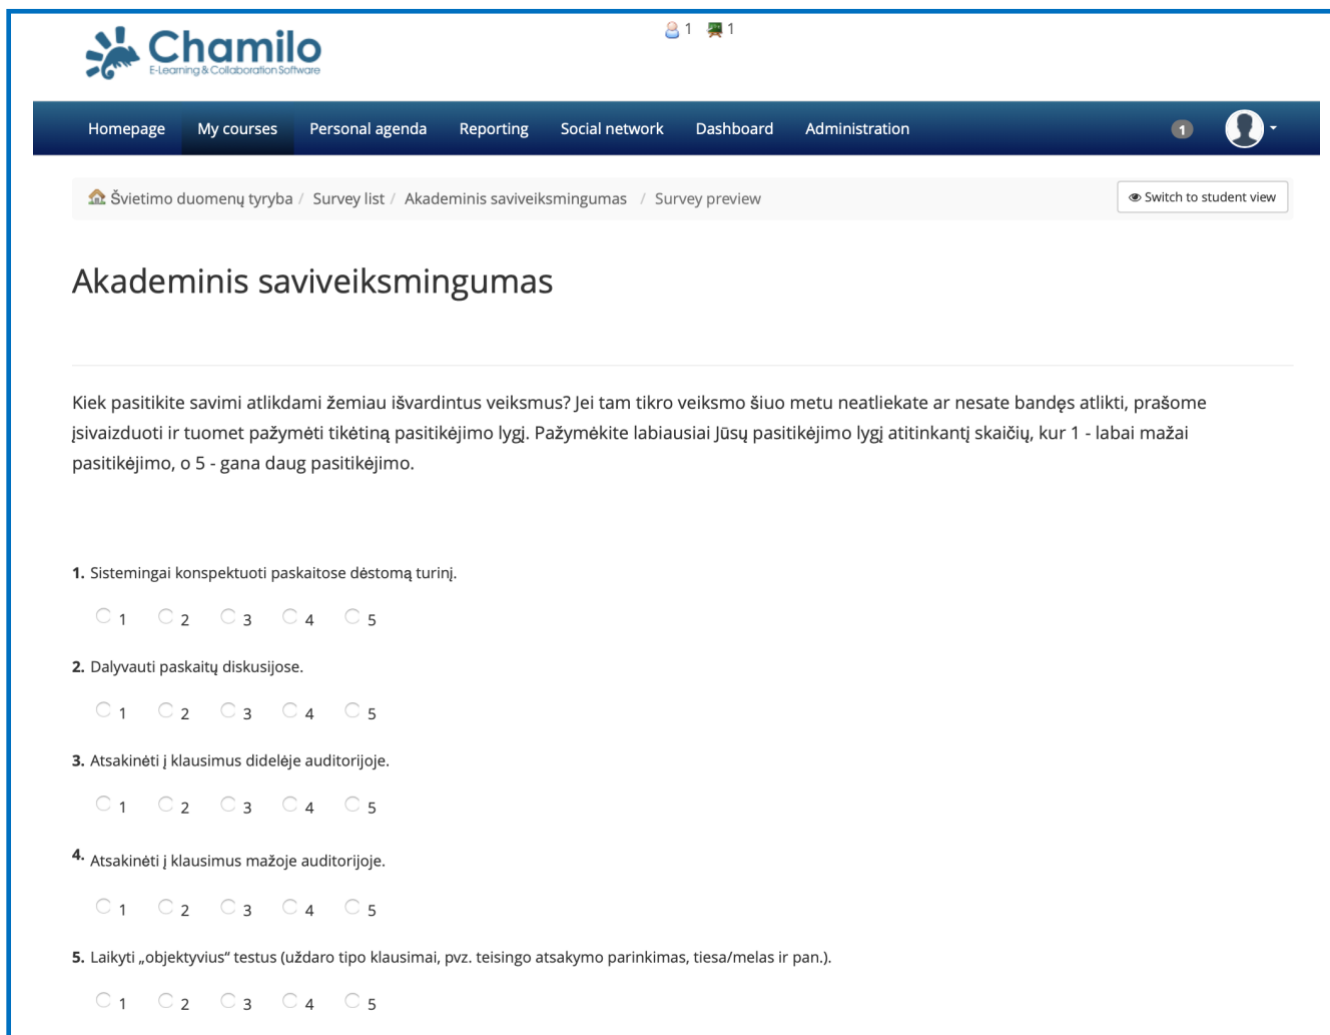
6 priedas. VMA bendravimo posistemio panaudojimo atvejų specifikacija

Panaudojimo atvejis	Nr. 1	Siųsti asmeninę žinutę dalyviams
Tikslas		Asmeninė žinutė siūsti informaciją virtualiosios mokymosi aplinkos dalyviams.
Dalyviai		Dėstytojas, besimokantysis, administratorius.
Ryšiai su kitais panaudojimo atvejais		Atsakyti į asmeninę žinutę. Gauti pranešimą e. paštu apie naujas asmenines žinutes, komentarus, įrašus forume.
Nefunkciniai reikalavimai		Prieinama visą parą, prieinama mobiliems įrenginiams, atliekama nesudėtingai, prieinama visiems registruotiems sistemos dalyviams.
Prieš-sąlygos		Dalyvis turi įsijungti asmeninės žinutės siuntimo meniu.
Sužadinimo sąlyga		Dalyvis paspaudžia asmeninės žinutės siuntimo mygtuką „Siųsti“.
Po-sąlyga		Asmeninė žinutė išsiunčiama nurodytam dalyviui.
Pagrindinis scenarijus		Dalyvis įsijungia asmeninės žinutės siuntimo meniu. Meniu lange dalyvis nurodo žinutės adresatą (dalyvį, kuriam siunčiama žinutė) ir parašo žinutės tekstą. Baigęs rašyti žinutės tekstą spaudžia <i>Siųsti</i> .
Alternatyvūs scenarijai		1. Gaunamas pranešimas apie neįvestą adresatą arba neparašytą žinutės tekstą. 2. Gaunamas pranešimas, kad tokio adresato nėra sistemoje.

Panaudojimo atvejis	Nr. 2	Sukurti pokalbių kanalą
Tikslas		Sukurti pokalbių kanalą, kuriame dalyviai galėtų bendrauti tarpusavyje realiu laiku.
Dalyviai		Dėstytojas, besimokantysis, administratorius.
Ryšiai su kitais panaudojimo atvejais		Rašyti pokalbio dalyviams. Jungtis prie pokalbių kanalo. Rodyti pokalbio dalyvius.
Nefunkciniai reikalavimai		Prieinama visą parą, prieinama mobiliems įrenginiams, atliekama nesudėtingai, prieinama visiems registruotiems sistemos dalyviams.
Prieš-sąlygos		Dalyvis turi būti prisijungęs prie sistemos ir pasirinkti pokalbių kanalo ikonėlę.
Sužadinimo sąlyga		Dalyvis paspaudžia pokalbių kanalo kūrimo mygtuką „Sukurti“.
Po-sąlyga		Sukuriamas pokalbių kanalas.
Pagrindinis scenarijus		Dalyvis paspaudžia ant pokalbių kanalo ikonėlės. Atsidaro pokalbių kanalo langas. Atsidariusiame lange dalyvis paspaudžia pokalbių kanalo kūrimo mygtuką „Sukurti“. Sukuriamas pokalbių kanalas.
Alternatyvūs scenarijai		Gaunamas pranešimas, kad pokalbių kanalas jau yra sukurtas ir gaunamas pasiūlymas jungtis prie anksčiau sukurto pokalbių kanalo.

Panaudojimo atvejis	Nr. 3	Siųsti e. laišką dalyviams
Tikslas		E. laišku siūsti informaciją virtualiosios mokymosi aplinkos dalyviams.
Dalyviai		Dėstytojas, besimokantysis, administratorius.
Ryšiai su kitais panaudojimo atvejais		Atsakyti į e. laišką.
Nefunkciniai reikalavimai		Prieinama visą parą, prieinama mobiliems įrenginiams, atliekama nesudėtingai, prieinama visiems registruotiems sistemos dalyviams.
Prieš-sąlygos		Dalyvis turi pasirinkti e. laiško ikonėlę.
Sužadinimo sąlyga		Dalyvis paspaudžia e. laiško siuntimo mygtuką „Siųsti“.
Po-sąlyga		E. laiškas išsiunčiamas nurodytam dalyviui.
Pagrindinis scenarijus		Dalyvis paspaudžia ant e. laiško ikonėlės. Atsidaro e. laiško siuntimo langas, kuriame dalyvis nurodo adresato e. pašto adresatą, įrašo e. laiško temą ir parašo e. laiško tekstą. Baigęs rašyti tekstą spaudžia <i>Siųsti</i> .
Alternatyvūs scenarijai		Gaunamas pranešimas apie neįvestą adresatą, neįrašytą e. laiško temą arba neparašytą e. laiško tekstą.

„Akademinio saviveiksmingumo skalė“ metodikos realizacija Chamilo VMA



The screenshot shows the Chamilo VMA interface. At the top, there is a navigation menu with options: Homepage, My courses, Personal agenda, Reporting, Social network, Dashboard, and Administration. The current page is titled 'Akademinis saviveiksmingumas' and is a survey preview. The survey content includes an introduction and five questions with radio button options for ratings from 1 to 5.

Chamilo
E-Learning & Collaboration Software

Home page My courses Personal agenda Reporting Social network Dashboard Administration

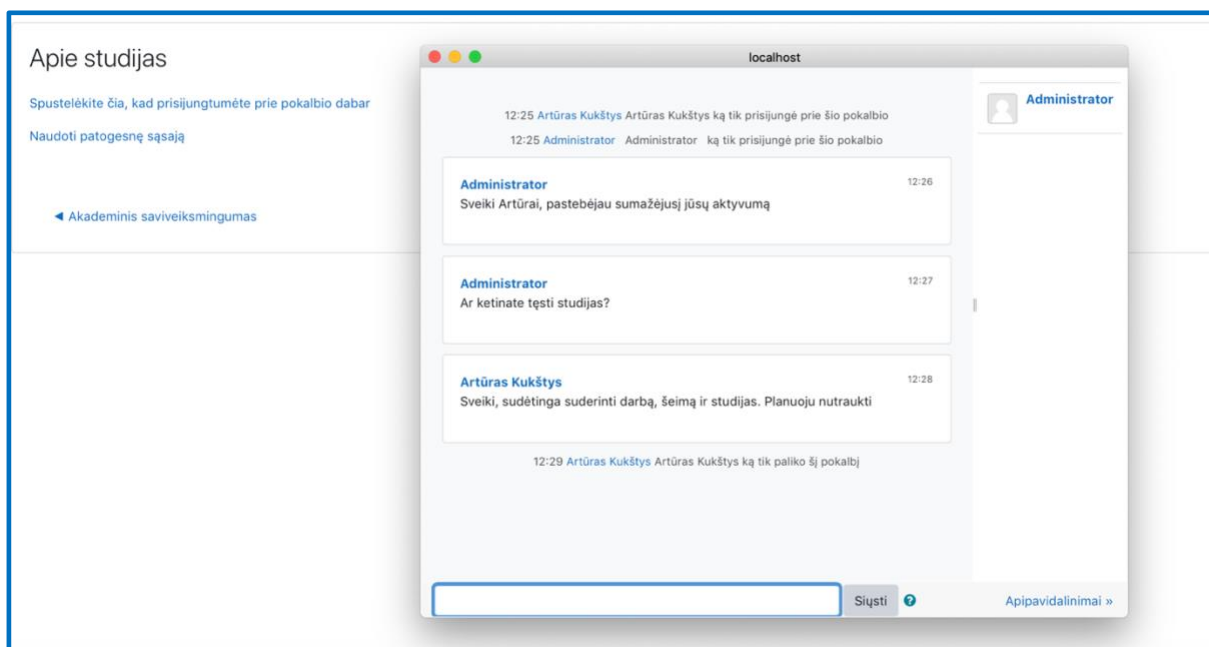
Švietimo duomenų tyryba / Survey list / Akademinis saviveiksmingumas / Survey preview [Switch to student view](#)

Akademinis saviveiksmingumas

Kiek pasitikite savimi atlikdami žemiau išvardintus veiksmus? Jei tam tikro veiksmo šiuo metu neatliekate ar nesate bandę atlikti, prašome įsivaizduoti ir tuomet pažymėti tikėtiną pasitikėjimo lygį. Pažymėkite labiausiai Jūsų pasitikėjimo lygį atitinkantį skaičių, kur 1 - labai mažai pasitikėjimo, o 5 - gana daug pasitikėjimo.

1. Sistemingai konspektuoti paskaitose dėstomą turinį.
 1 2 3 4 5
2. Dalyvauti paskaitų diskusijose.
 1 2 3 4 5
3. Atsakinėti į klausimus didelėje auditorijoje.
 1 2 3 4 5
4. Atsakinėti į klausimus mažoje auditorijoje.
 1 2 3 4 5
5. Laikyti „objektyvius“ testus (uždaro tipo klausimai, pvz. teisingo atsakymo parinkimas, tiesa/melas ir pan.).
 1 2 3 4 5

Pokalbio kanalo sukūrimas Moodle VMA ir bendravimas jame



The screenshot shows a Moodle chat window titled 'Apie studijas'. The chat history includes messages from the Administrator and Artūras Kukštys. The Administrator asks if Artūras is ready to start the studio, and Artūras responds that he is ready to start work, family, and the studio, and plans to leave.

Apie studijas

Spustelėkite čia, kad prisijungtumėte prie pokalbio dabar

Naudoti patogesnę sąsają

◀ Akademinis saviveiksmingumas

localhost

12:25 Artūras Kukštys Artūras Kukštys ką tik prisijungė prie šio pokalbio

12:25 Administrator Administrator ką tik prisijungė prie šio pokalbio

Administrator 12:26
Sveiki Artūrai, pastebėjau sumažėjusį jūsų aktyvumą

Administrator 12:27
Ar ketinate tęsti studijas?

Artūras Kukštys 12:28
Sveiki, sudėtinga suderinti darbą, šeimą ir studijas. Planuoju nutraukti

12:29 Artūras Kukštys Artūras Kukštys ką tik paliko šį pokalbį

[Apipavidalinimai >](#)

Pokalbio kanalo sukūrimas Chamilo VMA ir bendravimas jame

The screenshot displays the Chamilo VMA chat interface. On the left, under the heading "Interaction", there is a menu with six items: Agenda (calendar icon), Forums (speech bubbles icon), Groups (three people icon), Chat (smiling face icon), Wiki (pencils icon), and Notebook (notepad icon). The main chat area on the right shows a browser window with the URL `localhost:8888/chamilo/main/chat/chat.php?cidReq=SVIETIMODUOMENUTYRYBA&id_session=0&gradebook=0&o...`. A list of participants is visible: Artūras Kukštys (admin), Kazys Kukštys (mokytojas), and Artūras Kukštys (studentas). A message from Artūras Kukštys (admin) reads: "Sveiki dėstytojai, noriu informuoti, kad planuoju nutraukti studijas. Kaip tai galiu padaryti?". The message is timestamped "28/05/22 12:32:29". Below the message is a "Clear the chat" button. At the bottom, there is a "Write" tab, a "Preview" tab, an emoji picker, a text input field, and a "Send message" button.

8 priedas. Chamilo VMA grafinė vartotojo sąsaja lietuvių kalba

The screenshot displays the Chamilo VMA user interface in Lithuanian. At the top, the Chamilo logo is visible, along with the text 'E-Learning & Collaboration Software'. The navigation bar includes 'Pradžia', 'Mano kursai', 'Mano darbotvarkė', 'Mano progresas', and 'Social network'. The main content area is titled 'Mano kursai' and features a user profile section with a red circle highlighting the 'Profile' menu. The 'Profile' menu includes 'Priėmimo dėžutė', 'Compose', 'Pending invitations', 'Personal data', and 'Edit profile'. Below the profile section is a 'kursai' section with options like 'Rėduoti mano kursus', 'Courses history', 'Course catalog', 'Last visited course', and 'Last visited learning path'.

10 priedas. SQL užklauso duomenims paimti iš KTU IF Moodle duomenų bazės

Studijų modulio identifikacijos numerio paieška

```
SELECT * FROM `mdl_course` WHERE shortname LIKE '%VMP%'
```

Kiek kartų per savaitę jungtasi prie modulių KTU IF Moodle VMA

```
SELECT L.userid, U.firstname, U.lastname,  
WEEK(DATE_FORMAT(FROM_UNIXTIME(L.timecreated), '%Y-%m-%d')) as week_number,  
COUNT(*) as access_count  
FROM mdl_logstore_standard_log L  
JOIN mdl_user U ON U.id = L.userid  
WHERE L.courseid = '561' AND YEAR(FROM_UNIXTIME(L.timecreated)) = 2021  
GROUP BY L.userid, U.firstname, U.lastname, week_number;
```

Kiek paspaudimų atlikta moduluose KTU IF Moodle VMA

```
SELECT L.userid, U.firstname, U.lastname,  
WEEK(DATE_FORMAT(FROM_UNIXTIME(L.timecreated), '%Y-%m-%d')) as week_number,  
COUNT(*) as click_count  
FROM mdl_logstore_standard_log L  
JOIN mdl_user U ON U.id = L.userid  
WHERE L.courseid = '561'  
AND YEAR(FROM_UNIXTIME(L.timecreated)) = 2021  
AND L.action = 'viewed'  
GROUP BY L.userid, U.firstname, U.lastname, week_number;
```

11 priedas. Duomenų parengimas programinėje sistemoje R

Duomenų filtravimas ir pervadinimas

```
# Prieš kodo taikymą duomenys turi būti atskirti kableliu, ne kabliataškiu
# dplyr bibliotekos užkrovimas
# readr bibliotekos įkėlimas
library(readr)

library(dplyr)

# Nurodomas katalogas, kuriame yra failai su duomenimis
dir_path <- "/Magistrantura/Duomenys/Prasideda 35/"

# Sudaromas .csv failų sąrašas
file_list <- list.files(dir_path, pattern = "\\\\.csv$")

# Failų nuskaitymo ir duomenų filtravimo ciklas
for (file_name in file_list) {
  data <- read.csv(paste0(dir_path, file_name))

  # Duomenų filtravimas pagal nurodytas savaites, kai prasideda mokslo metai
  # Jei mokslo metai prasideda 36 savaitę, tai filtruojama nuo 36 iki 43 savaitės
  data_filtered <- data %>%
    filter(week_number %in% c(35, 36, 37, 38, 39, 40, 41, 42)) %>%

  # Pervadinimas į mokymosi savaites
  mutate(week_number = case_when(
    week_number == 35 ~ "week1",
    week_number == 36 ~ "week2",
    week_number == 37 ~ "week3",
    week_number == 38 ~ "week4",
    week_number == 39 ~ "week5",
    week_number == 40 ~ "week6",
    week_number == 41 ~ "week7",
    week_number == 42 ~ "week8",
    TRUE ~ as.character(week_number)
  ))

  # Duomenų failo po filtravimo išsaugojimas
  write.csv(data_filtered, paste0(dir_path, gsub("\\\\.csv$", "filtered.csv", file_name)))
}
```

Lentelės išplėtimas pagal stulpelius

```
# Bibliotekų įkėlimas
library(readr)
library(tidyr)

# Duomenų failo nuskaitymas
data <- read_csv("/Magistrantura/Duomenys/TP1_A.csv", col_names = TRUE, col_types = cols())

# Savaitės numeriai paverčiami stulpeliais (šiuo atveju - studentų prisijungimų skaičius)
join_wider <- data %>%
```

```

mutate(access_count = as.numeric(access_count)) %>%
pivot_wider(id_cols = c(key),
            names_from = week_number,
            values_from = access_count,
            names_prefix = "TP1_access_",
            values_fn = sum)

# Išplėstos lentelės išsaugojimas
write_csv(join_wider, "/Magistrantura/Duomenys/TP1_A_Wider.csv")

```

```

# Bibliotekų įkėlimas
library(readr)
library(tidyr)

# Duomenų failo nuskaitymas
data <- read_csv("/Magistrantura/Duomenys/Testavimui/TP1 clicks 2021filtered.csv", col_names =
TRUE, col_types = cols())

# Savaitės numeriai paverčiami stulpeliais (šiuo atveju - studentų paspaudimų skaičius)
join_wider <- data %>%
mutate(click_count = as.numeric(click_count)) %>%
pivot_wider(id_cols = c(key),
            names_from = week_number,
            values_from = click_count,
            names_prefix = "TP1_clicks_",
            values_fn = sum)

# Išplėstos lentelės išsaugojimas
write_csv(join_wider, "/Magistrantura/Duomenys/Testavimui/TP1_C_Wider.csv")

```

Lentelių sujungimas

```

# Duomenų failo nuskaitymas
# Pavyzdžiui, lentelė su access_count duomenimis sujungiama su clicks_count lentele
data1 <- read_csv("/Magistrantura/Duomenys/A.csv", col_names = TRUE, col_types = cols())
data2 <- read_csv("/Magistrantura/Duomenys/TP1 C.csv", col_names = TRUE, col_types = cols())

# Lentelių jungimas pagal stulpelį "key"
join <- inner_join(data1, data2, by = c("key"), multiple = "all")

# Rezultato peržiūrėjimas
View(join)

# Sujungtos lentelės išsaugojimas
write_csv(join, "/Magistrantura/Duomenys/Sujungti TP1.csv")

```


12 priedas. Akademinės sėkmės prognozavimo modelio apmokymui parengto duomenų rinkinio iškarpa

```
Apmokymas.arff
@relation 'KTU IF Moodle apmokymui-weka.filters.unsupervised.attribute.Remove-R1.9.17.25.33''
@attribute TP1_access_week1 numeric
@attribute TP1_access_week2 numeric
@attribute TP1_access_week3 numeric
@attribute TP1_access_week4 numeric
@attribute TP1_access_week5 numeric
@attribute TP1_access_week6 numeric
@attribute TP1_access_week7 numeric
@attribute TP1_clicks_week1 numeric
@attribute TP1_clicks_week2 numeric
@attribute TP1_clicks_week3 numeric
@attribute TP1_clicks_week4 numeric
@attribute TP1_clicks_week5 numeric
@attribute TP1_clicks_week6 numeric
@attribute TP1_clicks_week7 numeric
@attribute VMP_access_week1 numeric
@attribute VMP_access_week2 numeric
@attribute VMP_access_week3 numeric
@attribute VMP_access_week4 numeric
@attribute VMP_access_week5 numeric
@attribute VMP_access_week6 numeric
@attribute VMP_access_week7 numeric
@attribute VMP_clicks_week1 numeric
@attribute VMP_clicks_week2 numeric
@attribute VMP_clicks_week3 numeric
@attribute VMP_clicks_week4 numeric
@attribute VMP_clicks_week5 numeric
@attribute VMP_clicks_week6 numeric
@attribute VMP_clicks_week7 numeric
@attribute success {N,T}

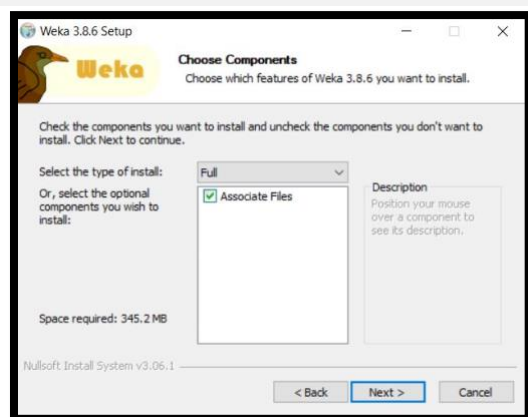
@data
17,0,0,0,0,0,9,0,0,0,0,0,0,0,5,0,0,0,0,0,0,0,5,0,0,0,0,0,0,N
36,63,29,19,23,28,27,23,43,29,18,21,23,17,96,46,83,120,70,41,67,87,46,83,106,56,41,56,T
41,0,68,42,73,18,2,38,0,63,32,68,17,2,36,0,65,108,61,17,6,27,0,64,95,56,17,6,N
13,8,20,2,17,27,7,10,8,15,2,16,20,7,34,13,50,36,63,0,25,25,13,42,25,52,0,20,N
0,34,16,20,29,2,12,0,26,16,15,25,2,12,26,58,80,110,92,21,41,17,56,71,90,84,18,36,T
47,35,54,18,26,3,7,39,35,47,17,26,3,7,32,44,65,31,65,24,43,32,33,50,26,54,21,35,T
7,47,23,33,36,8,19,4,42,23,28,33,8,19,42,74,70,56,124,18,97,33,74,59,45,111,18,89,T
10,13,23,6,4,1,0,7,13,17,6,4,1,0,24,14,24,15,26,38,44,15,14,22,9,23,27,39,T
7,85,8,0,0,5,0,4,80,8,0,0,5,0,35,16,59,49,61,60,37,26,16,48,39,50,57,32,T
23,53,14,10,30,18,19,15,48,14,5,27,18,14,83,13,106,92,91,46,92,74,13,90,81,83,46,83,T
27,21,5,20,10,2,24,19,21,4,15,9,2,22,46,18,39,55,45,34,42,37,16,34,41,34,31,34,T
0,39,16,13,4,9,12,0,31,16,8,4,9,12,23,16,38,62,13,19,63,14,16,34,50,13,16,58,T
18,30,27,28,60,27,17,15,25,27,28,49,25,17,40,19,96,91,50,40,94,31,19,82,80,43,37,86,T
18,35,17,26,22,7,8,10,20,17,20,15,7,8,82,37,51,81,84,16,62,73,35,40,66,76,16,53,T
5,14,5,5,25,2,0,2,9,5,5,17,2,0,33,32,52,21,60,17,38,24,32,41,16,44,14,33,T
12,0,4,17,13,6,5,4,0,4,17,10,6,5,28,16,52,23,68,45,39,19,14,38,18,55,39,34,N
8,12,40,10,17,0,2,5,12,35,5,15,0,2,38,5,110,52,64,16,55,29,5,99,45,56,16,46,N
24,24,24,6,17,4,23,21,16,19,6,16,4,23,69,41,79,65,68,38,51,60,41,62,53,63,34,46,T
0,36,4,18,105,0,17,0,28,4,18,77,0,17,0,13,16,34,122,0,35,0,13,16,32,101,0,35,T
0,11,0,135,22,162,48,0,8,0,104,22,134,47,0,1,3,104,103,38,56,0,1,3,93,92,34,54,T
0,28,0,98,37,24,18,0,20,0,65,27,18,18,0,12,0,33,152,18,40,0,12,0,31,129,18,36,T
0,4,19,0,8,0,0,0,1,14,0,8,0,0,0,7,21,3,64,0,0,0,7,17,3,47,0,0,N
```

13 priedas. Duomenų tyrybos programinės sistemos Weka diegimas Windows 10 OS



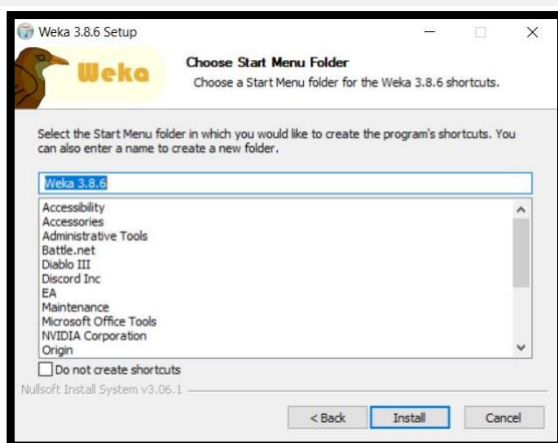
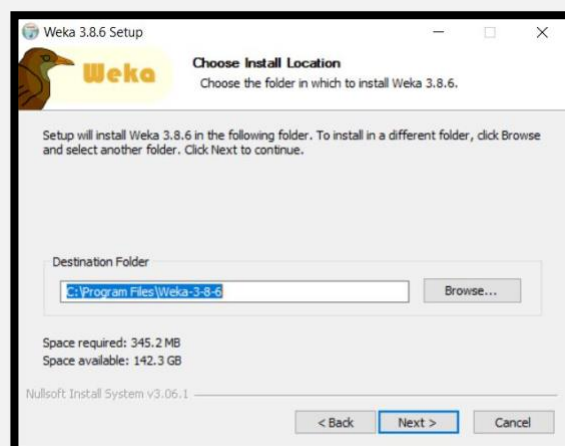
1. Parsisiuntus Weka diegimo failą .exe reikia jį atidaryti. Atsidariusiame pasisveikinimo lange spaudžiamas „Next“ mygtukas.

2. Toliau spaudžiamas mygtukas „I Agree“, kuriuo sutinkama su Weka licencijos sąlygomis.



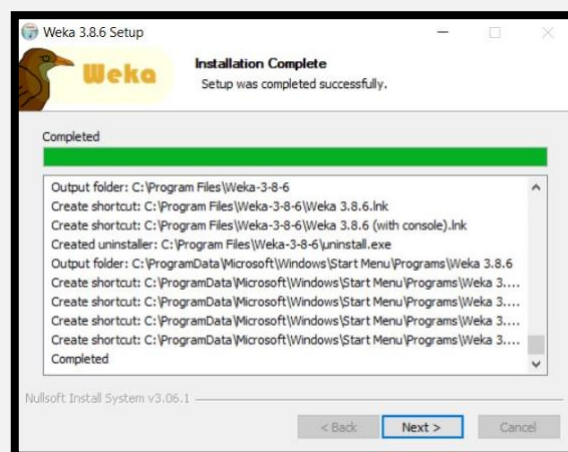
3. Atsidariusiame komponentų lange pasirenkamas „Associate Files“ ir spaudžiamas mygtukas „Next“.

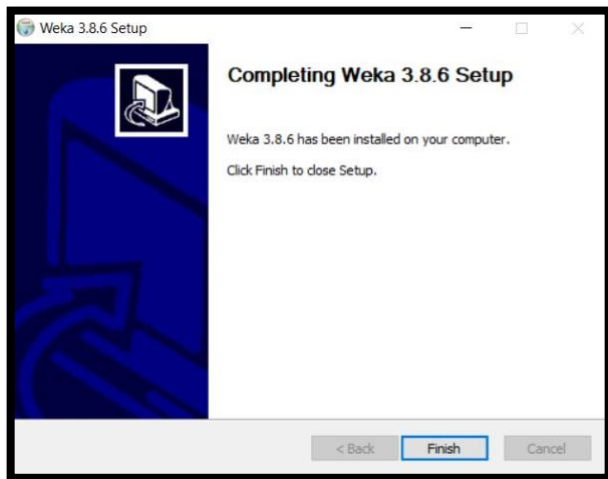
4. Tada nurodoma vieta, kur norima įdiegti Weka failus ir spaudžiamas mygtukas „Next“.



5. Vėliau nurodomas Weka katalogo pavadinimas pradžios meniu juostoje ir spaudžiamas „Install“ mygtukas.

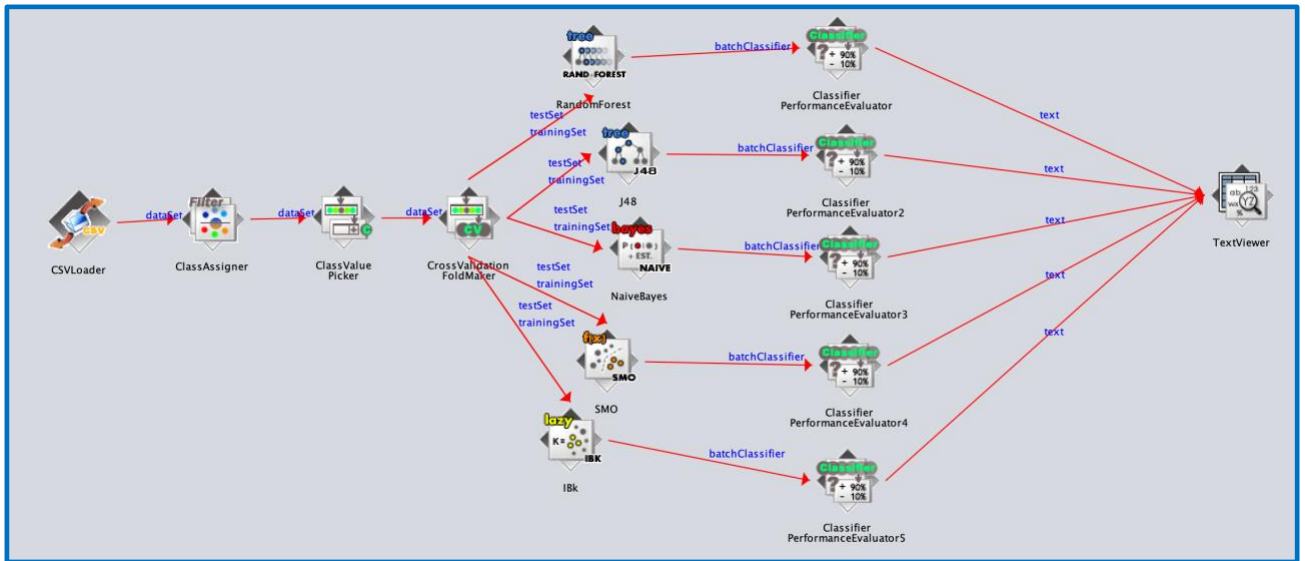
6. Atsidariusiame diegimo lange spaudžiamas mygtukas „Next“.





7. Diegimas baigiamas paspaudus mygtuką „Finish“.

14 priedas. Pirminis akademinės sėkmės prognozavimo modelis Weka programinėje sistemoje



15 priedas. SQL užklausų testavimo rezultatai

Paimant duomenis apie studentų prisijungimų skaičių modulyje „Virtualiojo mokymosi pagrindai“ (2021 m.)

The screenshot shows the phpMyAdmin interface with a SQL query executed. The query filters for course ID '561' and the year 2021, grouping results by week number. The result table shows the following data:

userid	firstname	lastname	week_number	access_count
			36	2
			35	28
			37	3
			39	22

Paimant duomenis apie studentų paspaudimų skaičių modulyje „Virtualiojo mokymosi pagrindai“ (2021 m.)

The screenshot shows the phpMyAdmin interface with a SQL query executed. The query filters for course ID '561' and the year 2021, grouping results by week number. The result table shows the following data:

userid	firstname	lastname	week_number	click_count
			35	16
			36	82
			37	3
			38	17

Paimant duomenis apie studentų paspaudimų skaičių modulyje „Tiriamasis projektas 1“ (2021 m.)

The screenshot shows the phpMyAdmin interface with a SQL query executed. The query filters for course ID '566' and the year 2021, grouping results by user and week. The results table shows one row with a click count of 1.

```

SELECT L.userid, U.firstname, U.lastname, WEEK(DATE_FORMAT(FROM_UNIXTIME(L.timecreated), '%Y-%m-%d')) as week_number, COUNT(*) as click_count FROM
mdl_logstore_standard_log L JOIN mdl_user U ON U.id = L.userid WHERE L.courseid = '566' AND YEAR(FROM_UNIXTIME(L.timecreated)) = 2021 AND L.action =
'viewed' GROUP BY L.userid, U.firstname, U.lastname, week_number;
    
```

userid	firstname	lastname	week_number	click_count
			40	1

Paimant duomenis apie studentų prisijungimų skaičių modulyje „Tiriamasis projektas 1“ (2022 m.)

The screenshot shows the phpMyAdmin interface with a SQL query executed. The query filters for course ID '599' and the year 2022, grouping results by user and week. The results table shows two rows with access counts of 27 and 50.

```

SELECT L.userid, U.firstname, U.lastname, WEEK(DATE_FORMAT(FROM_UNIXTIME(L.timecreated), '%Y-%m-%d')) as week_number, COUNT(*) as access_count FROM
mdl_logstore_standard_log L JOIN mdl_user U ON U.id = L.userid WHERE L.courseid = '599' AND YEAR(FROM_UNIXTIME(L.timecreated)) = 2022 GROUP BY
L.userid, U.firstname, U.lastname, week_number;
    
```

userid	firstname	lastname	week_number	access_count
			39	27
			40	50

Paimant duomenis apie studentų paspaudimų skaičių modulyje „Tiriamasis projektas 1“ (2022 m.)

The screenshot shows the phpMyAdmin interface with a SQL query executed. The query filters for course ID '599' and action 'viewed' in the year 2022. The results table shows the following data:

userid	firstname	lastname	week_number	click_count
			36	4
			37	18

Paimant duomenis apie studentų prisijungimų skaičių modulyje „Virtualiojo mokymosi pagrindai“ (2022 m.)

The screenshot shows the phpMyAdmin interface with a SQL query executed. The query filters for course ID '593' in the year 2022. The results table shows the following data:

userid	firstname	lastname	week_number	access_count
			39	5
			40	83
			41	35

Paimant duomenis apie studentų paspaudimų skaičių modulyje „Virtualiojo mokymosi pagrindai“ (2022 m.)

The screenshot shows the phpMyAdmin interface for a Moodle database. A SQL query is executed, showing the results in a table. The query filters for course ID 593 and year 2022, grouping by user and week. The results table shows click counts for three users.

```
SELECT L.userid, U.firstname, U.lastname, WEEK(DATE_FORMAT(FROM_UNIXTIME(L.timecreated), '%Y-%m-%d')) as week_number, COUNT(*) as click_count FROM md_logstore_standard_log L JOIN md_user U ON U.id = L.userid WHERE L.courseid = '593' AND YEAR(FROM_UNIXTIME(L.timecreated)) = 2022 AND L.action = 'viewed' GROUP BY L.userid, U.firstname, U.lastname, week_number;
```

userid	firstname	lastname	week_number	click_count
			38	12
			39	2
			40	8

16 priedas. Akademinės sėkmės prognozavimo modelio testavimui parengto duomenų rinkinio iškarpa

```
KTU IF Moodle testavimui su key.arff
@relation 'KTU IF Moodle testavimui'

@attribute key {1RI2T4,UFPQQB,UTIB7X,VTV0CY,CX7ZC0,BGBWDH,
5Q2BM0,AC0SYC,QNXZYW,N3QKDZ,YERKC6,EHRH4D,J3YX14,CZRDII,J09TVX,L00AAN,DCNE9R,
03TI1M,C0X5VN,U6Z6FC,90UC3M}
@attribute TP1_access_week1 numeric
@attribute TP1_access_week2 numeric
@attribute TP1_access_week3 numeric
@attribute TP1_access_week4 numeric
@attribute TP1_access_week5 numeric
@attribute TP1_access_week6 numeric
@attribute TP1_access_week7 numeric
@attribute TP1_clicks_week1 numeric
@attribute TP1_clicks_week2 numeric
@attribute TP1_clicks_week3 numeric
@attribute TP1_clicks_week4 numeric
@attribute TP1_clicks_week5 numeric
@attribute TP1_clicks_week6 numeric
@attribute TP1_clicks_week7 numeric
@attribute VMP_access_week1 numeric
@attribute VMP_access_week2 numeric
@attribute VMP_access_week3 numeric
@attribute VMP_access_week4 numeric
@attribute VMP_access_week5 numeric
@attribute VMP_access_week6 numeric
@attribute VMP_access_week7 numeric
@attribute VMP_clicks_week1 numeric
@attribute VMP_clicks_week2 numeric
@attribute VMP_clicks_week3 numeric
@attribute VMP_clicks_week4 numeric
@attribute VMP_clicks_week5 numeric
@attribute VMP_clicks_week6 numeric
@attribute VMP_clicks_week7 numeric
@attribute success {N,T}

@data
1RI2T4,25,0,10,140,39,1,49,1,0,10,103,26,1,36,1,0,0,5,0,0,0,1,0,0,5,0,0,0,?
UFPQQB,77,13,13,26,27,32,2,37,13,13,20,22,26,2,25,18,33,62,21,44,42,22,18,25,54,21,41,34,?
UTIB7X,79,10,22,41,32,18,2,49,10,22,35,27,12,2,32,3,39,57,22,34,34,29,3,35,48,21,28,30,?
VTV0CY,122,58,50,54,22,27,16,82,53,44,49,22,21,16,61,39,80,65,110,27,57,58,39,71,55,110,27,46,?
CX7ZC0,38,34,24,36,14,39,17,14,28,21,36,14,27,17,38,29,50,60,51,32,57,35,29,45,52,46,29,48,?
BGBWDH,58,23,11,54,2,2,20,28,23,11,38,2,2,12,42,17,37,32,3,25,31,39,17,25,25,3,21,23,?
5Q2BM0,78,18,31,39,9,39,5,48,13,25,29,9,28,5,60,27,90,70,34,22,53,57,27,77,55,34,22,45,?
AC0SYC,32,49,28,22,52,14,4,8,34,21,17,35,13,4,26,8,31,14,27,31,18,23,8,27,10,23,31,14,?
QNXZYW,105,38,52,21,43,65,3,63,38,47,15,32,46,3,26,22,46,38,19,26,45,23,22,37,31,19,20,37,?
N3QKDZ,51,0,3,0,0,0,0,21,0,3,0,0,0,0,15,0,0,0,0,0,0,12,0,0,0,0,0,?
YERKC6,87,20,31,38,2,9,20,45,20,31,27,2,9,14,24,15,41,32,21,29,69,21,13,28,21,21,26,56,?
```

17 priedas. Akademinės sėkmės prognozavimo modelio testavimo rezultatai

Akademinės sėkmės prognozės 2021 m. įstojusiems studentams

Nr.	Raktas	Užtikrintumo įvertis	Prognozė	Situacija
1.	1RI2T4	0,06	N	Sustabdė
2.	UFPQQB	-0,72	T	Studijuoja
3.	UTIB7X	-0,02	T	Studijuoja
4.	VTV0CY	-0,72	T	Studijuoja
5.	CX7ZC0	-0,96	T	Studijuoja
6.	BGBWDH	-0,42	T	Studijuoja
7.	5Q2BM0	-0,94	T	Studijuoja
8.	AC0SYC	-0,32	T	Studijuoja
9.	QNXZYW	-0,78	T	Studijuoja
10.	N3QKDZ	0,82	N	Nutraukė
11.	YERKC6	-0,32	T	Studijuoja
12.	EHRH4D	-0,68	T	Studijuoja
13.	J3YX14	-0,72	T	Studijuoja
14.	CZRDI	-0,86	T	Studijuoja
15.	J09TVX	0,78	N	Nutraukė
16.	L00AAN	-0,14	T	Nutraukė
17.	DCNE9R	0,02	N	Nutraukė
18.	03TI1M	-0,74	T	Studijuoja
19.	C0X5VN	-0,68	T	Studijuoja
20.	U6Z6FC	0,86	N	Nutraukė
21.	90UC3M	-0,72	T	Studijuoja

Akademinės sėkmės prognozės 2022 m. įstojusiems studentams

Nr.	Raktas	Užtikrintumo įvertis	Prognozė	Situacija
22.	3LTZSN	-0,1	T	Sustabdė
23.	AWX8ME	0,14	N	Studijuoja be skolų
24.	G13SVY	-0,04	T	Studijuoja, mažas aktyvumas
25.	227PO4	-0,68	T	Studijuoja
26.	6CY0D2	-0,88	T	Studijuoja
27.	1JUNVU	0,78	N	Nutraukė
28.	KOHIUE	-0,3	T	Studijuoja
29.	GQ36KE	-0,46	T	Studijuoja
30.	010XLO	0,46	N	Nutraukė
31.	DDRZNX	-0,54	T	Nutraukė dėl asmeninių priežasčių
32.	ZBI6ZP	0,28	N	Studijuoja, turi skolų
33.	82BHBC	-0,42	T	Studijuoja
34.	DQLZFO	-0,68	T	Studijuoja
35.	8LJ7V7	0,44	N	Nutraukė
36.	YSJW15	-0,88	T	Studijuoja
37.	FQZZR0	-0,68	T	Studijuoja
38.	LM59HF	-0,82	T	Studijuoja
39.	9L9D5N	-0,54	T	Studijuoja
40.	T9AOSB	-0,7	T	Studijuoja
41.	98MK19	-0,56	T	Studijuoja
42.	9PKHH	-0,34	T	Studijuoja

43.	02CE6X	-0,32	T	Studijuoją
44.	5M7MDC	-0,58	T	Studijuoją
45.	VP49X9	-0,82	T	Nutraukė
46.	P0TA7N	-0,6	T	Studijuoją
47.	ITDD4J	-0,46	T	Nutraukė, nes programa neatitiko lūkesčių
48.	3FAK7E	-0,82	T	Studijuoją
49.	Q3PN6U	-0,7	T	Studijuoją
50.	KJZMW7	-0,58	T	Studijuoją
51.	070V6G	-0,46	T	Studijuoją
52.	8U8TRA	-0,42	T	Studijuoją
53.	QU8CJH	-0,12	T	Studijuoją, mažas aktyvumas
54.	TA5N92	-0,36	T	Nutraukė
55.	PIUWTV	-0,2	T	Studijuoją
56.	UHAIMN	-0,3	T	Studijuoją
57.	5GJDTP	-0,66	T	Nutraukė dėl sveikatos problemų
58.	5WHHQG	-0,2	T	Studijuoją
59.	1RIG5Z	-0,22	T	Studijuoją
60.	OCMD9C	-0,34	T	Studijuoją
61.	S6DUBQ	-0,76	T	Studijuoją
62.	60JA4A	-0,72	T	Studijuoją
63.	2W1S1U	-0,44	T	Studijuoją
64.	9PEPD2	-0,3	T	Studijuoją
65.	UXJ4TY	0	N	Studijuoją, mažas aktyvumas
66.	27WHP1	0,74	N	Nutraukė dėl asmeninių priežasčių
67.	AQMCY4	-0,76	T	Studijuoją
68.	X32WRL	-0,1	T	Studijuoją, turi skolų
69.	25AX8Q	-0,52	T	Studijuoją
70.	4S22FG	-0,62	T	Nutraukė dėl asmeninių priežasčių
71.	LGR7BG	-0,46	T	Studijuoją
72.	THL7DX	-0,48	T	Nutraukė dėl asmeninių priežasčių
73.	5K19DP	-0,38	T	Nutraukė dėl asmeninių priežasčių
74.	X52I34	-0,44	T	Studijuoją
75.	0WUMN4	-0,58	T	Studijuoją
76.	5E9JY5	-0,5	T	Studijuoją
77.	XL5KL9	-0,88	T	Studijuoją
78.	8TAJMP	-0,46	T	Studijuoją
79.	POSA9D	-0,36	T	Nutraukė dėl asmeninių priežasčių
80.	7FFF3P	-0,4	T	Studijuoją
81.	TODJCD	-0,4	T	Nutraukė dėl asmeninių priežasčių
82.	Z7SM7D	-0,26	T	Sustabdė
83.	SJ96I0	-0,88	T	Studijuoją
84.	LPLUSX	-0,44	T	Studijuoją
85.	DQUJO9	-0,9	T	Studijuoją
86.	D3XNEI	-0,36	T	Nutraukė
87.	QRC9I6	0,6	N	Nutraukė dėl asmeninių priežasčių
88.	3AQKUF	-0,46	T	Nutraukė dėl asmeninių priežasčių
89.	0YBDFY	-0,28	T	Studijuoją
90.	AXHL9G	-0,36	T	Studijuoją
91.	UGTMRE	-0,08	T	Studijuoją, žemi akademiniai pasiekimai
92.	3I004X	-0,52	T	Studijuoją
93.	XIHUF0	0,34	N	Studijuoją, žemi akademiniai pasiekimai

94.	PZ1VVF	0,46	N	Nutraukė dėl asmeninių priežasčių
95.	N50BDC	-0,72	T	Studijuoja



**KAUNO TECHNOLOGIJOS UNIVERSITETO
INFORMATIKOS FAKULTETAS**

Viešoji įstaiga, K. Donelaičio g. 73, 44029 Kaunas.
Duomenys kaupiami ir saugomi Juridinių asmenų registre, kodas 111950581.
Fakulteto duomenys: Studentų g. 50, 51368 Kaunas, tel. (8 37) 30 03 50,
faks. (8 37) 30 03 52, if.ktu.edu, el. p. if@ktu.lt

Artūriui Kukščiui

2023-05-17

**PAŽYMA DĖL BESIMOKANČIŲJŲ AKADEMINĖS SĖKMĖS PROGNOZAVIMO
SISTEMOS MODELIO DIEGIMO**

Patvirtintu, kad Kauno technologijos universiteto antrosios pakopos studijų programos „Nuotolinio mokymosi informacinės technologijos“ studento Artūro Kukščio baigiamajame magistro projekte sukurtas besimokančiųjų akademinės sėkmės prognozavimo sistemos modelis įdiegtas Informatikos fakulteto „Moodle“ sistemoje. Naudojant modelį atliktas eksperimentinis akademinės sėkmės prognozavimas 2021 m. į magistrantūros studijų programą „Nuotolinio mokymosi informacinės technologijos“ įstojusiems studentams, kurie studijas baigia 2023 m. Modelis pakankamai tiksliai nustatė, kurie studentai veikiausiai studijų nebaigs. Ateityje modelis gali būti naudojamas ir vėlesniais metais įstojusių studentų akademinėi sėkmei prognozuoti. Naudojant modelį galima identifikuoti, kuriems studentams gresia studijų nutraukimas. Turint situaciją, kai studijų nebaigia per 30% studentų, Artūro Kukščio sukurtas ir įdiegtas besimokančiųjų akademinės sėkmės prognozavimo modelis gali padėti laiku imtis reikiamų veiksmų, siekiant sumažinti studentų nubyreįjimą.

Studijų programos vadovas

Ramūnas Kubiliūnas

Ramūnas Kubiliūnas, tel. (8 688) 15330, el. p. Ramunas.Kubiliunas@ktu.lt