



Kauno technologijos universitetas

Informatikos fakultetas

**Įvesties ir veido išraiškos analizę taikanti priemonė
besimokančiųjų įsitraukimui vertinti**

Baigiamasis magistro studijų projektas

Povilas Kripas

Projekto autorius

Doc. Vytenis Punys

Vadovas

Kaunas, 2021



Kauno technologijos universitetas

Informatikos fakultetas

Įvesties ir veido išraiškos analizę taikanti priemonė besimokančiųjų įsitraukimui vertinti

Baigiamasis magistro studijų projektas

Nuotolinio mokymosi informacinės technologijos (6211BX010)

Povilas Kripas

Projekto autorius

Doc. Vytenis Punys

Vadovas

Prof. Tomas Blažauskas

Recenzentas

Kaunas, 2021



Kauno technologijos universitetas

Informatikos fakultetas

Povilas Kripas

Įvesties ir veido išraiškos analizę taikanti priemonė besimokančiųjų įsitraukimui vertinti

Akademinio sąžiningumo deklaracija

Patvirtinu, kad mano, Povilo Kripo, baigiamasis projektas tema „Įvesties ir veido išraiškos analizę taikanti priemonė besimokančiųjų įsitraukimui vertinti“ yra parašytas visiškai savarankiškai ir visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

Aš suprantu, kad išaiškėjus nesąžiningumo faktui, man bus taikomos nuobaudos, remiantis Kauno technologijos universitete galiojančia tvarka.

(vardą ir pavardę įrašyti ranka)

(parašas)

Kripas, Povilas. Įvesties ir veido išraiškos analizę taikanti priemonė besimokančiųjų įsitraukimui vertinti. Magistro baigiamasis projektas / vadovas doc. dr. Vytenis Punys; Kauno technologijos universitetas, Informatikos fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Nuotolinio mokymosi informacinės technologijos (Informatikos inžinerija)

Reikšminiai žodžiai: įsitraukimas, nuotolinis mokymasis, veido išraiškos analizė, įvesties analizė, dirbtinis intelektas.

Kaunas, 2021. 57 p.

Santrauka

Baigiamajame magistro darbe nagrinėjama įsitraukimo vertinimo problematika nuotolinio mokymosi kontekste.

Darbe apžvelgiama įsitraukimo mokymesi apibrėžimas literatūroje, pagrindžiamas įsitraukimo vertinimo poreikis, apžvelgiama neverbalinės kalbos svarba mokymosi procese bei įsitraukimo raiškos per neverbalinę kalbą formos, apžvelgiami veidų aptikimo, veido išraiškos atpažinimo ir įvesties analizės sprendimai paremti mašininio mokymosi ir (arba) dirbtinio intelekto algoritmais, atliekamas šių sprendimų pritaikomumo įsitraukimui vertinti tyrimas panaudojant laisvai prieinamus duomenų rinkinius.

Remiantis tyrimo rezultatais ir literatūra suprojektuota ir įgyvendinta priemonė taikanti veido išraiškos bei įvesties analizę įsitraukimo automatiniam vertinimui, realizuota naudojant atvirojo kodo programinę įrangą.

Kripas, Povilas. Application for evaluating engagement of learners using input and facial analysis. Master's Final Degree Project / supervisor doc. dr. Vytenis Punys; Faculty of Informatics, Kaunas University of Technology.

Study field and area (study field group): Information Technologies of Distance Education (Informatics Engineering).

Keywords: engagement, distance learning, facial expression analysis, input analysis, artificial intelligence.

Kaunas, 2021. 57 pages

Summary

The topic of this project is engagement assessment in distance learning context.

The paper reviews the definition of engagement in literature, substantiates the need for engagement assessment, reviews the importance of nonverbal language in learning and engagement expressions through nonverbal language, reviews face detection, facial expression recognition and input analysis solutions based on machine learning and / or algorithmic artificial intelligence, conducts research on the applicability of these solutions to assess engagement using freely available datasets of engagement-related data.

Based on the research results and literature, a tool using facial expression and input analysis for automatic engagement assessment was designed and implemented using open source software.

Turinys

Paveikslų sąrašas	8
Įvadas.....	9
1. Teorinė dalis.....	11
1.1. Įsitraukimo apibrėžimas ir svarba ugdymosi procese	11
1.1.1. Įsitraukimo apibrėžimas mokslinėje literatūroje	11
1.1.2. Įsitraukimo svarba mokymesi.....	12
1.1.3. Įsitraukimo vaidmuo virtualiajame ir nuotoliniame mokymesi	13
1.2. Egzistuojantys įsitraukimo vertinimo sprendimai	14
1.3. Neverbalinė kalba ir jos vaidmuo mokymosi procese.....	15
1.3.1. Vaizdiniai neverbalinės kalbos aspektai.....	16
1.3.2. Parakalba	19
1.3.3. Afektyvioji kompiuterija	20
1.4. Skyriaus išvados	20
2. Metodologinė dalis.....	21
2.1. Įsitraukimo vertinimo modelis	21
2.2. Veidų aptikimo metodai	22
2.2.1. Haar' o klasifikatorių kaskada (Viola-Jones' o metodas)	22
2.2.2. Orientuotų gradientų histogramos metodas.....	25
2.2.3. Giliaisiais neuroniniais tinklais paremtas veidų atpažinimas	26
2.3. Veido išraiškų atpažinimo metodai	27
2.3.1. Tikrinių veidų metodas.....	28
2.3.2. Vietinių dvejetainių šablonų metodas	29
2.3.3. Regresijos medžių rinkinio metodas	29
2.4. Veido išraiškos analizės taikymo įsitraukimo vertinimui tyrimas	30
2.4.1. Bendri tyrimų parametrai	30
2.4.2. Atraminių vektorių klasifikatoriaus modelio taikymas įsitraukimo vertinimui	30
2.4.3. Neuroninio tinklo taikymas įsitraukimo vertinimui	33
2.4.4. Konvoliucinio neuronų tinklo taikymas įsitraukimo vertinimui	35
2.4.5. Išvados.....	36
2.5. Įvesties analizės metodai	36
2.5.1. Pagrindinės įvesties analizės metrikos	37
2.5.2. Bixler'io ir D'Mello papildomos įvesties analizės metrikos.....	37
2.5.3. Įvesties analizė emocijoms nustatyti panaudojant atsitiktinio miško modelį.....	38
2.6. Įvesties analizės taikymo įsitraukimo vertinimui tyrimas	38
2.6.1. Bendri tyrimų parametrai	38
2.6.2. Sudėtinio klasifikatoriaus taikymas įsitraukimo vertinimui.....	39
2.6.3. Neuronų tinklo taikymas įsitraukimo vertinimui	39
3. Projektinė dalis	41
3.1. Reikalavimų specifikacija	41
3.1.1. Projektuojamos priemonės paskirtis ir tikslai.....	41
3.1.2. Suprojektuotos priemonės vartotojai.....	41
3.2. Programos architektūrinė apžvalga	42
3.2.1. Pagrindinė programos posistemė.....	42

3.2.2. Veido išraiškos analizės posistemė	44
3.2.3. Įvesties analizės posistemė	46
3.2.4. Duomenų posistemė	47
3.2.5. Posistemių tarpusavio ryšiai	48
3.2.6. Programos grafinė aplinka.....	48
3.2.7. Programos resursų naudojimas.....	49
Išvados	50
Literatūros sąrašas	51

Paveikslų sąrašas

1 pav. Darbo problematika.....	9
2 pav. Lear NMA interaktyvumo ir bendruomenės procesų modelis	14
3 pav. Pagrindinės emocijos [19].....	17
4 pav. Sudėtinės emocijos	18
5 pav. Dvimatis sužadavimo – valentingumo modelis	19
6 pav. Kategorinis įsitraukimo vertinimo modelis.....	21
7 pav. Tipiniai Haar‘o požymiai	22
8 pav. Klasifikatorių grandinės schema	24
9 pav. Pirminiai Haar‘o klasifikatoriai.....	25
10 pav. Orientuotų gradientų histogramos vizualizacija.....	25
11 pav. Vaizdo gradientai X ir Y ašyse.....	26
12 pav. Zhang‘o ir kt. modelio schema[]	27
13 pav. Tikrinių veidų pavyzdžiai iš AT&T duomenų bazės tikrinių veidų rinkinio	28
14 pav. Regresijos medžių rinkinio metodu išskirti veido požymiai	29
15 pav. Kaupiamosios paaiškintosios dispersijos kreivė	31
16 pav. Apmokyto atraminių vektorių klasifikatoriaus sumaišymo matrica	32
17 pav. Apmokyto atraminių vektorių klasifikatoriaus, prieš tai duomenis transformavus pagal pagrindinių dedamųjų analizę, sumaišymo matrica	33
18 pav. Apmokyto neuronų tinklo sumaišymo matrica	34
19 pav. Apmokyto neuronų tinklo, prieš tai duomenis transformavus pagal pagrindinių dedamųjų analizę, sumaišymo matrica.....	35
20 pav. Apmokyto konvoliucinio neuronų tinklo sumaišymo matrica	36
21 pav. Pagrindiniai įvesties analizės įvykiai	37
22 pav. Apmokyto sudėtinio klasifikatoriaus sumaišymo matrica	39
23 pav. Apmokyto neuronų tinklo sumaišymo matrica	40
24 pav. Pagrindinės posistemės algoritmas.....	42
25 pav. Veido išraiškos posistemės algoritmas.....	44
26 pav. Įvesties analizės posistemės algoritmas	46
27 pav. Duomenų posistemės algoritmas.....	47
28 pav. Programos vaizdas Windows aplinkoje	48
29 pav. Pradinis programos langas.....	49
30 pav. Programos darbo indikatorius su kontekstiniu meniu	49

Įvadas

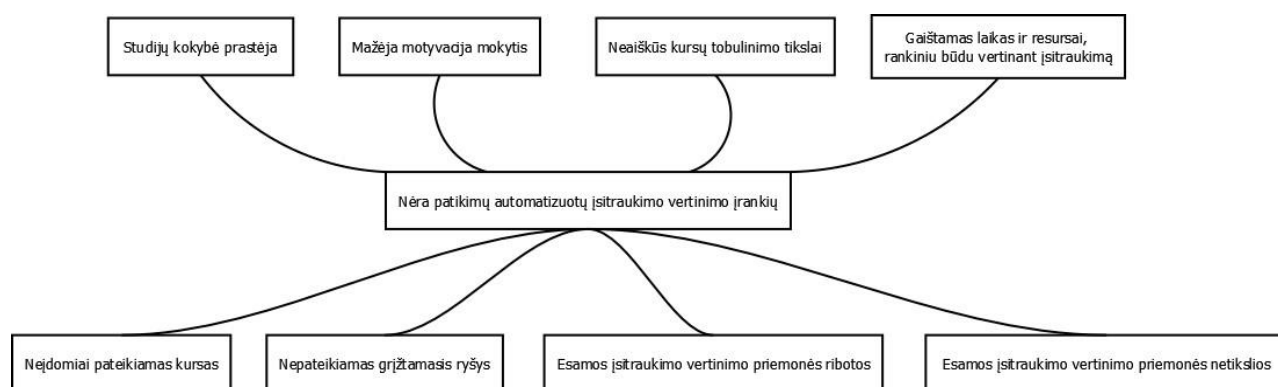
Įsitraukimo vertinimas yra aktuali mokymosi proceso dalis. Tyrimai rodo, kad besimokantieji, kurie yra įsitraukę į mokymosi procesą, geba geriau sutelkti dėmesį, yra labiau motyvuoti, geriau panaudoja kritinio mąstymo įgūdžius ir patiria prasmingas mokymosi patirtis. Įsitraukę besimokantieji yra labiau patenkinti mokymosi procesu, todėl dažniau baigia kursus. Jie taip pat labiau linkę bendrauti su kitais besimokančiais ir skleisti savo naujai įgytas žinias bendraujant tarpusavyje.

Vykdam mokymosi procesą nuotoliniu būdu kyla sunkumų vertinti įsitraukimą, nes nėra stipriai išreikšto neverbalinio grįžtamojo ryšio iš besimokančiųjų, ypač srautinėse paskaitose, kai yra išjungtos kameros ir paskaitų formatas nereikalauja besimokančiųjų sąveikos su turiniu ir (arba) dalyko dėstytoju.

Įsitraukimą galima vertinti įvairiais klausimynais, tačiau tai užtrunka daug laiko ir rezultatai gali būti subjektyvūs, dėl to, kad besimokančiųjų įsitraukimo suvokimas yra itin asmeniškasis ir gali būti sunkiai palyginamas. Egzistuojantys automatinio vertinimo įrankiai yra riboti – arba veikia tik specifinėse mokymosi aplinkose, arba duomenis renka tik iš vieno šaltinio.

Nesekant mokymosi proceso dalyvių įsitraukimo duomenų, įsitraukimo rodikliai tik netiesiogiai gali atsispindėti tokiuose formaliuose rodikliuose, kaip paskaitų lankomumas, darbų pateikimo savalaikiškumas ir (arba) kurso įverčiai, tačiau vien iš šių duomenų negalima identifikuoti žemo įsitraukimo lygio priežasčių.

Automatizuotas įsitraukimo vertinimas ir stebėseną leistų rinkti objektyvius mokymosi proceso dalyvių įsitraukimo duomenis, kurie galėtų būti panaudojami mokymosi programų kokybės gerinimui.



1 pav. Darbo problematika

Šio darbo objektas – Automatizuotas besimokančiųjų įsitraukimo vertinimas nuotolinio mokymosi aplinkoje.

Darbo tikslas – palengvinti besimokančiųjų įsitraukimo vertinimo procesą sukuriant automatizuotą priemonę besimokančiųjų įsitraukimui vertinti. Tikslui pasiekti iškelti uždaviniai:

1. Atlikti besimokančiųjų įsitraukimo nuotolinio mokymosi kontekste literatūros analizę
2. Remiantis literatūra, identifikuoti metodus ir priemones automatizuotam besimokančiųjų įsitraukimo vertinimo realizavimui
3. Ištirti skirtingų DI metodų patikimumą įsitraukimo vertinimui
4. Suprojektuoti priemonę remiantis literatūra bei atliktu tyrimu, realizuoti suprojektuotą priemonę

Darbo produktas – įvesties ir veido išraiškos analizę taikanti priemonė besimokančiųjų įsitraukimui vertinti, paprastai naudojama tiek besimokantiejiems, tiek kursų dėstytojams.

1. Teorinė dalis

Šio darbo teorinė dalis susideda iš dviejų poskyrių.

Pirmasis apžvelgia įsitraukimo sąvoką, jos svarbą mokymosi procesui (tiek bendrai tiek virtualiajame mokymesi), antrajame apžvelgiami egzistuojantys įsitraukimo vertinimo sprendimai.

1.1. Įsitraukimo apibrėžimas ir svarba ugdymosi procese

Šiame poskyryje apžvelgiama įsitraukimo sąvoka ir jos svarba ugdymosi procese. Besimokančiųjų įsitraukimas į mokymosi procesą yra aktuali švietimo literatūros tema jau nuo XX a. 9 dešimtmečio. Pirminį susidomėjimą šia tema iš dalies nulėmė susirūpinimas dėl didelio mokymosi procesą nutraukiančių asmenų skaičiaus ir statistika, rodanti, kad nuo 25% iki 60% besimokančiųjų mokymosi procesas atrodo bukinantis ir (arba) nuobodus [1,2]. Tam, kad būtų galima detaliau tirti šią temą, yra būtina išanalizuoti ir palyginti mokslinėje literatūroje pateiktus besimokančiųjų įsitraukimo apibrėžimus.

1.1.1. Įsitraukimo apibrėžimas mokslinėje literatūroje

Axelson'as ir Flick'as [3] pateikia kelis skirtingus įsitraukimo apibrėžimus, pradedant istorine perspektyva, kai senojoje anglų kalboje kalbant apie įsitraukimą (angl. *engagement*) omenyje buvo turima žemių užstatymas, o platesne prasme – moralinis, o dažnai ir teisinis įsipareigojimas, toliau pateikdami tokį įsitraukimo sąvokos apibrėžimą – įsitraukimas yra būsena arba veiksmas, kai visas dėmesys yra sutelktas į vieną objektą, buvimas čia ir dabar.

Wolf-Wendel ir kiti [4] visų pirma pabrėžia, kad reikia skirti tris atskiras sąvokas – dalyvavimą (angl. *involvement*), įsitraukimą (angl. *engagement*) ir integraciją.

Astin'as [4, 5] dalyvavimą apibrėžia kaip fizinės ir psichologinės energijos kiekį, kurį studentas skiria savo akademinėi patirčiai. Šis dalyvavimas gali būti tiek akademinis, tiek socialinis. Paprastai dalyvavimo sąvoka yra naudojama tyrimuose, kuriuose taikomas įvesties – aplinkos – išvesties modelis, kuris naudojamas identifikuoti dalyvavimo įvairaus pobūdžio akademinėje ir socialinėje veikloje įtaką mokymosi procesui.

Wolf-Wendel ir kiti [4] pateikia tokį įsitraukimo sąvokos apibrėžimą: įsitraukimas apibrėžia, kiek laiko ir pastangų besimokantieji skiria savo studijoms ir kitoms veikloms, kurios tiesiogiai lemia įgytą patirtį ir rezultatus. Aukštas besimokančiųjų įsitraukimo laipsnis yra susijęs su įvairiomis švietimo praktikomis ir sąlygomis, tokiomis kaip tikslingas studentų ir dėstytojų kontaktas, aktyvus ir bendradarbiavimą skatinantis mokymąsi. Autoriai prieina prie išvados, kad besimokančiųjų įsitraukimas nėra tiesiog dalyvavimo išdava ar plėtinys, o labiau - įrankis, leidžiantis aiškiau susieti studentų elgseną ir efektyvias švietimo praktikas. Įsitraukimas skiriasi nuo dalyvavimo tuo, kad jis yra labiau susijęs su norimais ugdymo procesais ir rezultatais, ir pabrėžia veiksmus, kurių institucija gali imtis, kad padidintų studentų įsitraukimą.

Integracijos sąvoka naudojama paaiškinti, koku mastu studentų požiūris bei įsitikinimai dera su kolegų ir dėstytojų požiūriais ir įsitikinimais bei koku mastu studentai laikosi institucijos struktūrinių taisyklių ir reikalavimų - institucinės kultūros [4]. Akademinės ir socialinės integracijos teoriją sukūrė Tinto [4,6], ieškodamas priežasčių, kurios galėtų paaiškinti savanorišką studentų pasitraukimą iš akademinėjų institucijų.

Šie apibrėžimai yra gana platūs ir teoriniai, kituose literatūros šaltiniuose pateikiama taksonominė įsitraukimo klasifikacija, kuri yra paprasčiau taikoma. Whitehill'as ir kiti [1], remdamiesi Fredricks ir kt. [7] bei Anderson ir kt. [8] apibrėžia įsitraukimą išskirdami 3 esminius įsitraukimo potipius – elgsenos, emocinį ir kognityvinį:

- Elgsenos įsitraukimas apibūdina besimokančiųjų polinkį dalyvauti mokymosi procese. Tai apima paskaitų lankymą, nenukrypimą nuo užduoties, savalaikį darbų atsiskaitymą ir gebėjimą vadovautis dėstytojo nurodymais.
- Emocinis įsitraukimas apibūdina emocinį požiūrį ir (arba) afektyvią būklę mokymosi proceso atžvilgiu. Skirtumą tarp elgsenos ir emocinio potipių galima iliustruoti pavyzdžiu – besimokantysis gali lankyti paskaitas reguliariai, tačiau jose nuobodžiauti ir (arba) nemėgti dėstomo dalyko. Toks besimokantysis pasižymėtu aukštu elgsenos įsitraukimu, tačiau žemu emociniu.
- Kognityvinis įsitraukimas apibūdina mokymosi proceso pajėgumą išnaudoti ir patenkinti besimokančiojo kognityvinius gebėjimus, tokius kaip dėmesio sutelkimas, atminties panaudojimas bei kūrybinis mąstymas.

Šio darbo kontekste įsitraukimo sąvoka, atsižvelgiant į tyrimo sritį, bus vartojama pagal Whitehill'o ir kt. [1] pateiktą apibrėžimą – įsitraukimas yra besimokančiojo savybė, mokymosi proceso metu parodanti besimokančiojo polinkį dalyvauti mokymosi procese (kitais tariant, motyvaciją mokytis), atskleidžianti jo emocinį požiūrį į mokymosi procesą ir kognityvinių gebėjimų naudojimą.

1.1.2. Įsitraukimo svarba mokymesi

Daugelyje analizuotų šaltinių įsitraukimo svarba pabrėžiama jau įvadiniuose sakiniuose. Visgi, yra svarbu ne tik konstatuoti, jog įsitraukimas yra svarbus mokymosi proceso elementas, bet kiekybiškai ir kokybiškai identifikuoti įsitraukimo naudą.

Lane ir Harris [9], tirdami įsitraukimo svarbą srautinėse paskaitose per konstruktyvizmo prizmę, konstatuoja, kad studentai geriausiai mokosi aktyviai įsitraukę, kai gali giliai įsisavinti medžiagą.

Srautinių paskaitų metu studentai labiau linkę į anonimiškumą ir blaškymąsi, kas daro neigiamą įtaką įsitraukimui. Taip pat, studentams gali būti sunku susikaupti ilgesnį laiką truncančiose tradicinėse paskaitose, kai jie yra pasyvaus mokymosi režime, t. y. tiesiog klauso skaitomos paskaitos. Kai studentai nustoja kreipti dėmesį į kurso turinį, jie nesugeba susikurti žinių, kurios padėtų įsisavinti dėstomą dalyką. Dėl to dėstytojams ar instruktoriams, dirbantiems su didelėmis grupėmis yra svarbu identifikuoti, ką jie galėtų padaryti, kad labiau įtrauktų mokinius į mokymąsi. Kaip pavyzdį autoriai pateikia tiriamos grupės įsitraukimo lygio skirtumą, kai paskaita yra dėstoma tradiciniu, didaktiniu būdu ir kai paskaita dėstoma to paties lektoriaus, tačiau interaktyviai. Net jei lektorius gerai pasirengęs, vidutinis įsitraukimo lygis tradicinės paskaitos metu siekė 56-58 % (turima omenyje įsitraukusių į paskaitą studentų kiekis), tuo tarpu interaktyvios paskaitos įsitraukimas siekė 84-88%.

Ainley [10] teigia, kad jei mokymosi veiklos turinys susijęs su tuo, kas yra vertinama ir (arba) suvokiama, kad tai teikia malonumą, studentai pasirenka įsitraukimą ir dažnai siekia iš naujo įsitraukti, jei jiems suteikiama galimybė, įskaitant net ir tuos besimokančiuosius, kurie yra charakterizuojami kaip nepažangūs ar keliantys sunkumų

Lam'as ir kiti [11] konstatuoja, kad nors akademinėje bendruomenėje yra sutariama dėl studentų įsitraukimo svarbos ir tyrimų, identifikuojančių kaip gerinti įsitraukimo rodiklius, būtinybės, tačiau nėra bendro sutarimo dėl įsitraukimo konceptualizavimo ir išmatavimo. Visgi autoriai išskiria trumpo bei ilgo laikotarpio efektus, susijusius su įsitraukimu į mokymosi procesą. Trumpalaikėje perspektyvoje pagal įsitraukimo rodiklius gali būti numatomas besimokančiųjų mokymasis, jų rezultatai ir elgesys mokymosi aplinkoje. Ilgalaikėje perspektyvoje įsitraukimas siejamas su įvairiais rodikliais, tokiais kaip akademiniai pasiekimai, savigarba ir socialiai tinkamas elgesys.

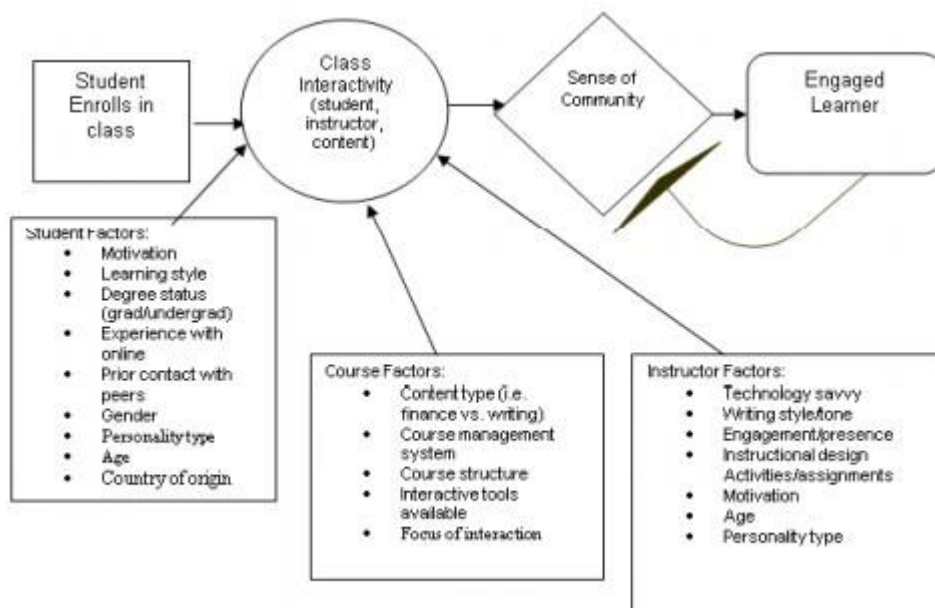
Galima apibendrinti, kad besimokančiųjų įsitraukimas yra svarbus efektyviam žinių įgyjimui, pasitenkinimui mokymosi procesu, akademiniam rezultatams ir net besimokančiojo savigarbai bei elgesiui.

1.1.3. Įsitraukimo vaidmuo virtualiajame ir nuotoliniame mokymesi

Martin ir Bolliger [12] teigia, kad studentų įsitraukimo skatinimas didina studentų pasitenkinimą, didina studentų motyvaciją mokytis, mažina atskirties jausmą ir pagerina studentų rezultatus. Autoriai taip pat konstatuoja, kad studentų įsitraukimas nuotoliniame mokymesi yra labai svarbus, nes besimokantieji nuotoliniu būdu turi mažiau galimybių lengvai bendrauti su institucija, dėstytojais ir kolegomis. Dėl to yra labai svarbu sudaryti sąlygas studentų įsitraukimui nuotolinio mokymosi aplinkoje. Autoriai apžvegia įsitraukimo strategijas, skirtas suteikti teigiamą patirtį besimokantiems, įskaitant aktyvaus mokymosi galimybes (pavyzdžiui, bendradarbiaujant atliekant grupinius darbus), įgalinant studentus moderuoti ir (arba) pristatyti pranešimus ir diskusijas, aktyviai dalytis ištekliais, kurti kursų užduotis su praktiniais komponentais ir integruoti atvejų analizę bei refleksiją.

Banna ir kiti [13] teigia, kad kad įsitraukimas yra pagrindinis besimokančiųjų atskirties, studijų metimo, išlaikymo ir baigimo lygio nuotoliniame mokyme sprendimas. Autoriai taip pat pabrėžia studentų įsitraukimo į nuotolinį mokymąsi svarbą, nes, jų manymu, studentų įsitraukimas gali būti įrodytas kaip įdėtų pastangų kognityviniam tobulėjimui ir jų gebėjimo kurti žinias įrodymas, lemiantis aukštą studentų sėkmės lygį. Jei praeityje pagrindinis dėmesys buvo skiriamas turiniui, dabar įsitraukimas vaidina pagrindinį vaidmenį skatinant nuotolinį mokymąsi.

Lear ir kiti [14], aprašydami nuotolinio mokymosi aplinkos interaktyvumo ir bendruomenės procesų modelį, įsitraukimą koreliuoja su mokomojo kurso interaktyvumu bei bendruomenės jausmu (2 pav.).



2 pav. Lear NMA interaktyvumo ir bendruomenės procesų modelis

Svarbu pažymėti, kad įsitraukimo skatinimo strategijos, palaikančios sąveiką su dėstytojais, buvo labiau vertinamos nei strategijos, kuriomis siekiama palaikyti sąveiką su mokymosi medžiaga ir kitais besimokančiais. Dėstytojo buvimas yra labai svarbus besimokantiems nuotoliniu būdu. Jie nori žinoti, kad kažkas „iš kitos pusės“ kreipia dėmesį. Besimokantieji nori dėstytojų, kurie juos palaiko, klauso ir su jais bendrauja [12].

Iš atliktos analizės galime matyti, kad įsitraukimo duomenys gali teikti nešališką ir savalaikį grįžtamąjį ryšį instruktoriams ir kursų rengėjams bei turi potencialo būti panaudojami mokymo(si) praktikų ir metodų, kurie efektyviai įtraukia studentus, identifikavimui.

1.2. Egzistuojantys įsitraukimo vertinimo sprendimai

Whitehall'as [1] identifikuoja tris pagrindines įsitraukimo vertinimo priemonių kategorijas: savianalizės klausimynus, stebėtojų pildomus klausimynus bei automatinio vertinimo sistemas.

- **Savianalizės klausimynai** – tai klausimynai, kuriuose besimokantieji pažymi savo dėmesingumo, išsiblašymo, jaudulio ar nuobodulio lygį. Šių apklausų metu nereikia tiesiogiai klausti besimokančiųjų, kiek jie jaučiasi įsitraukę, tačiau jie gali padaryti išvadą apie paslėptą kintamąjį iš apklausos atsakymų, pavyzdžiui, naudojant veiksmių analizę. Pagrindinis savianalizės trūkumas – vertinimo subjektyvumas: besimokančiųjų suvokimas apie savo įsitraukimą gali skirtis, taip pat besimokantieji gali gėdytis rašyti, kad jie nesijaučia įsitraukę į kursą.
- **Stebėtojų pildomi klausimynai** – tai kitas klausimynų, skirtų įsitraukimui vertinti, tipas. Šiuo atveju, įsitraukimą vertina išoriniai stebėtojai (pavyzdžiui, dėstytojai). Vertinimui panaudojami kontroliniai klausimai, taip pat gali būti naudojami studentų atlikti darbai. Stebėtojai taip pat gali pildyti klausimynus pagal paskaitos įrašą.

Whitehall'as [1] taip pat teigia, kad klausimynai yra gana primityvi, nors ir naudinga, įsitraukimo vertinimo priemonė – juose pasigendama laiko sąvokos, t. y. nėra įvertinama, kaip vyksta įsitraukimo pokyčiai laiko atžvilgiu, juos pildyti užtrunka daug laiko, o tam tikri klausimai ne visada gali būti susiję su įsitraukimu, ypač tokie bendriniai kriterijai kaip „sėdi tyliai“, „elgiasi gerai“ ar „nevėluoja į užsiėmimus“ nes jie gali rodyti tiek įsitraukimą, tiek polinkį laikytis taisyklių.

Trečioji išskiriama kategorija yra **automatinio vertinimo sistemos**. Šią kategoriją autoriai skaido į tris sub-kategorijas:

- **Į intelektualiąsias mokymosi sistemas integruotos vertinimo sistemos** (angl. *engagement tracing*). Šių sistemų veikimas pagrįstas įvykių, kurie įvyksta vartotojui sprendžiant užduotis intelektualiojoje mokymosi sistemoje ir (arba) atliekant testus bei atsiskaitymus. Šiuos metodus dažniausiai sudaro dvi dedamosios – klausymo atsakymo laikas ir klausimo atsakymo tikslumas. Tikimybinės išvados gali būti naudojamos norint įvertinti, ar stebimi laiko / tikslumo modeliai labiau atitinka įsitraukusį ar neįsitraukusį studentą. Šių sistemų trūkumas yra tai, kad jos veikia ir gali vertinti įsitraukimą tik intelektualiosios mokymosi sistemos viduje.
- **Fiziologinius ir (arba) neurologinius jutiklius taikančios vertinimo sistemos**. Šių sistemų veiklos principas paremtas įvairių žmogaus kūno parametrų (smegenų elektrinio aktyvumo, kraujospūdžio, pulso, odos laidumo) matavimu ir analize. Tokios sistemos yra gana tikslios, tačiau joms reikia papildomos įrangos ir fizinio priėjimo.
- **Kompiuterinę regą taikančios vertinimo sistemos** yra paremtos kompiuterinės regos metodais, įgyvendinamais analizuojant įvairius požymius, dažniausiai taip pat naudojami mašininio mokymosi ar dirbtinio intelekto sprendimai. Šios sistemos gali būti naudojamos tiek veido išraiškai, tiek kūno laikysenai atpažinti. Pagrindiniai privalumai - kompiuterine rega paremti sprendimai leidžia įsitraukimą vertinti be papildomų trikdžių ugdymosi procesui bei nereikalauja papildomos įrangos. Bixler'is ir D'Mello [15] šį automatinių vertinimo sistemų tipą priskiria afektyvios būklės atpažinimo metodams, pabrėžia afektyviosios kompiuterijos svarbą ir šią kategoriją praplečia kitais modalumais – be veido išraiškos analizės, autoriai įvardija kalbos intonacijos analizę, teksto sentimentalumo analizę, žvilgsnio, gestikuliacijos analizę bei įvesties analizę.

Vyraujantis automatizuoto įsitraukimo vertinimo modalumas literatūroje yra veido išraiškos analizė, tačiau yra verta apžvelgti ir kitus modalumus, pavyzdžiui, įvesties analizę. Norint suprasti, kaip ir kodėl veido išraiškos analizė siejasi su įsitraukimu, verta apžvelgti neverbalinės kalbos sąvoką ir jos vaidmenį mokymosi procese, kaip ir mašininio mokymosi ir (arba) dirbtinio intelekto sprendimus, įgalinančius tiek veido išraiškos, tiek įvesties analizės automatizavimą ir atitinkamą sprendimų priėmimą.

1.3. Neverbalinė kalba ir jos vaidmuo mokymosi procese

Literatūroje galima rasti skirtingų neverbalinės kalbos apibrėžimų. Giri [16] pateikia tokį neverbalinės kalbos apibrėžimą: pranešimų ar signalų perdavimas per neverbalinę platformą, pvz., akių kontaktą, veido išraiškas, gestus, laikyseną ir atstumą tarp dviejų asmenų. Giri identifikuoja tokius požymius: kūno kalba (kinezika), atstumas (proksemika), bendraujančiųjų fizinė aplinka bei išvaizda, gretutiniai kalbos elementai (parakalba) ir lytėjimas (haptika). Mitkus [17] pateikia

bendresnį apibrėžimą, teigdamas, kad neverbalinės komunikacijos mokslas susideda iš dviejų pagrindinių atšakų. Pirmoji analizuoja vaizdinius neverbalinės kalbos aspektus, tokius kaip veido išraiška, gestai, rankų padėtis, kūno padėtis, antroji šaka tyrinėja parakalbą, kuri apima tokius aspektus, kaip kalbėjimo stiprumas, pauzės, kalbos greitis ir trukmė, tonas bei kitos savybės bei jų nešamą informaciją. Dėl darbo specifikos toliau darbe bus naudojamas ir analizuojamas Mitkaus naudojamas apibrėžimas, nes proksemikos bei haptikos analizė nuotolinio mokymosi kontekste yra už šio darbo ribų.

1.3.1. Vaizdiniai neverbalinės kalbos aspektai

Mokslas, tyrinėjantis vaizdinius neverbalinės aspektus, tiksliau – jų poaibį, susijusį su veido išraiška bei gestikulacija yra vadinamas kinezika. Kinezikos sąvoką pirmasis panaudojo antropologas Ray'us Birdwhistell'is [18], tirdamas, kaip žmonės komunikuoja tarpusavyje pasitelkdami laikyseną, stovėseną, kūno pozą bei gestikuliaciją. Ekman'as [19,20] padėjo pagrindus tolimesniam šio mokslo vystymuisi, sukurdamas ir aprašydamas empirinius neverbalinės kalbos matavimo būdus, daugiausiai dėmesio skirdamas emocijų nustatymui iš veido išraiškos.

Pasak Nikitinaitės ir kt. [21], stebėdamas besimokančiųjų bendravimą, dėstytojas gali nuspėti jų mąstymą, tuo metu išgyvenamas emocijas iš jų kūno kalbos. Taip pat konstatuojama, kad ryškiausiai emocijos pasireiškia per veido išraišką - gebėjimas veidu išreikšti stiprias emocijas leidžia be žodžių išreikšti mintį. Mokymosi procese dėstytojas, stebėdamas besimokančiųjų veido išraiškas, gali pagal jas interpretuoti, ar paskaitos turinys yra įdomus, aiškus bei suprantamas. Panaudojant šį grįžtamąjį ryšį, galima interaktyviai reaguoti į paskaitos situaciją, ieškoti būdų besimokančiųjų suaktyvinimui pagal poreikį ir efektyvinti mokymosi procesą. Lane ir Harris [9], remdamasis Blatchford ir kt. [22], Fenollar ir kt. [23] bei Young ir kt. [24], konstatuoja, kad neverbalinė kūno kalba ir mimika yra svarbios dedamosios mokymosi procesų dalyvių stebėsenai ir remiantis jomis galima identifikuoti besimokančiųjų įsitraukimo lygį, kuris tiesiogiai koreliuoja su jų pajėgumu išlaikyti dėmesį bei įsisavinti naują informaciją.

Veido išraišką ir jos ryšį su emocine būseną aprašančioje literatūroje empiriniam vertinimui naudojami trys skirtingi vertinimo metodai - kategorinis emocijų atpažinimas pagal pagrindines veido išraiškas, emocijų analizė pagal veido veiksmo vienetų aktyvumą, darant prielaidą, kad išraiškos intensyvumas yra universalus ir pastovus bei emocijų analizė, paremta afekto erdvės modeliu, kaip pagrindinius rodiklius išskiriant valentingumą ir sužadimą, o emocijas aprašant valentingumo ir sužadavimo reikšmių pora [25,26].

Kategorinis emocijų atpažinimas yra pati paprasčiausia empirinio vertinimo sistema, paremta pagrindinių emocijų išskyrimu. Ekman'o ir Friezen'o atlikti tyrimai rodo, kad šešios pagrindinės emocijos – pyktis, džiaugsmas, baimė, nuostaba, pasišlykštėjimas ir liūdesys – yra praktiškai universalios ir atpažįstamos vienodai daugelyje pasaulio kultūrų [19,27]. Paprastai veido išraiškos taip klasifikuojamos naudojant ekspertinį vertinimo metodą. Visgi, kadangi klasifikavimo skalė yra diskreti, kategorinis vertinimas nėra plačiai pritaikomas įsitraukimo analizei, nes veido išraiškos mokymosi procese dažnai yra prislopintos.



3 pav. Pagrindinės emocijos [19]

Siekant detalesnio ir tikslesnio veido išraiškos klasifikavimo, Ekman'as ir Friesen'as, remdamiesi švedų anatomo Karlo-Hermano Hjortsjo sukurta veido judesių taksonomijos sistema, savo tyrimuose pradėjo taikyti veido veiksmo vienetų kodavimo sistemą *FACS*[28], kuria galima užkoduoti beveik bet kurią anatomiškai įmanomą veido išraišką, išskaidant ją į specifinius veido veiksmo vienetus laiko ašyje.

Veido veiksmo vienetų išskyrimas *FACS* sistemoje yra paremtas specifinių veido raumenų ir (arba) jų grupių teigiamu arba neigiamu aktyvavimu, tai yra, įsitempimu arba atsipalaidavimu. Pavyzdžiui, naudojant *FACS* galima objektyviai įvertinti šypsenos tikrumą – netikra šypsena susideda tik iš 12 veido veiksmo vieneto (lūpos kampo tempiklio) aktyvavimo abiejose veido pusėse, šypsantis nuoširdžiai taip pat aktyvuojamas žiedinis akies raumuo, *FACS* sistemoje išreiškiamas 6 veido vieneto aktyvacija[28].

Kadangi veido veiksmo vienetai yra pakankamai objektyvūs, jie gali būti naudojami įvairiuose sprendimų priėmimo procesuose, tokiuose kaip pagrindinių emocijų atpažinimas, arba intelektualių aplinkų valdymui[29,30,31].

Remiantis *FACS*, Du ir Martinez'as emocinių būklių, identifikuojamų iš veido išraiškos skalę praplėtė iki septyniolikos universalių emocijų – be šešių pagrindinių emocijų taip pat identifikuotos tokios emocijos kaip pakraupimas, pagarba, neapykanta, bei įvairios sudėtinės emocijos, susidedančios iš kelių pagrindinių emocijų, pasireiškiančių vienu metu – pavyzdžiui, nuostaba, be bazinės raiškos, taip pat gali būti džiugi, liūdna, pikta, su pasišlykštėjimu [32].



4 pav. Sudėtinės emocijos


Tolimesnė emocijų empirinio vertinimo iš veido išraiškos raida vystosi panašiu principu, kaip ir šuolis nuo bazinių emocijų klasifikacijos iki *FACS* taksonominės sistemos – diskreti emocijų skalė yra transformuojama į emocinės būklės erdvę, paskira emocinė išraiška yra paverčiama tašku, kurio koordinatės parodo valentingumo ir sužadavimo vertes. Šį modelį, vadinamą afekto erdvės modeliu, XX a. viduryje pasiūlė Schlosberg‘as[33], o vėliau išplėtojo Russel‘as [34] ir Lang‘as[35].

Schlosberg‘o pasiūlytas modelis teigia, kad pagrindinę afektinės patirties struktūrą galima apibūdinti kaip afektinių būsenų išdėstymą apskritimo formos erdvėje. Modelio autorius teigia, kad bet kurių dviejų afektinių būsenų panašumas priklauso nuo jų atstumo vienas nuo kito apskritimo perimetre, o bet kokių dviejų būsenų skirtumai didėja didėjant atstumui tarp jų apskritime[33]. Russel‘as, o vėliau ir Larsen‘as bei Diener‘is, formalizavo šį modelį, kaip susidedantį iš valentingumo ir sužadavimo ašių [34,36]. Lang‘as modelį praplėtė, pridėdamas kategorinį sluoksnį, susijusį su valentingumo ir sužadavimo verčių ženklais [35].

Sužadinimas (kitai – intensyvumas) yra apibrėžiamas, kaip dirgiklio arba įvykio sukuriamas autonominės aktyvacijos lygis, kurio ribinės vertės yra ramumas (žemo lygio sužadinimas) ir susijaudinimas (aukšto lygio sužadinimas). [34,35,36]

Valentingumas yra aprašomas, kaip malonumo, kurį sukuria dirgiklis ar įvykis, lygis, apibrėžiamas neigiama (nemalonu) – teigiama (malonu) verčių kontinuumu. [34,35,36]

Aukštas sužadavimo lygis ir teigiamas valentingumas yra stebimas teigiamų emocijų, tokių kaip džiaugsmas, pasitenkinimas, išraiškoje, aukštas sužadinimas ir neigiamas valentingumas reprezentuoja stiprias neigiamas emocijas, tokias kaip nerimas, baimė, pyktis ar frustracija. Analogiškai, žemas sužadavimo lygmuo ir teigiamas valentingumas atspindi atsipalaidavimą, ramybę, ir mažėjant valentingumo reikšmei pereina į tokias būkles, kaip mieguistumas, nuovargis, nuobodulys ar liūdesys. [34,35,36,37]



5 pav. Dvimatis sužadavimo – valentingumo modelis

Kiekvienas iš šių modelių turi panaudojimo sričių, bet įsitraukimo vertinimui tikslingiausia naudoti Lang'o praplėstos afekto erdvės modelį, nes iš emocijų aibės jis aiškiai apibrėžia kvadrantus, kurie rodo įsitraukimo lygį nepriklausomai nuo emocinės išraiškos stiprumo ir gali jautriau aptikti įsitraukimo kategoriją.

1.3.2. Parakalba

Schuller'is ir kt. [38], remdamiesi Crystal'o [39] ir Abercrombie'io [40] darbais, parakalbą bei mokslą, tiriantį parakalbą - paralingvistiką, apibrėžia, kaip visus garsinius elementus kalboje, kurie neneša tiesioginės informacijos, bet yra įmoduliuojami ar įterpiami į kalbinę žinutę, nesvarbu, ar tai akustiniai, ar lingvistiniai elementai. Visgi, Crystal ir Abercrombie'io darbai buvo rašyti XX a. 7-8 dešimtmečiais, kai sinchroninė tekstinė komunikacija dar buvo tik ankstyvoje stadijoje ir nebuvo plačiai išplitusi. Schandorf'as [41] teigia, kad paralingvistiniai požymiai egzistuoja ne vien šnekamosios kalbos ribose, tačiau ir sinchroniniame ar artimam sinchroniniui bendravime tekstu, naudojant kompiuterines ryšio priemones (mobiliuosius įrenginius, įvairias pokalbių programas ir programėles). Solanky ir Shukla [42] paralingvistinius požymius, leidžiančius nuspėti tiriamojo subjekto emocinę būseną identifikuoja iš spausdinimo klaviatūra dinaminųjų parametrų, tokių kaip klavišo nuspaudimo trukmė, laikas tarp dviejų nuoseklių klavišų paspaudimų, klaidų taisymo (*Backspace* ir *Delete* klavišų paspaudimo dažnis). Panašius tyrimus atliko ir Epp'as ir kt. [43], parodydami, kad egzistuoja koreliacija tarp šių požymių ir emocijų raiškos.

1.3.3. Afektyvioji kompiuterija

Epp'as ir kt. [43] afektyviają kompiuteriją apibrėžia, kaip „kompiuteriją, susijusią su emocijomis, kylančias iš jų arba tiesiogiai turinčias įtakos emocijoms“. Kadangi emocijų raiška yra tiesiogiai susijusi su įsitraukimo požymiais, galima teigti, kad identifikavus emocijas, susijusias su įsitraukimo išraiška, būtų galima nuspėti įsitraukimo lygį. Afektyvioji kompiuterija bando priskirti kompiuteriams panašias į žmogų stebėjimo, interpretavimo ir afekto funkcijų generavimo galimybes. Tai yra svarbi harmoningos žmogaus ir kompiuterio sąveikos tema, kuria siekiama vystyti žmogaus ir kompiuterio bendravimo kokybę. Afektyvioji kompiuterija paremta „afekto modelių“, pagrįstų įvairia jutiklių užfiksuota informacija, naudojimu įgyvendinant personalizuotą sistemą, galinčią suvokti, interpretuoti žmogaus jausmus, taip pat suteikti protingus, jautrius ir draugiškus atsakymus. [44]. Įsitraukimo vertinimas yra viena iš afektyviosios kompiuterijos taikymo sričių.

1.4. Skyriaus išvados

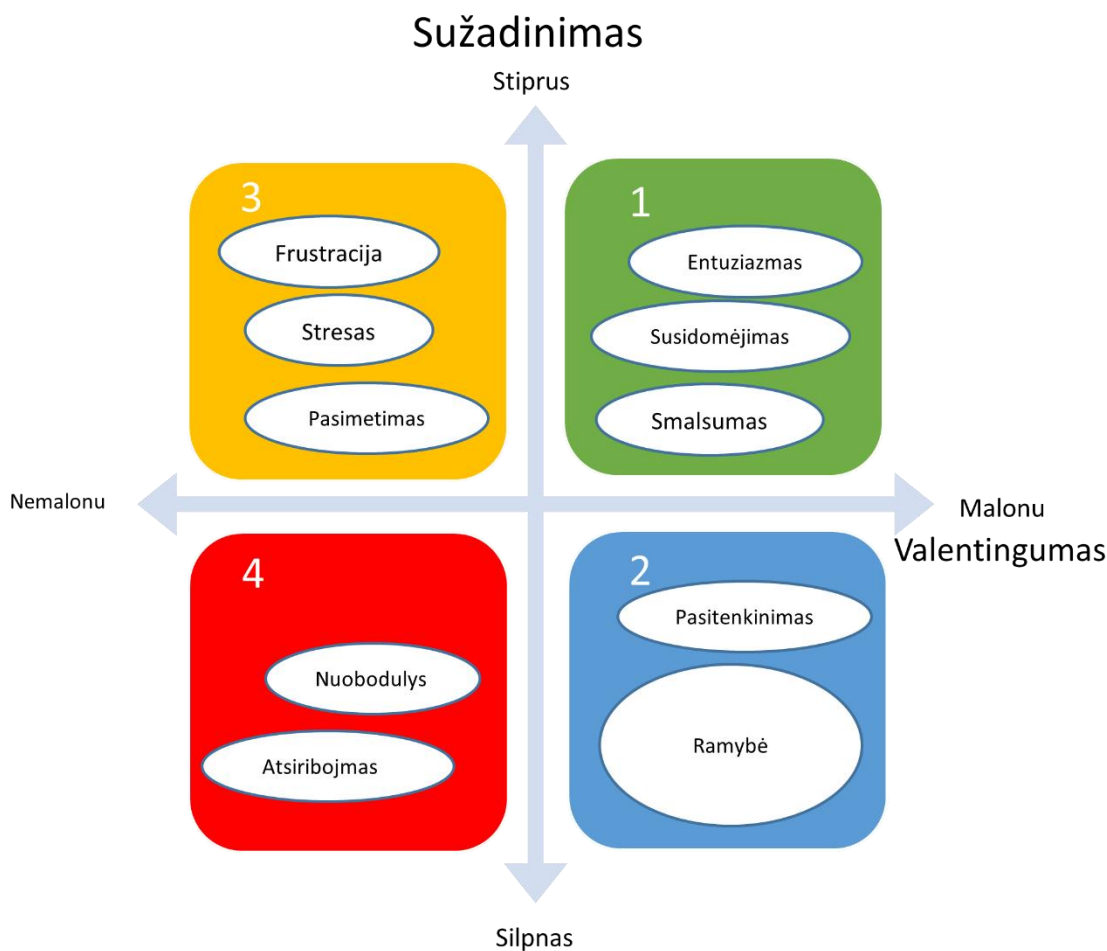
1. Įsitraukimas yra apibrėžiamas, kaip besimokančiojo savybė, mokymosi proceso metu parodanti besimokančiojo polinkį dalyvauti mokymosi procese.
2. Įsitraukimas yra svarbus grįžtamojo ryšio elementas mokymosi procese, nes indikuoja besimokančiųjų dėmesį ir motyvaciją.
3. Kadangi įsitraukimas dažnai indikuojamas per neverbalinę kalbą, nuotolinio mokymosi aplinkose gali būti sunku vertinti įsitraukimą.
4. Įsitraukimo duomenys gali būti panaudojami mokymo(si) praktikų ir metodų, kurie efektyviai įtraukia studentus, identifikavimui.
5. Įsitraukimo vertinimui tikslinga naudoti vartotojo biometrinius duomenis – veido išraišką bei klaviatūros įvestį.

2. Metodologinė dalis

Šioje darbo dalyje aprašoma metodika įsitraukimo nustatymui. Dalis susideda iš įsitraukimo modelio aprašo, veidų aptikimo metodų palyginimo, veido išraiškų atpažinimo metodų apžvalgos, atliekamas veido išraiškos analizės taikymo su skirtingais mašininiais mokymais ar dirbtinio intelekto metodais paremtais algoritmais tyrimas, taip pat apžvelgiami įvesties analizės principai bei metodai, atliekamas įvesties analizės taikymo su skirtingais mašininiais mokymais ar dirbtinio intelekto metodais paremtais algoritmais tyrimas, pateikiamos išvados.

2.1. Įsitraukimo vertinimo modelis

Pagal atliktą literatūros analizę ir prieinamus duomenis, įsitraukimo vertinimui pasirinkta naudoti kategorinį modelį, paremtą valentingumo ir sužadavimo reikšmių ženklais. Šį modelį motyvacijos ir dėmesio klasifikavimui pasiūlė Lang'as[35], vėliau modelį pritaikė Chaouachi's ir kt. [45], naudodami jį emocinių būklių nustatymui remiantis biofiziologiniais duomenimis, tokiais kaip pulso dažnis ar smegenų elektrinis aktyvumas.



6 pav. Kategorinis įsitraukimo vertinimo modelis

Siekiant taikyti šį modelį naudojant veido išraiškos ir įvesties analizę, būtina apžvelgti veido išraiškos bei įvesties analizių metodologiją – veidų aptikimą ir išraiškos požymių nustatymą, įvesties analizės principus bei požymių išskyrimą, atlikti tyrimą metodų ir požymių pritaikomumui problemai spręsti.

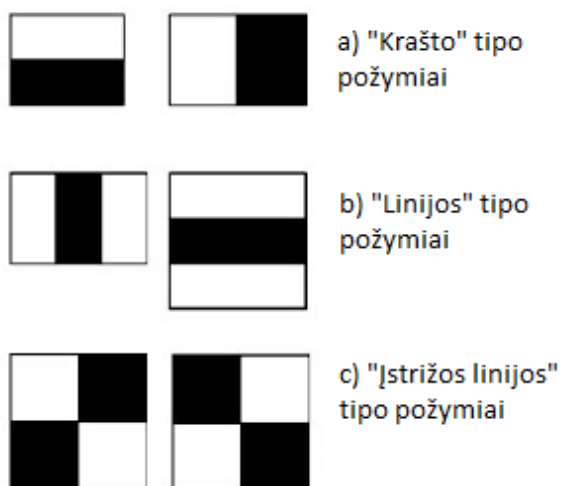
2.2. Veidų aptikimo metodai

Žmogaus veidas yra itin sudėtinga ir dinamiška struktūra, kuri yra vienas iš pagrindinių socialinių santykių elementų ir vaidina svarbų vaidmenį perduodant emocijas.[] Norint atpažinti emociją iš atvaizdo, pirmasis uždavinys yra vaizdo elemente aptikti veido regioną. Dėl aplinkos faktorių, pavyzdžiui, skirtingo apšvietimo, įvairaus fono, kūno bei galvos padėties vaizdo kameros atžvilgiu, atvaizdo raiškos, programatinis žmogaus veido aptikimas išlieka iššūkiu. Šiame poskyryje apžvelgiami įvairiais algoritmais paremti veidų aptikimo metodai, atliekamas jų palyginimas.

2.2.1. Haar'o klasifikatorių kaskada (Viola-Jones'o metodas)

Objektų aptikimo metodą naudojant Haar požymiais paremtas klasifikatorių kaskadas pasiūlė Viola ir Jones'as [46]. Metodo veikimas yra paremtas specifinių požymių, vadinamų Haar'o požymiais, išskyrimu veido elementų atpažinimui.

Haar'o požymis yra vertė, gaunama atimant visų taškų, esančių baltame stačiakampyje, sumą iš visų taškų, esančių juodame stačiakampyje, sumos. Šie požymiai gali būti trijų tipų – iš dviejų stačiakampių susidedantis „krašto“ požymis, iš trijų stačiakampių susidedantis „linijos“ požymis ir iš keturių stačiakampių susidedantis „įstrižos linijos“ požymis.[47]



7 pav. Tipiniai Haar'o požymiai

Haar'o požymių apskaičiavimas, įvertinant tai, kad požymiai gali būti įvairaus dydžio ir įvairiai išdėstyti vaizde yra pakankamai reiklus skaičiavimui – pasirinkus 24x24 pikselių tiriamąjį langą, jame egzistuoja virš 160000 požymių.[46]

Haar'o požymių apskaičiavimui optimizuoti Viola ir Jones'as[46] įveda „integraliojo vaizdinio“ sąvoką (angl. *integral image*), kuri įvesties vaizdo, reprezentuojamo dvimate nespaltotų pikselių matrica, elementui (x, y) apibrėžiama, kaip visų matricos elementų, kurių indeksai yra mažesni arba lygūs x ir y , suma,

$$ii(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y')$$

kur ii yra integralusis vaizdinys, o i – įvesties vaizdas. Panaudojant rekurentines lygtis

$$\begin{aligned}s(x, y) &= s(x, y - 1) + i(x, y) \\ ii(x, y) &= ii(x - 1, y) + s(x, y)\end{aligned}$$

kur $s(x, y)$ yra nuosekli eilučių suma, $s(x, -1) = 0$ ir $ii(-1, y) = 0$, integralusis vaizdas gali būti apskaičiuojamas vieną kartą iteruojant per matricą.

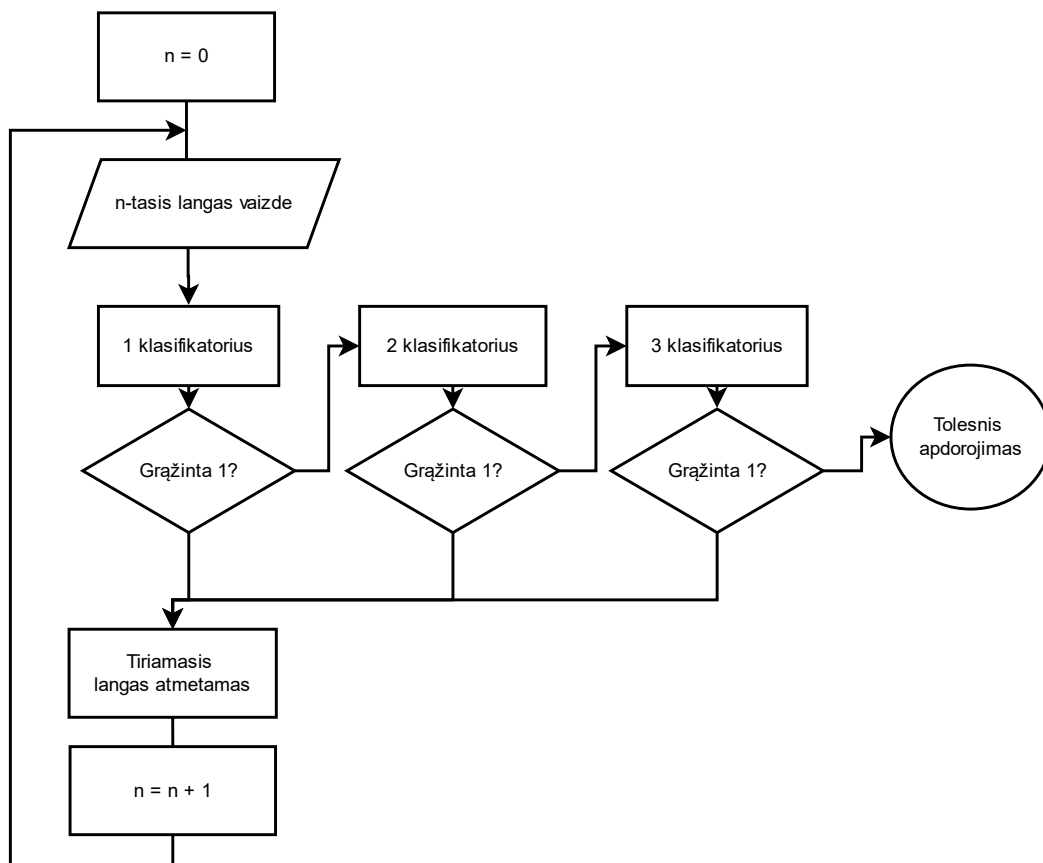
Pritaikius integraliojo vaizdinio principą, dviejų stačiakampių tipo („krašto“) Haar‘o požymio apskaičiavimui užtenka panaudoti šešių kampinių taškų integraliojo vaizdinio reikšmes (analogiškai, 8 taškų reikšmes trijų stačiakampių tipo Haar‘o požymiui ir 9 taškų reikšmes keturių stačiakampių požymiui), nepriklausomai nuo vaizdo dydžio.[46]

Nors kiekvienas požymis apskaičiuojamas efektyviai, pilnos požymių aibės skaičiavimas yra brangus. Kiekviename vaizdo lange gali būti daugiau nei 180 000 stačiakampių požymių, ir šis skaičius yra daug didesnis nei taškų skaičius lange. Požymių atrinkimui šiame metode yra naudojamas *AdaBoost* meta-algoritmas, apjungiantis j paprastųjų klasifikatorių $h_j(x)$, aprašomų sistema

$$h_j(x) = \begin{cases} 1 & \text{jei } p_j f_j(x) < p_j \theta_j \\ 0 & \text{kitais atvejais} \end{cases}$$


kur f_j – tiramasis bruožas, θ_j – slenkstinė klaidos vertė, p_j – pariteto operatorius, į subendrintą klasifikatorių. Kiekvienas paprastasis klasifikatorius yra apribotas naudoti tik vieną požymį iš visos požymių aibės. *AdaBoost* meta-algoritmas identifikuoja mažiausią klaidą turinčius paprastuosius klasifikatorius, priskiria jiems svertines reikšmes ir iš jų svertinės sumos yra išvedamas stiprusis klasifikatorius. Metodo autoriai teigia, kad tokiu būdu išgautas frontalinis klasifikatorius veidus aptinka 95% tikslumu, tačiau pripažįsta, kad toks tikslumo lygis nėra pakankamas praktiniam pritaikymui, ir susiduria su problema – norint išgauti didesnę tikslumą, tektų didinti klasifikatoriaus požymių skaičių, kas pailgintų skaičiavimo laiką. Kita autorių identifikuota problema – didžioji dalis informacijos tiriamame vaizde nėra veidai ir jos nebūtina tirti.[46]

Šios problemos Viola ir Jones‘o metodas išvengia, vietoje didelio sudėtingumo klasifikatorių panaudodami klasifikatorių grandines, susidedančias iš didėjančio kompleksiško klasifikatorių – klasifikatorių kaskadas, paremtas degeneratyviojo sprendinių medžio (angl. *degenerate decision tree*) principu. Teigiamas pirmojo klasifikatoriaus rezultatas aktyvuoja antrąjį klasifikatorių, teigiamas antrojo klasifikatoriaus rezultatas aktyvuoja trečiąjį klasifikatorių, ir taip toliau. Bet kurio klasifikatoriaus nulinis rezultatas sukelia tiriamojo lango atmetimą. Apmokius pirminius klasifikatorius minimizuojant II tipo klaidas, didžioji dalis vaizdo langų, nenešančių norimos informacijos, gali būti atmetama pirmuosiuose kaskados etapuose.[46]



8 pav. Klasifikatorių grandinės schema

Autoriai pabrėžia, kad pirminiai klasifikatoriai, atrinkti iš klasifikatorių aibės pasitelkiant *AdaBoost* yra prasmingi ir lengvai interpretuojami – pirmasis požymis matuoja intensyvumo tarp akių ir skruostikaulių sričių skirtumą, antrasis lygina akių sričių intensyvumą su nosikaulio sritimi.



9 pav. Pirminiai Haar'o klasifikatoriai

2.2.2. Orientuotų gradientų histogramos metodas



10 pav. Orientuotų gradientų histogramos vizualizacija

Orientuotų gradientų histograma (angl. *Histogram of Oriented Gradients*, sutrumpintai HOG) yra požymių deskriptorius, naudojamas objektų aptikimui kompiuterinės regos ir vaizdų apdorojimo uždaviniuose. Šį modelį sukūrė McConnell'as[48], tačiau plačiau modelis pradėtas naudoti Dalal ir Triggs [49], kurie ieškojo tikslesnio objektų atpažinimo metodo testavimui naudojant tiesinę atraminių vektorių mašiną (angl. *linear SVM*). Pradžioje modelis naudotas pėsčiųjų siluetsams atpažinti. Dalal-Triggs modelis naudoja pastovaus dydžio slenkantį langą, sudarytą iš 16x16 pikselių normalizuotų orientuotų gradientų histogramų (HOG) bloką.

Algoritmas susideda iš penkių žingsnių:

1. Vaizdo normalizavimas. Šiame etape taikomas globalus vaizdo normalizavimas, skirtas sumažinti apšvietimo efektų įtaką. Dažniausiai naudojamas gama suspaudimas, skaičiuojant kvadratinę šaknį arba logaritmą kiekvienos spalvos kanalams. Vaizdo tekstūros stiprumas

paprastai yra proporcingas vietiniam paviršiaus apšvietimui, todėl šis suspaudimas padeda sumažinti vietinių šešėlių ir apšvietimo variacijos poveikį.

2. Gradiento apskaičiavimas. Šiame etape apskaičiuojamas pirmosios eilės vaizdo gradientas. Tai atliekant, užfiksuojami pagrindiniai kontūrai, siluetai ir tekstūros informacija, tuo pačiu užtikrinant dar didesnę atsparumą apšvietimo kitimams. Gradientas apskaičiuojamas atliekant pradinio vaizdo konvoliuciją su vienmačiu diskrečiu branduoliu X ir Y ašyse.



11 pav. Vaizdo gradientai X ir Y ašyse

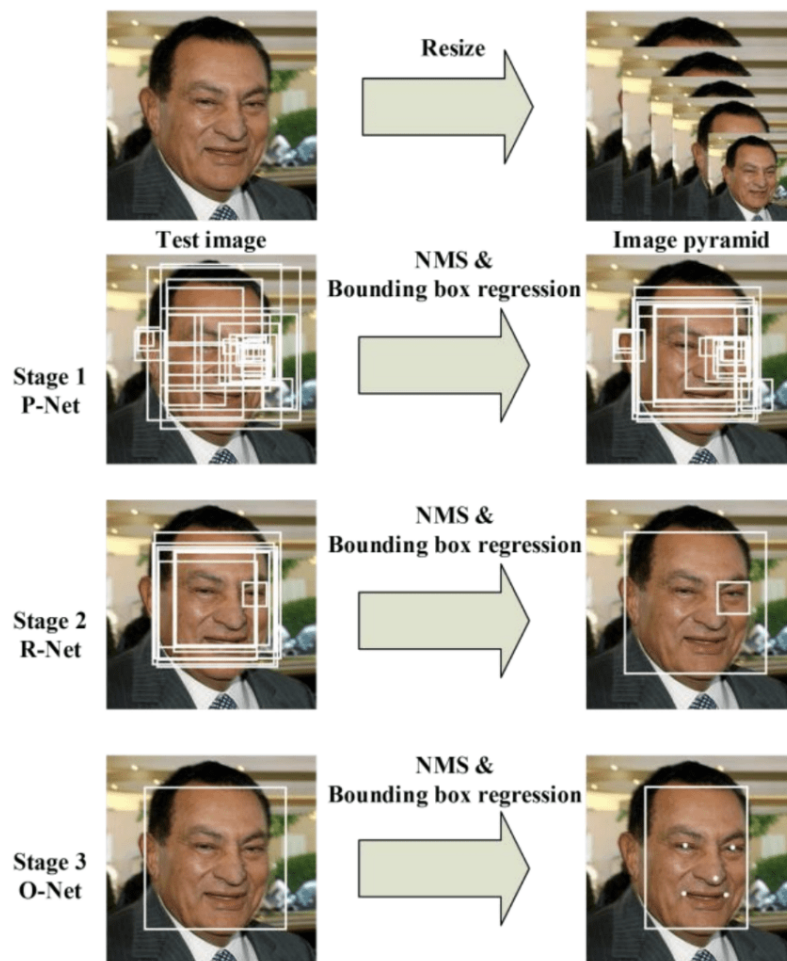
3. Blokų histogramų generavimas. Kiekvienam bloko pikseliui yra apskaičiuojamas gradiento stiprumas (pikselyje vertė yra lyginama su aplinkinių pikselių vertėmis) ir pagal vyraujančią kryptį bloke sugeneruojama orientacijos histograma. orientuota gradiento histograma gradiento kampo intervalą sudalina į iš anksto nustatytų diapazonų skaičių (Dalal'o ir Triggs'o tyrimai rodo, kad devyni intervalai yra pakankami žmogaus silueto atpažinimui [49]).
4. Blokų grupių normalizavimas. Siekiant sumažinti pašalinių faktorių, pavyzdžiui, netolygaus apšvietimo, įtaką blokai gali būti grupuojami, grupėms apskaičiuojama vietinė histogramos energija ir gauta reikšmė naudojama bloko normalizavimui.
5. Požymių vektoriaus suformavimas. Blokų arba blokų grupių histogramos apjungiamos į požymių vektorių.

Veido regiono aptikimui, gautas orientuotų gradientų vektorių perduodamas klasifikavimo algoritmui, pavyzdžiui, atraminių vektorių klasifikatoriui [50,51], apmokytam su tipinėmis veidų regionų orientuotų gradientų histogramomis.

2.2.3. Giliaisiais neuroniniais tinklais paremtas veidų atpažinimas

Zhang'as ir kt. [52] veido regionų išskyrimui pasiūlė naudoti konvoliucinių neuroninių tinklų modelių sistemą. Sistema susideda iš trijų modelių kaskados ir pirminio duomenų apdorojimo žingsnio:

1. Vaizdų piramidės suformavimas. Algoritmas iš pradinio vaizdo, keičiant jo mastelį apibrėžtame režyje, suformuoja skirtingos raiškos vaizdų, paremtų įvesties vaizdu, masyvą.
2. Vaizdų piramidė perduodama pirmajam modeliui, vadinamam „pasiūlymų tinklu“, kuris identifikuoja potencialius veidų regionus.
3. Aptikti veidų regionai perduodami antrajam modeliui („išgryninimo tinklui“), kuris detaliau ištiria potencialius regionus ir atmeta regionus, kuriuose neranda veidų bei persidengiančius regionus.
4. Antrojo modelio rezultatai perduodami trečiajam modeliui („išvesties tinklui“), kuris aptinka specifinius veido taškus.



12 pav. Zhang'o ir kt. modelio schema[]

Šie trys modeliai nėra tiesiogiai sujungti - kiekvieno modelio išvestis yra įvestis po jo sekančiam modeliui. Tai leidžia atlikti papildomą apdorojimą tarp etapų – pavyzdžiui, ne-maksimumų slopinimo algoritmas gali būti naudojamas filtruoti potencialius regionus, išskirtus „pasiūlymų tinklo“, prieš pateikiant juos „išgryninimo tinklui“.


2.3. Veido išraiškų atpažinimo metodai

Iš vaizdo šaltinio išskyrus veidą, tolimesnis (ir sudėtingesnis) uždavinys yra identifikuoti veide atsispindinčią emociją – pagrindinis kriterijus yra veido išraiška. Veido išraiškos atpažinimo

uždaviniai iš esmės yra veidų atpažinimo uždavinių plėtinys – naudojami panašūs metodai, tačiau skiriasi uždavinio tikslas – veidų atpažinimo algoritmų paskirtis yra identifikuoti tiriamo regiono panašumą su jau žinomais veidų regionais, o veido išraiškos atpažinimas reikalauja sudėtingesnių lyginamųjų procesų. Bendriniai veidų atpažinimo algoritmai sieka atmesti veido išraiškos įtaką atpažinimui, nes to paties žmogaus veidas, užfiksuotas su skirtinga veido išraiška, gali nebūti atpažįstamas, kaip tas pats veidas[53].

Veido išraiškos atpažinimui galima naudoti visą veido regioną, tačiau, siekiant sumažinti skaičiavimo intensyvumą, dažniausiai iš veido išskiriami specifiniai požymiai – pavyzdžiui, specifinių veido taškų ir (arba) regionų koordinatės, bei išvestiniai požymiai, tokie kaip regiono forma arba dydis, kurie naudojami kartu su klasifikavimo algoritmais siekiant išskirti veido išraiškas. Siekiant sumažinti duomenų dimensiškumą, tiek prieš, tiek po požymių išskyrimo gali būti taikoma pagrindinių komponentų analizė[54,55]. Literatūroje identifikuoti sprendimai, paremti įvairiais klasifikavimo algoritmais – tiek aiškiai apibrėžtais mašininio mokymosi algoritmais, tiek sprendimais, paremtais neuroniniais tinklais.

2.3.1. Tikrinių veidų metodas



13 pav. Tikrinių veidų pavyzdžiai iš AT&T duomenų bazės tikrinių veidų rinkinio

Vienas pirmųjų metodų požymiams išskirti – tikrinių veidų metodas[56]. Metodas yra paremtas pagrindinių dedamųjų analize – tikriniai veidai yra apibrėžiami kaip pagrindiniai veidų skirstinio požymiai arba kaip tikriniai veidų aibės kovariacijų matricos vektoriai, kur $x*y$ pikselių dydžio vaizdas yra laikomas vektoriumi $x*y$ matmenų erdvėje.

Tikrinių veidų metodo tikslas – užfiksuoti veido vaizdų rinkinio variacijas ir šią informaciją panaudoti koduojant ir (arba) lyginant atskirų veidų vaizdus holistiškai, t.y. kaip visą veidą vienu metu, o ne lyginant specifinių požymių išraišką.

Iš pradžių metodas taikytas vaizdų, reprezentuojančių veidus, saugojimo supaprastinimui, leidžiant iš esmės bet kokią veidą susintetinti iš ~100 pirminių veidų, juos maišant specifinėmis proporcijomis, tačiau vėliau pradėtas naudoti ir veidų atpažinimui.

Tikrinių veidų metodą galima pritaikyti ir veidų aptikimui, kur potencialus veido regionas identifikuojamas kaip regionas, kurio pikselių vertės yra artimos tikrinių veidų deriniui.


Tikrinių veidų metodo trūkumai yra normalizavimo poreikis, t.y. metodas, kadangi jis paremtas neanotuotų požymių radimu, yra jautrus pradinių duomenų formatui – apmokymui naudojami veidai turi būti ne tik vienodos raiškos, bet ir papildomai apdoroti, pašalinant foną bei visas vaizdo dalis, kurios nėra veidas, taip pat pagrindiniai veido elementai turi būti sulygiuoti, t.y. būti kiek įmanoma panašesnėse pozicijose.

2.3.2. Vietinių dvejetainių šablonų metodas

Vietinių dvejetainių šablonų (ang. *Local binary patterns*, sutrumpintai LBP) algoritmas naudojamas aprašyti vaizdo formai bei tekstūrai. Vaizdas yra padalinamas į regionus, iš kurių yra išskiriami požymiai. Gauti požymiai yra apjungiami į požymių vektorių [57,58].

Algoritmo veikimo principas yra paremtas pikselių regionų verčių lyginimu ir šablonų ieškojimu gautose histogramose. Metodas dažniau naudojamas veido atpažinimui, tačiau gali būti naudojamas kartu su papildomais meta-algoritmais (pavyzdžiui, *AdaBoost*), iš histogramos siekiant išgauti požymius, įgalinančius atpažinti veido išraišką.

2.3.3. Regresijos medžių rinkinio metodas



14 pav. Regresijos medžių rinkinio metodu išskirti veido požymiai

Vienas naujesnių metodų veido išraiškos atpažinimo įgalinimui yra regresijos medžių rinkinio metodas, paremtas veido požymių šablono deformavimu ir pritaikymu tiriamam vaizdui[59]. Algoritmo veikimas yra paremtas specifinių intensyvumo reikšmių aptikimu tiriamame vaizde ir nuostolių funkcijos (vidutinės kvadratinės paklaidos) minimizavimu kiekvieną požymio tašką aprašančiam regresoriui.

Šis metodas yra itin tinkamas veido išraiškos atpažinimui, nes leidžia bet kokios raiškos vaizde išskirti taškus, kurie leidžia reprezentuoti didžiąją dalį veido išraiškos duomenų daug kompaktiškesniu pavidalu tolimesniam apdorojimui, atmetant netolygaus apšvietimo, vaizdo kokybės, fono, odos spalvos ir kitus panašius faktorius, kurie gali suprastinti veido išraiškos atpažinimo modelio darbą.

2.4. Veido išraiškos analizės taikymo įsitraukimo vertinimui tyrimas

2.4.1. Bendri tyrimų parametrai

DI modelių apmokymas ir tyrimas atliktas *JupyterLab* aplinkoje naudojant *Aff-Wild-2* [60,61,62,63,64,65] duomenų rinkinį bei *OpenCV*, *Tensorflow* ir *Scikit-py* bibliotekas. Duomenys rinkinyje pateikiami vaizdo įrašų pavidalu, kartu su sužadinimo ir valentingumo anotacijomis kiekvieno vaizdo įrašo kiekvienam kadru. Siekiant supaprastinti darbą su duomenų rinkiniu, buvo parašyta *Python* programa, atliekanti pirminį duomenų apdorojimą:

1. Vaizdo įrašai išskaidomi į kadrus panaudojant *ffmpeg* programą
2. Naudojant detektorius iš kadrų išskiriami veidų regionai.
3. Veidų regionai reguliarizuojami subendrinant jų dydį ir spalvinę raišką:
 - Dydis: 96x96 pikseliai
 - Spalvinė raiška: 8 bitai, pilkos atspalviai
4. Siekiant sumažinti duomenų dimensiškumą, naudojant *dlib* bibliotekos estimatorių, paremtą Kazemi ir Sullivan tyrimais [59] iš kiekvieno standartizuoto veido regiono išskiriami 68 veido žymenys.
5. Veido žymenų informacija (žymenų koordinatės veido regione) papildomai apdorojamos *Python* aplinkoje - koordinatės konvertuojamos į vienmatį masyvą ir išsaugomos *CSV* formato byloje kartu su šaltinio duomenimis (bylos vardu ir kadro eilės numeriu)
6. Sužadinimo ir valentingumo anotacijos konvertuojamos į kategorinę kvadrantų anotaciją, išskiriant klases pagal pasirinktą modelį:
 - a. 1 kvadrantas – teigiamas sužadinimas, teigiamas valentingumas
 - b. 2 kvadrantas – teigiamas sužadinimas, teigiamas valentingumas
 - c. 3 kvadrantas – teigiamas sužadinimas, teigiamas valentingumas
 - d. 4 kvadrantas – teigiamas sužadinimas, teigiamas valentingumas
7. Atliekamas vidinis anotacijos ir žymenų duomenų apjungimas, gauti duomenys papildomi kategorine anotacija, perduoduota į vektorius.
8. Duomenys išvalomi, pašalinant visus laukus, kuriuose yra neskaitinės reikšmės

2.4.2. Atraminų vektorių klasifikatoriaus modelio taikymas įsitraukimo vertinimui


Atraminų vektorių klasifikatoriui apmokyti ir validuoti atsitiktiniu būdu atrinkta 80 000 mėginių iš apdoroto duomenų rinkinio, siekiant išlaikyti vienodą įrašų skaičių kategorijose. 60 000 mėginių naudota apmokymui, likę 20 000 mėginių naudoti modelio validavimui.

Duomenys buvo papildomai apdoroti, juos normalizuojant [-1;1] režyje, panaudojant normalizacijos funkciją

$$x'_{mn} = \frac{x_{mn} - \min(x_m)}{\max(x_m) - \min(x_m)} * 2 - 1$$

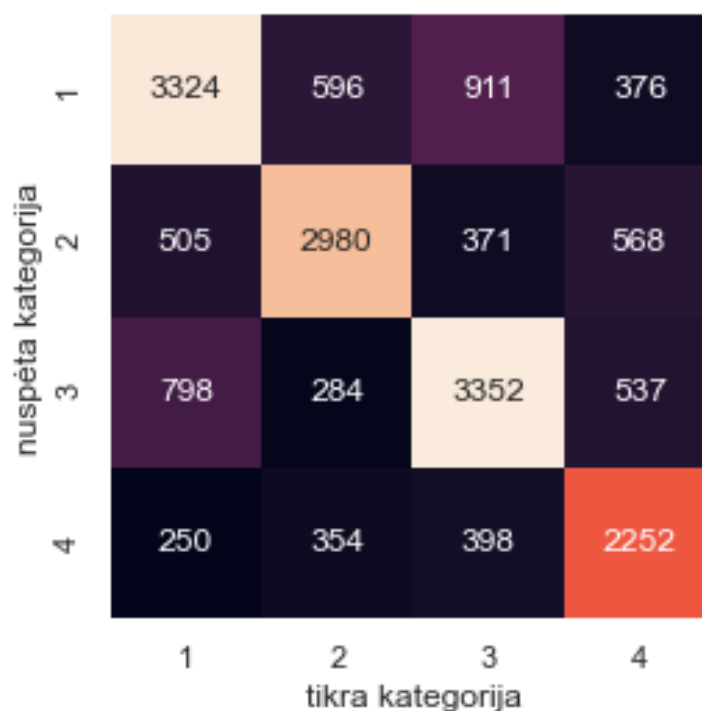
nes to reikalauja atraminių vektorių modelis. Atliekant bandymą apmokyti atraminių vektorių klasifikatorių, pastebėta, kad apmokymas užtrunka sąlyginai ilgai, daugiausia dėl didelio duomenų daugiamatiškumo, (atraminių vektorių skaičiavimo algoritmo sudėtingumas yra $O(n^2)$), todėl kaip palyginimą nuspręsta sukurti modelio kopiją, kurioje prieš apmokant modelį duomenims atliekama pagrindinių dedamųjų analizė ir kaip įvestis modeliui pateikiami transformuoti duomenys, kurių dimensionalumas yra mažesnis.

Atlikus kaupiamosios paaiškintosios dispersijos analizę (kaupiamasis rodiklis, nurodantis dedamųjų įtaką bendrai dispersijai), nustatyta, jog įvestį galima transformuoti iš 136 matmenų į 20 matmenų masyvą praktiškai neprarandant informacijos.



15 pav. Kaupiamosios paaiškintosios dispersijos kreivė

Apmokius modelio kopiją su transformuotais duomenimis, pastebėta, kad mokymo laikas sutrumpėjo nuo 37 minučių iki 7 minučių. Po modelių apmokymo apskaičiuotos sumaišymo matricos abiem modeliams bei įvertinti modelių parametrai.



16 pav. Apmokyto atraminių vektorių klasifikatoriaus sumaišymo matrica

Po sumaišymo matricų apskaičiavimo, apskaičiuoti modelio įvertinimo parametrai – taiklumas, tikslumas, atkūrimas ir F_1 vertė.

$$\text{taiklumas} = \frac{\text{teisingų klasifikacijų skaičius}}{\text{visų klasifikacijų skaičius}}$$

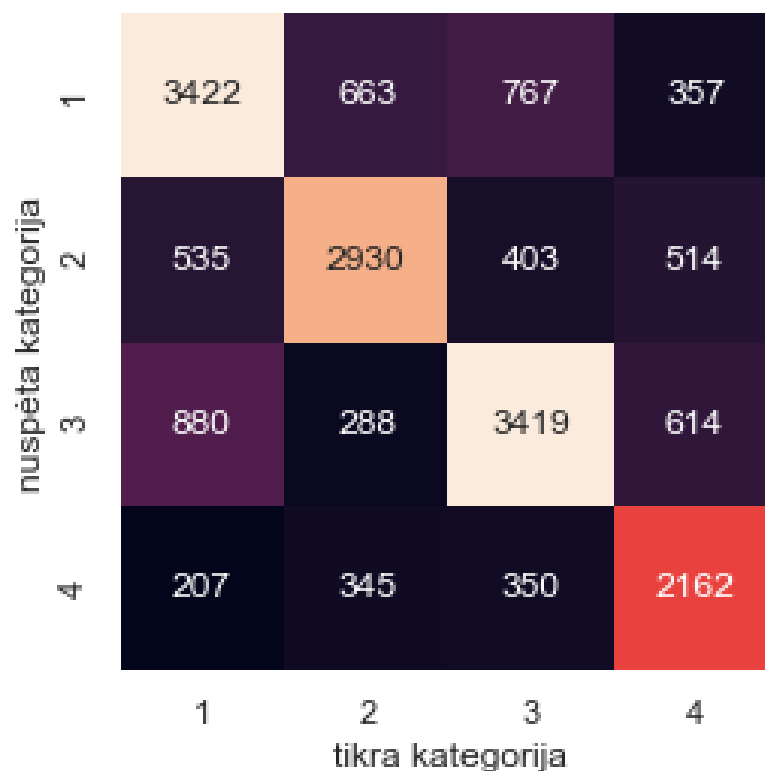
$$\text{tikslumas} = \frac{\text{teisingų klasifikacijų skaičius}}{\text{teisingų klasifikacijų skaičius} + \text{I tipo klaidų skaičius}}$$

$$\text{atkūrimas} = \frac{\text{teisingų klasifikacijų skaičius}}{\text{teisingų klasifikacijų skaičius} + \text{II tipo klaidų skaičius}}$$

$$F_1 \text{ vertė} = 2 * \frac{\text{tikslumas} * \text{atkūrimas}}{\text{tikslumas} + \text{atkūrimas}}$$

Kategorija	tikslumas	atkūrimas	F_1 vertė
1	0.64	0.68	0.66
2	0.67	0.71	0.69
3	0.67	0.67	0.67
4	0.69	0.6	0.64
taiklumas	0.67		

Sumaišymo matrica bei modelio įverčiai apskaičiuoti ir modeliui, kuriame duomenims, prieš juos perduodant klasifikavimo algoritmui, buvo pritaikyta pagrindinių dedamųjų analizė.



17 pav. Apmokyto atraminių vektorių klasifikatoriaus, prieš tai duomenis transformavus pagal pagrindinių dedamųjų analizę, sumaišymo matrica

Kategorija	tikslumas	atkūrimas	f1-vertė
1	0.64	0.68	0.66
2	0.67	0.71	0.69
3	0.67	0.67	0.67
4	0.69	0.6	0.64
taiklumas			0.67

Atraminių vektorių klasifikatorius pasiekė 67% tikslumą, duomenims pritaikius pagrindinių dedamųjų analizę, modelio tikslumas iš esmės nepasikeitė, tačiau ženkliai sumažėjo modelio apmokymo trukmė.

2.4.3. Neuroninio tinklo taikymas įsitraukimo vertinimui

Po atraminių vektorių klasifikatoriaus atliktas dirbtinio neuroninio tinklo taikymo įsitraukimo vertinimui iš veido išraiškos tyrimas. Dirbtiniam neuronų tinklui apmokyti ir validuoti atsitiktiniu būdu atrinkta 80 000 mėginių iš apdoroto duomenų rinkinio, siekiant išlaikyti vienodą įrašų skaičių kategorijose. 60 000 mėginių naudota apmokymui, likę 20 000 mėginių naudoti modelio validavimui.

Parinkta neuronų tinklo architektūra: trijų sluoksnių neuronų tinklas, susidedantis iš tankiai sujungtų dirbtinių neuronų. Pirmajame sluoksnyje naudota 300 dirbtinių neuronų, antrajame – 100, išėjimo sluoksnyje neuronų skaičius turi būti lygus kategorijų skaičiui, todėl panaudoti 4 neuronai. Pirmų dviejų sluoksnių neuronams parinkta rektifikuojančio tiesinio vieneto (angl. *Rectified Linear Unit (ReLU)*) aktyvacijos funkcija

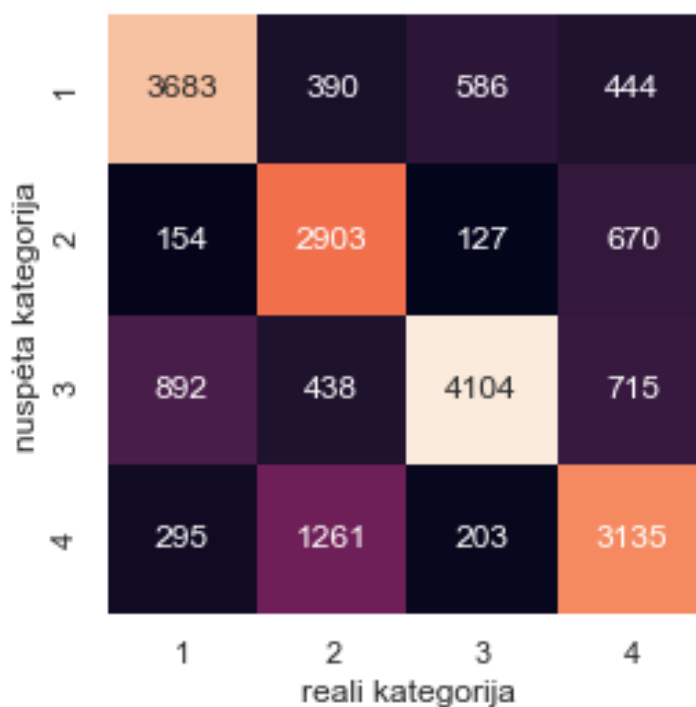
$$\varphi(x) = \begin{cases} 0 & x \leq 0 \\ x & x > 0 \end{cases}$$

, išėjimo sluoksniui parinkta minkštojo maksimumo funkcija

$$\varphi(x)_i = \frac{e^{x_i}}{\sum_n e^{x_n}}$$

Atitinkamos aktyvacijos funkcijos parinktos pagal modelio įvesties ir išvesties reikalavimus – rektifikuojančio tiesinio vieneto funkcija ir jos išvestinė yra apskaičiuojamos greičiau, nei sigmoidinės funkcijos, o minkštojo maksimumo funkcija leidžia gauti klasifikavimo tikimybes.

Apmokius modelį, apskaičiuota jo sumaišymo matrica bei vertinimo rodikliai.



18 pav. Apmokyto neuronų tinklo sumaišymo matrica

Kategorija	tikslumas	atkūrimas	f1-vertė
1	0.72	0.73	0.73
2	0.75	0.58	0.66
3	0.67	0.82	0.73
4	0.64	0.63	0.64
taiklumas	0.69		

Taip pat atliktas tyrimas, prieš duomenis paduodant neuronų tinklui, juos apdoroti naudojant pagrindinių komponentų analizę (kaip ir atramos vektorių modelyje). Pagrindinių komponentų analizės taikymas duomenims ženkliai pagerino modelio rezultatus.

nuspėta kategorija	1	4489	81	284	79
	2	113	4500	125	581
	3	342	85	4441	139
	4	70	308	130	4233
		1	2	3	4
		reali kategorija			

19 pav. Apmokyto neuronų tinklo, prieš tai duomenis transformavus pagal pagrindinių dedamųjų analizę, sumaišymo matrica

Kategorija	tikslumas	atkūrimas	f1-vertė
1	0.91	0.89	0.9
2	0.87	0.89	0.88
3	0.88	0.91	0.9
4	0.9	0.86	0.88
taiklumas	0.89		

2.4.4. Konvoliucinio neuronų tinklo taikymas įsitraukimo vertinimui

Įsitraukimo nustatymui taip pat tirtas konvoliucinio neuronų tinklo modelio taikymas. Buvo parašyta programa, apjungianti modifikuotas anotacijos (kvadrantų) duomenis su paveikslėlių bylomis, t.y. pervadinanti kiekvieną paveikslėlį tiriamajame duomenų rinkinyje į pavadinimą įtraukiant anotuotą kvadranto kategoriją. Po duomenų paruošimo duomenų rinkinys padalintas į apmokymo ir testavimo dalis, parinkti baziniai modelio parametrai ir apmokytas modelis. Kadangi modelio įvesčiai buvo naudojami vaizdai iš failų sistemos, o ne saugomi atmintyje, ir apmokymas vykdytas kompiuteryje be grafikos plokštės, tinkamos akseleravimui, apmokymo procesas užtruko itin ilgai – 5 epochų apmokymas truko kiek daugiau, nei 18 valandų.

nuspėta kategorija	1	12203	1331	6509	1067
	2	1062	140	572	94
	3	4929	580	2523	404
	4	335	36	183	32
		1	2	3	4
		reali kategorija			

20 pav. Apmokyto konvoliucinio neuronų tinklo sumaišymo matrica

Gauti modelio rezultatai netenkino užduoties poreikio – vidutinis modelio taiklumas siekė tik 47%, todėl tolimesnis modelio taikymas tirtas nebuvo.

2.4.5. Išvados

Įvertinus bandytų modelių klasifikavimo rezultatus, galutinei programai pasirinktas dirbtinio neuronų tinklo modelis su pagrindinių dedamųjų analize.

2.5. Įvesties analizės metodai

Įvesties analizė (angl. *analysis of keystroke dynamics*) yra įvairių metodų (statistinės analizės, dirbtinių neuroninių tinklų ir kt.), kaip pradinius duomenis naudojančių vartotojų sąveikos su klaviatūros klavišais požymius laike, pavyzdžiui, klavišo paspaudimo trukmę bei laiko intervalą tarp dviejų (ar daugiau) nuoseklių klavišų paspaudimų, pritaikymas įvairiems antriniam duomenims išgauti [66]. Plačiausiai įvesties analizė yra taikoma vartotojo atpažinimui, tačiau yra ir kitų taikymo sričių – viena iš jų yra emocinės būklės nuspėjimas iš biometrinių klaviatūros duomenų.

Khanna ir Sasikumar [67] pateikė metodą, identifikuojantį neutralią, teigiamą arba neigiamą emocinę būklę klasifikuojant klaviatūros įvesties analizės metrikas atsiktinio medžio metodu. Tyrimas taip pat parodė, kad vartotojai yra linkę daryti daugiau klaidų, po kurių seka teksto trynimai ar nesusijusių klavišų spaudimas, tuo atveju, kai jų emocinė būseną yra neigiama. Taip pat nustatyta, kad neigiama emocinė būseną neigiamai įtakoja ir spausdinimo greitį, ir atvirkščiai – teigiama emocinė būseną koreliuoja su greitesniu spausdinimu.

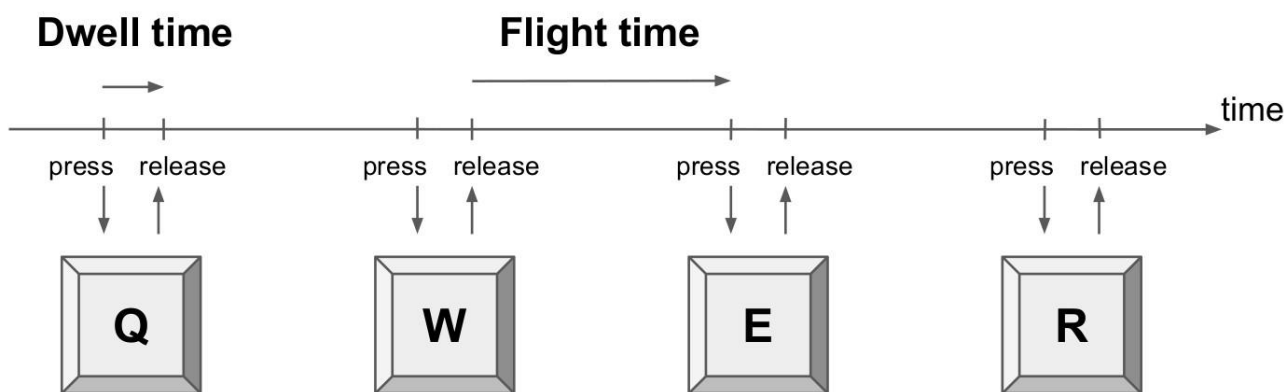
Epp'as ir kt. [43] pasiūlė sprendimą nustatyti vartotojo emocinę būseną analizuojant įvesties metrikų dinamiką. Autoriai rinko vartotojų spausdinimo metrikas bei emocines būsenas. Jie bandė klasifikuoti 15 skirtingų emocinių būsenų. Tyrimo rezultatas – sukurti binariniai pasitikėjimo, dvejonų, nervingumo, atsipalaidavimo, liūdesio ir nuovargio klasifikatoriai, kurių tikslumas svyruoja nuo 77% iki 88%.

Šio darbo kontekste aktualu apžvelgti įvesties analizės taikymą afektinių būklių nuspėjimui, nes tam tikros afektinės būklės, tokios kaip nuobodulys, pasimetimas ar susidomėjimas gali indikuoti vartotojų emocinio įsitraukimo lygį.

2.5.1. Pagrindinės įvesties analizės metrikos

Literatūroje išskiriamos pagrindinės metrikos, registruojamos laiko skalėje:

- klavišo paspaudimas (angl. *press*),
- klavišo atleidimas (angl. *release*),
- laikas tarp klavišo paspaudimo ir atleidimo (angl. *dwell*)
- laikas nuo vieno klavišo atleidimo iki kito klavišo paspaudimo (angl. *flight*)



21 pav. Pagrindiniai įvesties analizės įvykiai

2.5.2. Bixler'io ir D'Mello papildomos įvesties analizės metrikos

Bixler'is ir D'Mello [68] aprašo modelį, kuriuo naudojantis galima įvertinti vartotojo įsitraukimą į tai, su kuo vartotojas sąveikauja. Autoriai išskiria papildomas, daugiausia išvestines metrikas:

- Sesijos laikas – nuo sesijos pradžios praėjęs laikas
- Daugždožiavimas – klavišų skaičius intervale
- Trynimas – „backspace“ klavišo nuspaudimų skaičius per laiko intervalą
- Didžiausias delsos laikas - didžiausias laiko skirtumas tarp klavišų paspaudimų intervale
- Mažiausias delsos laikas - mažiausias laiko skirtumas tarp klavišų paspaudimų intervale

- Vidutinis delsos laikas – vidutinis laiko skirtumas tarp klavišų paspaudimų intervale
- Delsos laiko mediana – laiko skirtumų tarp klavišų paspaudimų intervale mediana
- Pusės sekundės pauzės – pauzių, ilgesnių nei pusė sekundės, bet trumpesnių nei sekundė skaičius
- Sekundės pauzės – pauzių, ilgesnių nei sekundė, bet trumpesnių nei pusantros sekundės skaičius
- Pusantrų sekundės pauzės – pauzių, ilgesnių nei pusantrų sekundės, bet trumpesnių nei dvi sekundės skaičius
- Dviejų sekundžių pauzės – pauzių, ilgesnių nei dvi sekundės, bet trumpesnių nei trys sekundės skaičius.

2.5.3. Įvesties analizė emocijoms nustatyti panaudojant atsitiktinio miško modelį

Literatūroje dažniausiai aptinkamas atsitiktinio miško algoritmo taikymas, siekiant pagal įvesties metrikas nuspėti vartotojo emocinę būklę[68,69,70].

Atsitiktinis miškas yra klasifikavimo algoritmas, susidedantis iš sprendimų medžių aibės. Generuojant kiekvieną atskirą medį, naudojamas *bagging* meta-algoritmas, kad būtų sukurtas tarpusavyje nekoreliuojančių medžių miškas, kuris gali prognozuoti tiksliau nei bet kuris pavienis medis[71].

2.6. Įvesties analizės taikymo įsitraukimo vertinimui tyrimas

Siekiant parinkti optimalų sprendimą projektinės dalies įgyvendinimui, reikia ištirti ir įvertinti įvesties analizės modelių tinkamumą iškeltai užduočiai. Tyrimui eksperimentiniu būdu pasirinkti dirbtinio neuronų tinklo bei sudėtinio klasifikatoriaus modeliai.

2.6.1. Bendri tyrimų parametrai

DI modelių apmokymas ir tyrimas atliktas *JupyterLab* aplinkoje naudojant *EmoSurv*[72] duomenų rinkinį bei *Tensorflow* ir *Scikit-py* bibliotekas. Rinkinyje pateikiami laisvo rašymo įvesties duomenys kableliu atskirtų reikšmių byloje, kartu su kategorinėmis emocijų anotacijomis kiekvienam klavišo paspaudimui. Siekiant supaprastinti darbą su duomenų rinkiniu, buvo parašyta *Python* programa, atliekanti pirminį duomenų apdorojimą:

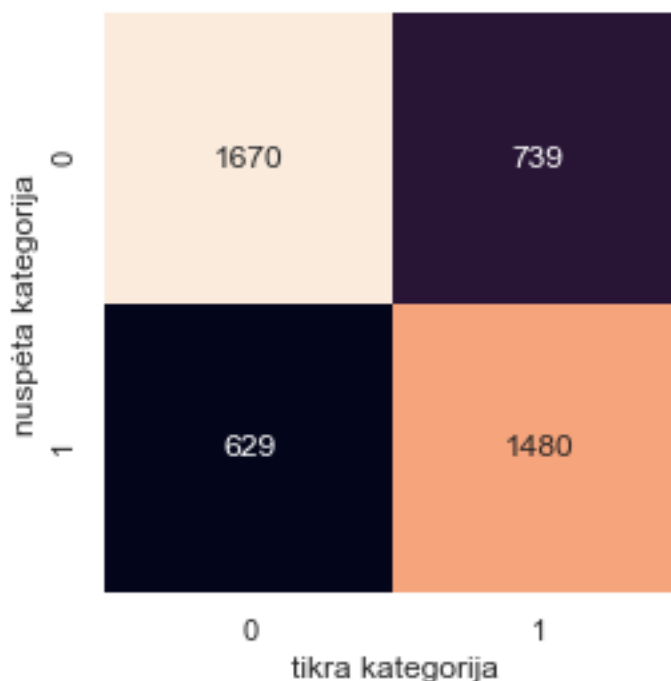
1. Emocijų anotacijos konvertuojamos į binarinę įsitraukimo anotaciją, remiantis afekto erdvės modeliu:
 - a. Kategorijos „Džiaugsmas“, „Pyktis“, „Nuostaba“ perklasifikuojamos kaip aukšto įsitraukimo rodiklis (1)
 - b. Likusios kategorijos perkoduojamos kaip žemo įsitraukimo (0)
2. Atliekama duomenų analizė ir pašalinami duomenys, labai nutolę nuo vidurkio.

3. Duomenys išvalomi, pašalinant laukus, kuriuose yra neskaitinės reikšmės bei išvestinius rodiklius, nenaudojamus skaičiavimui.
4. Požymiai išplečiami pridodant 4 prieš tai paspaustų klavišų požymius.

2.6.2. Sudėtinio klasifikatoriaus taikymas įsitraukimo vertinimui

Tyrimui eksperimentiniu būdu pasirinktas sudėtinis klasifikatorius, susidedantis iš atsitiktinio miško bei *AdaBoost* klasifikatorių, kurių klasifikavimo rezultatai papildomai apdorojami logistiniu regresoriumi ir taip gaunama galutinė klasifikacija.

Klasifikatoriui apmokyti ir validuoti naudotas pilnas išvalytas *EmoSurv* duomenų rinkinys. Duomenų rinkinys padalintas į dvi dalis – 80% duomenų naudoti modelio apmokymui, 20% duomenų naudoti modelio testavimui. Lyginant testavimu metu gautas kategorines vertes su duomenų anotacijomis, sudaryta sumaišymo matrica bei apskaičiuoti modelio rodikliai vertinimui.



22 pav. Apmokyto sudėtinio klasifikatoriaus sumaišymo matrica

Kategorija	tikslumas	atkūrimas	f1-vertė
0	0.69	0.73	0.71
1	0.7	0.67	0.68
Taiklumas	0.7		

Gauto modelio taiklumas – 70%.

2.6.3. Neuronų tinklo taikymas įsitraukimo vertinimui

Dirbtiniam neuronų tinklui apmokyti ir validuoti naudotas pilnas išvalytas *EmoSurv* duomenų rinkinys. Duomenų rinkinys padalintas į dvi dalis – 80% duomenų naudoti modelio apmokymui, 20% duomenų naudoti modelio testavimui.

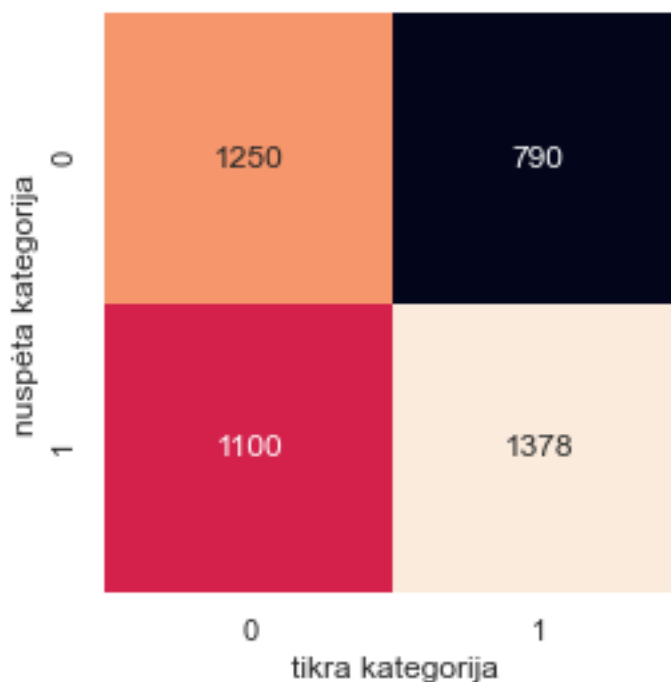
Parinkta neuronų tinklo architektūra: trijų sluoksnių neuronų tinklas, susidedantis iš tankiai sujungtų dirbtinių neuronų. Pirmajame sluoksnyje naudota 120 dirbtinių neuronų, antrajame – 20, išėjimo sluoksnyje užtenka vieno neurono, nes naudojama binarinė klasifikacija. Pirmų dviejų sluoksnių neuronams parinkta rektifikuojančio tiesinio vieneto (angl. *Rectified Linear Unit (ReLU)*) aktyvacijos funkcija

$$\varphi(x) = \begin{cases} 0 & x \leq 0 \\ x & x > 0 \end{cases}$$

, išėjimo sluoksniui parinkta sigmoidinė funkcija, nes ji yra tinkama binariniam klasifikavimui.

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

Lyginant testavimu metu gautas kategorines vertes su duomenų anotacijomis, sudaryta sumaišymo matrica bei apskaičiuoti modelio rodikliai vertinimui.



23 pav. Apmokyto neuronų tinklo sumaišymo matrica

Kategorija	tikslumas	atkūrimas	f1-vertė
0	0.61	0.53	0.57
1	0.56	0.64	0.59
taiklumas			0.58

3. Projektinė dalis

Remiantis atliktais tyrimais bei literatūros analize, suformuotas sprendimas – programa, realiu (ar artimu realiam) laiku vertinanti vartotojo įsitraukimą, remiantis veido išraiškos bei įvesties analize. Programa rašoma *Python 3* kalba naudojant atvirojo kodo *OpenCV*, *dlib*, *TensorFlow* ir *Keras* bibliotekas.

3.1. Reikalavimų specifikacija

Reikalavimai priemonei:

- Paprasta vartotojo sąsaja
- Įsitraukimo klasės pagal veido išraišką duomenų rinkimas
- Įsitraukimo klasės pagal veido išraišką duomenų apdorojimas
- Įsitraukimo klasės pagal klaviatūros įvestį duomenų rinkimas
- Įsitraukimo klasės pagal klaviatūros įvestį duomenų apdorojimas
- Kompiuterio kameros dublikavimas
- Galimybė išsaugoti duomenis
- Vartotojų anonimiškumo užtikrinimas
- Programos veikimo indikacija vartotojui
- Galimybė saugoti duomenis lokaliai arba nutolusiame serveryje

3.1.1. Projektuojamos priemonės paskirtis ir tikslai

Projektuojamos priemonės paskirtis – rinkti vartotojo įsitraukimo duomenis, juos eksportuoti tolimesniam apdorojimui.

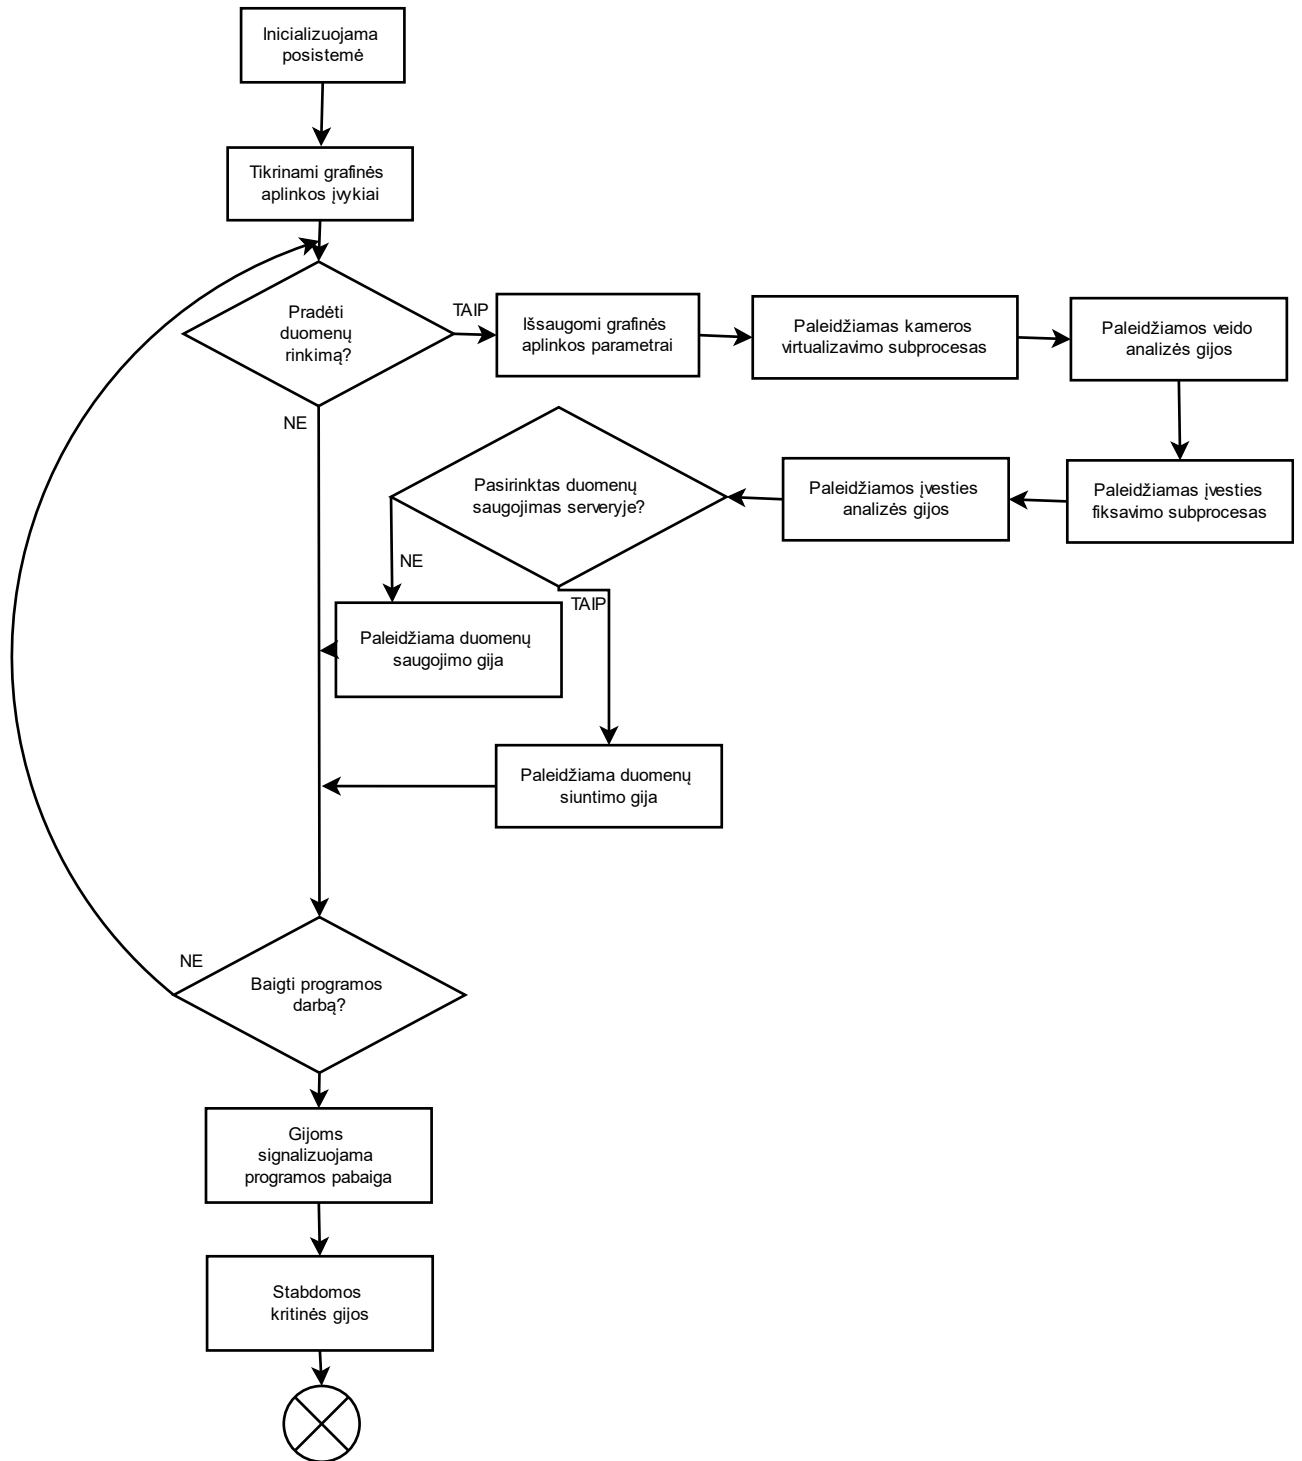
Priemonės tikslas – palengvinti įsitraukimo duomenų rinkimą nuotolinio mokymosi aplinkose be papildomos apkrovos vartotojams.

3.1.2. Suprojektuotos priemonės vartotojai

Suprojektuotos priemonės vartotojai – nuotolinių mokymosi kursų dalyviai ir rengėjai. Priemonės surinktų duomenų naudotojai – mokymosi kursų rengėjai, mokymosi proceso organizatoriai, dėstytojai, mokymosi įstaigos.

3.2. Programos architektūrinė apžvalga

3.2.1. Pagrindinė programos posistemė

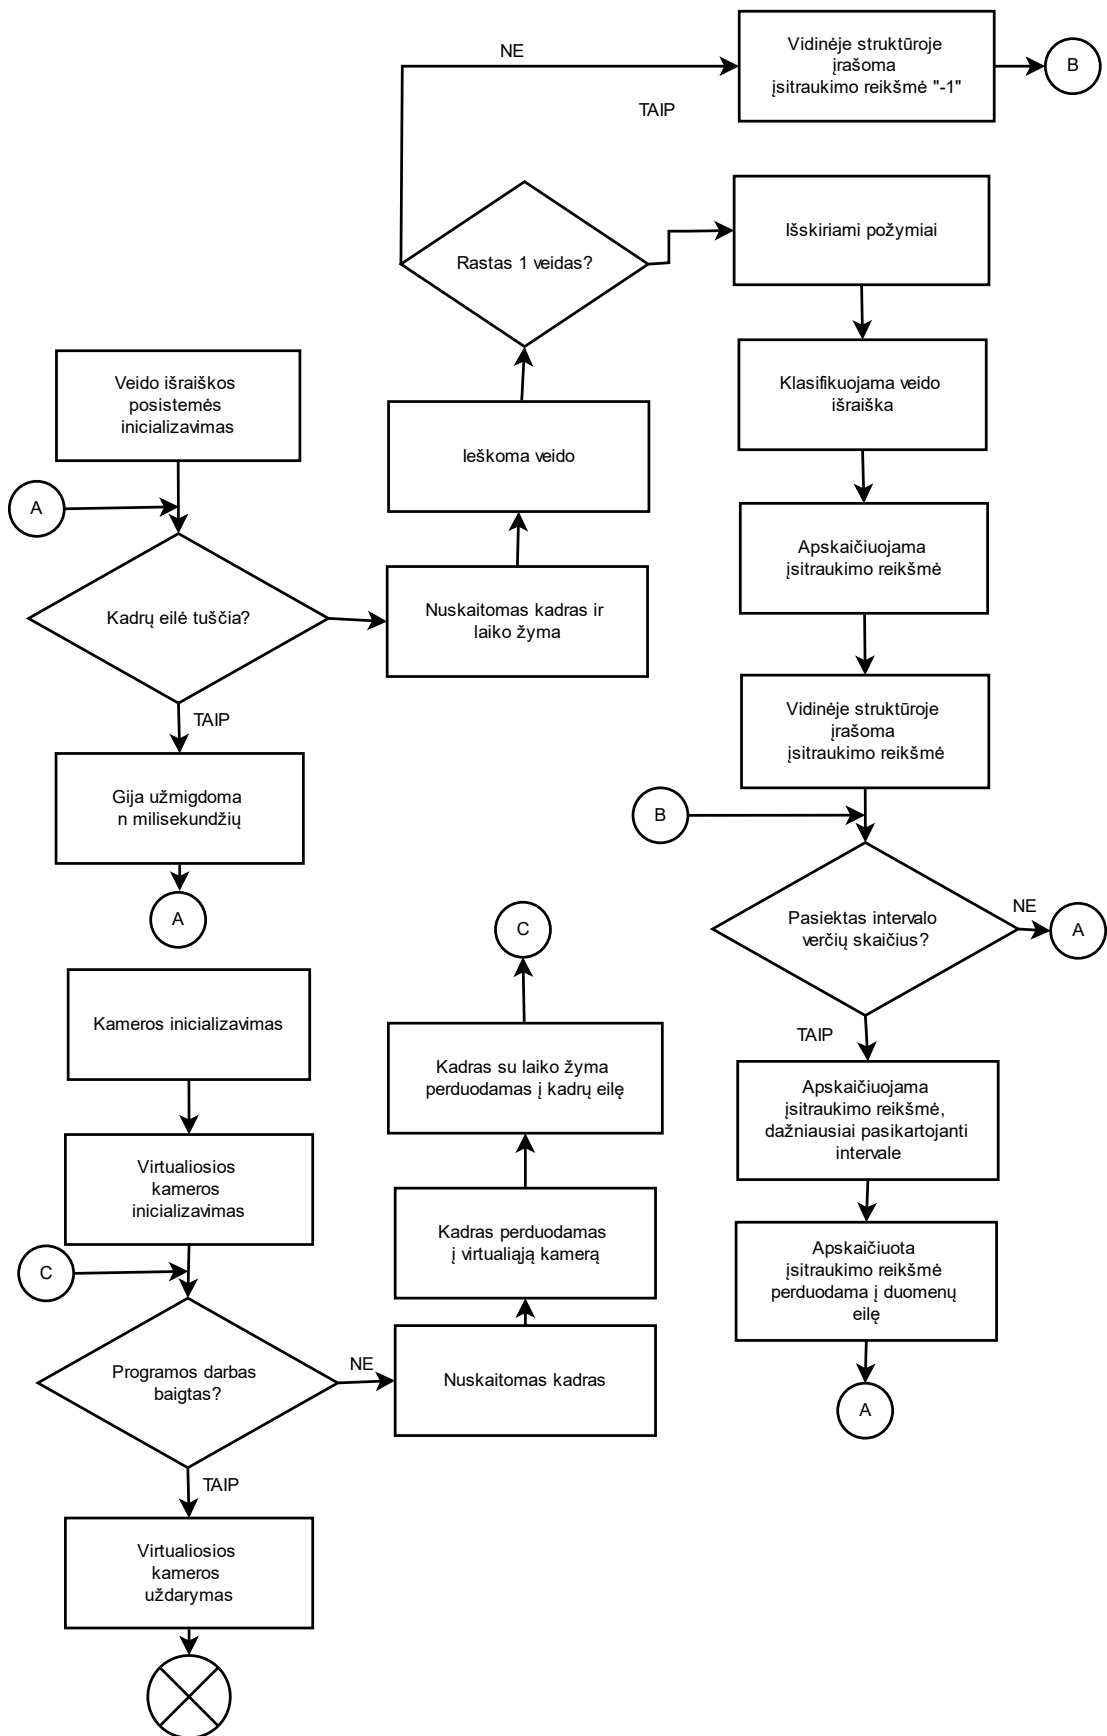


24 pav. Pagrindinės posistemės algoritmas

Pagrindinei programos posistemėi keliamos užduotys:

- **Unikalus identifikatoriaus generavimas.** Kiekvieną kartą paleidus programą, yra sugeneruojamas unikalus vartotojo identifikatorius, naudojamas sekti vartotojo įsitraukimo pokyčius ir fiksuojamas programos išvesties duomenyse.
- **Analizės ir duomenų posistemų inicializavimas bei stabdymas.** Programos posistemėje paruošiamos duomenų struktūros, skirtos duomenų mainams tarp posistemų gijų bei procesų, gavus vartotojo įvesties signalą pradėti darbą, paleidžiamos posistemų gijos bei procesai. Gavus signalą baigti darbą, kritinės posistemės uždaromos tvarkingai, atlaisvinant naudotus sisteminius resursus.
- **Grafinės aplinkos inicializavimas ir valdymas.** Pagrindinėje programos posistemėje veikia įvykių mašina paremtas ciklas, atvaizduojantis programos grafinius elementus ir įgalinantis vartotojo sąsają su programa.

3.2.2. Veido išraiškos analizės posistemė

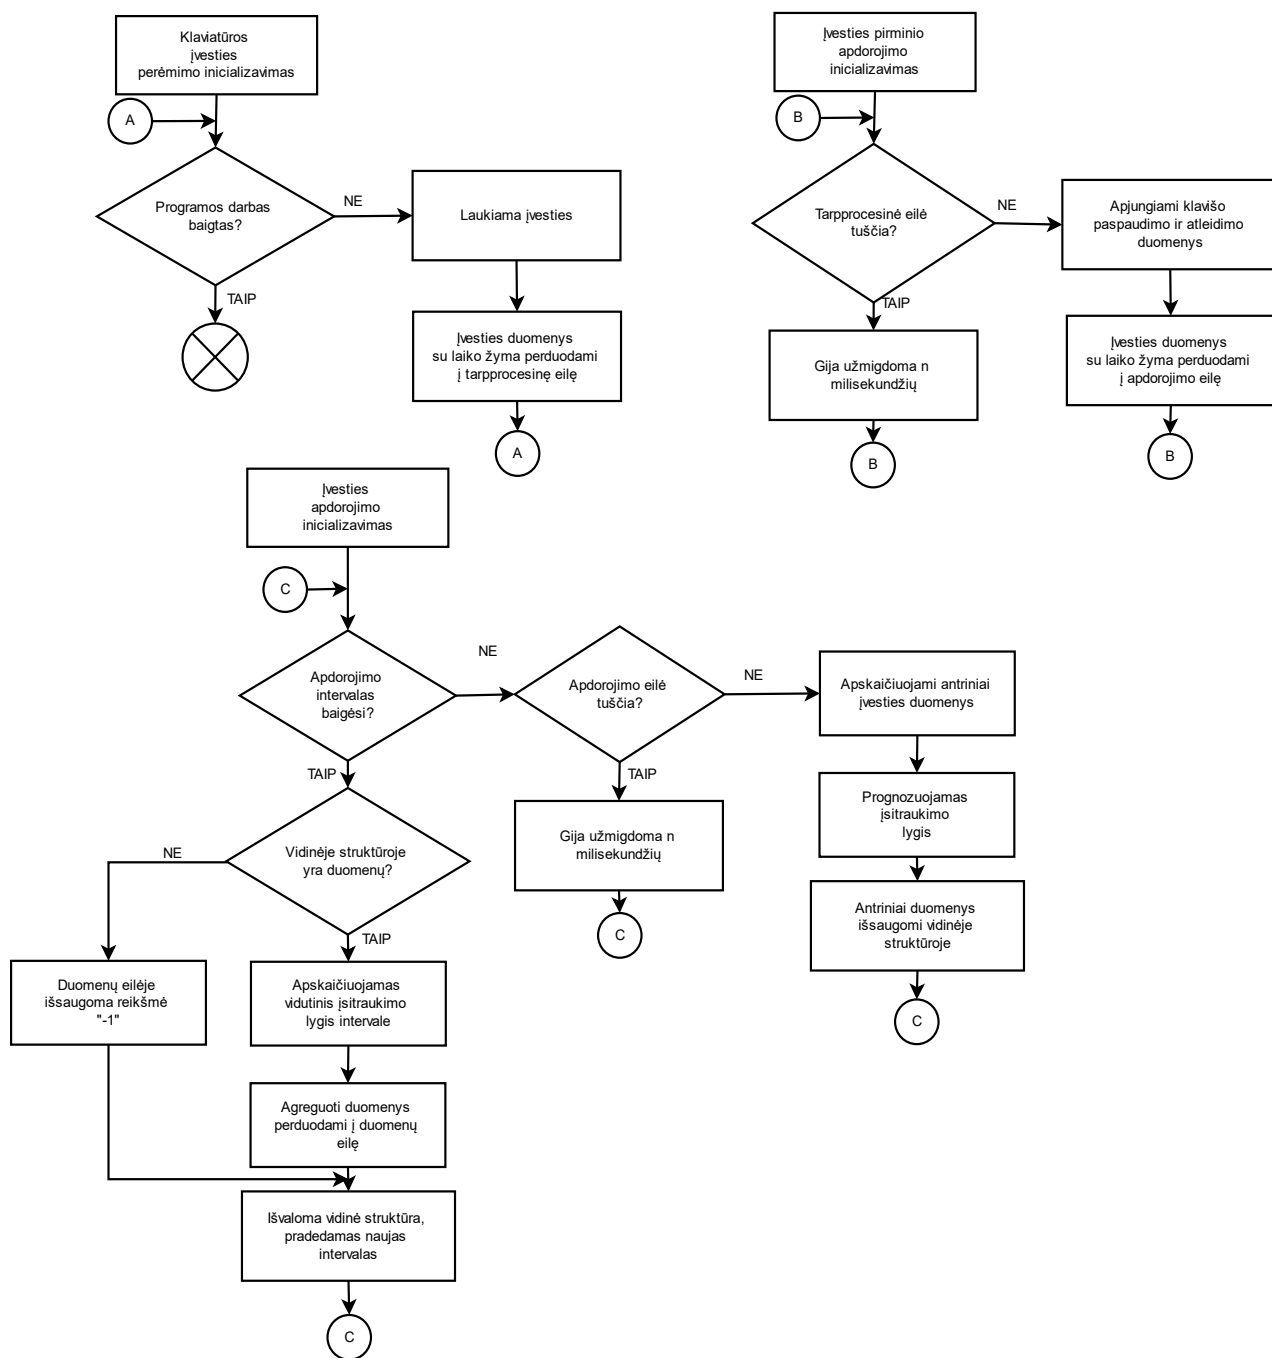


25 pav. Veido išraiškos posistemės algoritmas

Veido išraiškos analizės posistemei keliamos užduotys:

- **Vaizdo kameros įvesties dublikavimas.** Kadangi kompiuterio kamerą vienu metu gali naudoti tik vienas procesas, būtina užtikrinti, kad vaizdo kameros duomenų srautas bus dubliuojamas ir vartotojui pateikiamas per virtualųjį vaizdo kameros įrenginį. Tam įgyvendinti programa darbo pradžioje paleidžia atskirą subprocesą, kuris skaito iš vaizdo kameros gautą duomenų srautą, jį perduoda virtualiajai kamerai (naudojama *OBS Studio* virtualiosios kameros biblioteka) ir per tarpprocesinę duomenų dalinimosi eilę perduoda vaizdo kameros kadro bei laiko duomenis tolimesniam apdorojimui.
- **Vaizdo normalizavimas.** Kiekvienas kadras, perduotas virtualiajai kamerai, yra normalizuojamas – sumažinama spalvinė raiška ir vaizdo dydis, siekiant naudoti mažiau kompiuterio resursų.
- **Veido regionų išskyrimas.** Normalizuotame kadre ieškoma veido regionų naudojant detektorius, paremtą orientuotomis gradientų histogramomis ir atraminių vektorių mašina.
- **Kadru atmetimas.** Suskaičiuojami kadre rasti veidų regionai, jei kadre nerandama veido, arba randamas daugiau, nei vienas veidas, regionas atmetamas ir duomenų posistemei perduodama vidinė vertė -1, rodanti netinkamus duomenis bei laiko žymė.
- **Veido regiono normalizavimas.** Veido regiono dydis pakeičiamas į 96x96 pikselius.
- **Veido požymių išskyrimas.** Veido regionas perduodamas požymių išskyrimui naudojamam regresijos medžių rinkiniui.
- **Veido požymių vektoriaus apdorojimas.** Gauta veido požymių matrica performuojama į vienmatį vektorių, jam pritaikoma pagrindinių komponentų analizės transformacija. Gautas vektorius transponuojamas į neuronų tinklo modelio įvesčiai tinkamą formą.
- **Įsitraukimo nustatymas naudojant iš anksto apmokytą modelį.** Požymių vektorius perduodamas dirbtiniam neuronų tinklui, gaunamas spėjimas. Tikimybinė spėjimo išraiška perkoduojama į kategorinę vertę.
- **Duomenų agregavimas ir perdavimas duomenų posistemei.** Duomenys agreguojami nustatytą laiko intervalą ir intervalo pabaigoje perduodami duomenų posistemei.

3.2.3. Įvesties analizės posistemė



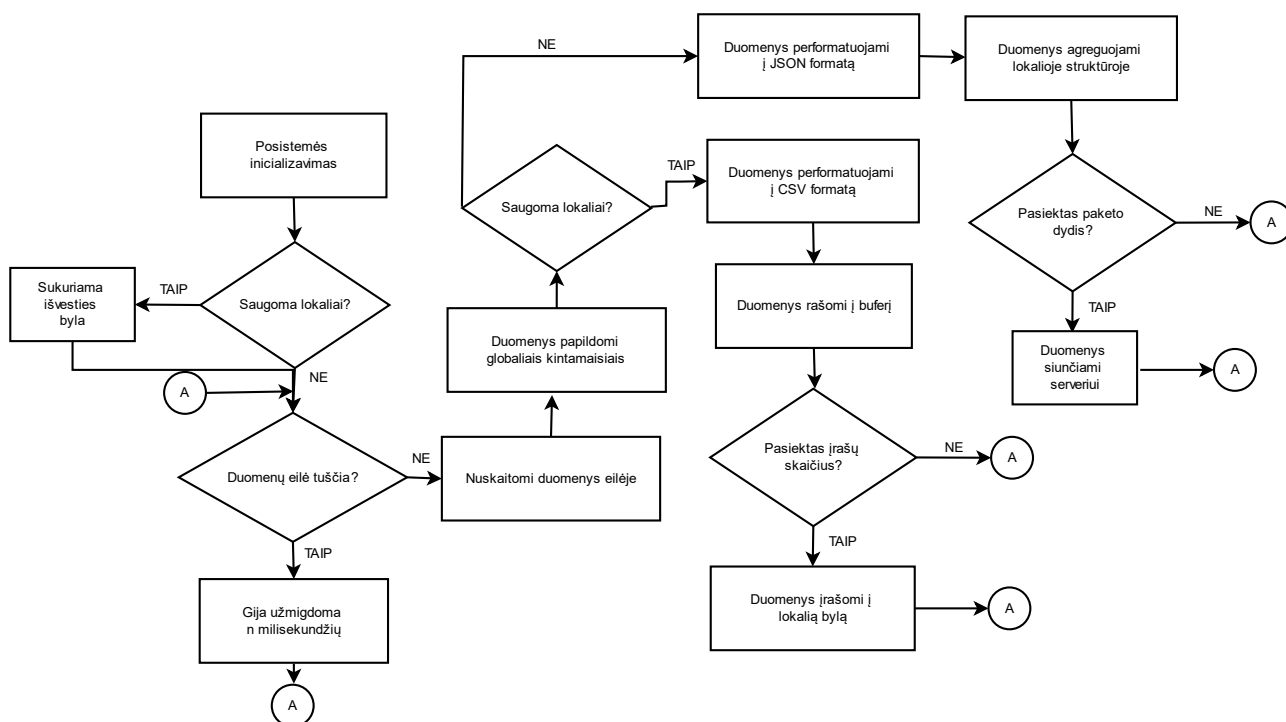
26 pav. Įvesties analizės posistemės algoritmas

Įvesties analizės posistemėi keliamos užduotys:

- Klaviatūros įvykių fiksavimas.** Klaviatūros įvykiai fiksuojami per žemo lygio Windows sistemos aplikacijų programavimo sąsają pasitelkiant *pyWinHook* biblioteką. Klaviatūros įvykių fiksavimui paleidžiamas subprocesas fiksuojantis klaviatūros įvykius (mygtukas, paspaudimo laikas, atleidimo laikas) ir juos per atgalinės krypties iškvietimo funkciją perduodantis duomenų apdorojimo gijai per tarpprocesinę eilę.

- **Požymių skaičiavimas.** Iš klaviatūros įvykių fiksavimo subprocesu gauti duomenis agreguojami, skaičiuojami išvestiniai rodikliai – klavišo nuspaudimo trukmė, intervalas tarp klavišų paspaudimų. Pašalinami turinio duomenys – klavišų istorija.
- **Įsitraukimo modeliavimas pagal įvestį.** Apdoroti požymių vektoriai perduodami iš anksto apmokytam sudėtiniam klasifikatoriui, susidedančiam iš atsitiktinio miško, *AdaBoost* ir logistinio regresoriaus. Gaunama įsitraukimo vertė (aukštas arba žemas).
- **Duomenų agregavimas ir perdavimas duomenų posistemei.** Duomenys agreguojami nustatytą laiko intervalą ir intervalo pabaigoje perduodami duomenų posistemei.

3.2.4. Duomenų posistemė



27 pav. Duomenų posistemės algoritmas

Duomenų posistemei keliamos užduotys:

- **Duomenų surinkimas iš analitinių posistemių.** Duomenys renkami per eilės tipo duomenų struktūrą, apjungiami su duomenimis iš pagrindinės posistemės (unikaliu vartotojo identifikaciniu kodu, paskaitos kodu, jei duomenys renkami į išorinį serverį, duomenų posistemės gijai taip pat perduodamas serverio adresas.
- **Duomenų formatavimas ir išvestis.** Duomenys formatuojami į bendrą formatą ir saugomi kableliu atskirtų reikšmių formatu arba JSON formatu pateikiami į išorinį serverį.


Duomenų posistemę sudaro dvi funkcijos – lokalaus rašymo funkcija *writer*, ir nuotolinio rašymo funkcija *poster*. Vienu metu veikia tik viena funkcija (priklausomai nuo pasirinkto duomenų saugojimo būdo pagrindinėje posistemėje).

3.2.5. Posistemių tarpusavio ryšiai

Posistemės tarpusavyje sąveikauja per dviejų tipų eilių duomenų struktūras – tarpprocesines ir paprastąsias eiles. Didžioji dalis eilių naudojama duomenų mainams tarp gijų ir (arba) programos subprocesų. Parinktos eilių struktūrų implementacijos, tinkamos duomenų mainams tarp gijų ir procesų.

Analitinių ir duomenų posistemių gijos ir subprocesai paleidžiami iš pagrindinės programos posistemės, nuo pasirinkimo pradiniame programos lange priklauso, kuri duomenų posistemės gija bus paleista – duomenų rašymo lokaliai ar į nutolusį serverį.

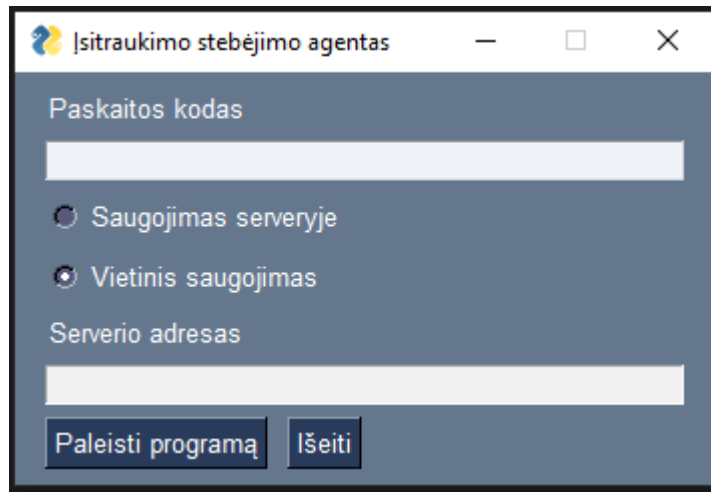
3.2.6. Programos grafinė aplinka



28 pav. Programos vaizdas Windows aplinkoje

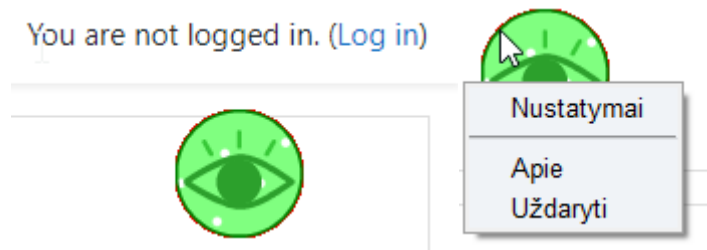
Programos grafinė aplinka susideda iš dviejų pagrindinių elementų:

- **Programos paleidimo langas.** Programos paleidimo lange rodoma informacija apie programą. Paleidimo langas susideda iš tekstinio laukelio paskaitos kodui įvesti, pasirinkimo, kur saugomi duomenys, serverio adreso įvesties lauko bei valdymo mygtukų, leidžiančių paleisti programą arba iš jos išeiti.



29 pav. Pradinis programos langas

- **Plaukiojantis programos darbo indikatorius su kontekstiniu meniu.** Programai dirbant, paleidimo langas yra uždaromas ir apie programos darbą vartotojui indikuojama plaukiojančiu indikatoriumi, kuris yra aiškiai matomas, tačiau vartotojas jį gali perkelti į bet kurią ekrano vietą, kad netrukdytų darbui. Per indikatoriaus kontekstinį meniu galima peržiūrėti programos nustatymus, informaciją apie programą, arba baigti programos darbą.



30 pav. Programos darbo indikatorius su kontekstiniu meniu

3.2.7. Programos resursų naudojimas

Dirbanti programa naudoja apie 200 MB operatyviosios atminties. Šį rodiklį būtų galima pagerinti perrašant programą žemesnio lygio programavimo kalba, pavyzdžiui C#, Java arba C++.

Išvados

1. Įsitraukimas yra apibūdinamas, kaip besimokančiojo savybė, mokymosi proceso metu parodanti besimokančiojo polinkį dalyvauti mokymosi procese. Srautinių paskaitų metu studentai labiau linkę į anonimiškumą ir blaškymąsi, kas daro neigiamą įtaką įsitraukimui. Kai studentai nustoja kreipti dėmesį į kurso turinį, jie nesugeba susikurti žinių, kurios padėtų įsisavinti dėstomą dalyką.
2. Remiantis literatūra, identifikuota, kad įsitraukimą galima vertinti iš biometrinių duomenų – veido išraiškos, įvesties ir parakalbos, automatizuotam įsitraukimo vertinimui pritaikytas įsitraukimo vertinimo modelis, paremtas emocinio sužadavimo ir valentingumo reikšmių skaičiavimu remiantis veido išraiškos bei įvesties duomenimis.
3. Ištirtas skirtingų dirbtinio intelekto ir mašininio mokymosi metodų patikimumas vartotojų įsitraukimo vertinimui – nustatyta, kad veido išraiškos analizei tiksliausia naudoti dirbtinį neuronų tinklą, o įvesties analizei – sudėtinį klasifikatorių. Tyrimo metu taip pat nustatyta, kad tikslingiau įsitraukimą vertinti naudojant veido išraišką, nes įvesties duomenys neneša pakankamai informacijos daugiaklasiam vertinimui.
4. Remiantis literatūra bei atliktu tyrimu, suprojektuota ir realizuota priemonė, realiu laiku vertinanti vartotojų įsitraukimą pagal veido išraišką bei įvesties specifiką ir išsauganti duomenis analizei.

Literatūros sąrašas

1. WHITEHILL, Jacob, et al. The faces of engagement: Automatic recognition of student engagement from facial expressions. *IEEE Transactions on Affective Computing*, 2014, 5.1: 86-98 [Interaktyvus resursas]. Žiūrėta 2019 11 26. Prieiga per:
<https://inc.ucsd.edu/mplab/wordpress/wp-content/uploads/EngagementRecognitionFinal.pdf>
2. LARSON, Reed W.; RICHARDS, Maryse H. Boredom in the middle school years: Blaming schools versus blaming students. *American journal of education*, 1991, 99.4: 418-443.
3. AXELSON, Rick D.; FLICK, Arend. Defining student engagement. *Change: The magazine of higher learning*, 2010, 43.1: 38-43. [Interaktyvus resursas]. Žiūrėta 2020 01 10. Prieiga per:
<http://nur655sect2jan12teama.pbworks.com/w/file/fetch/50933853/defining%20student%20engagement.pdf>
4. WOLF-WENDEL, Lisa; WARD, Kelly; KINZIE, Jillian. A tangled web of terms: The overlap and unique contribution of involvement, engagement, and integration to understanding college student success. *Journal of College Student Development*, 2009, 50.4: 407-428. [Interaktyvus resursas]. Žiūrėta 2019 12 18. Prieiga per:
https://kuscholarworks.ku.edu/bitstream/handle/1808/17576/WolfWendel_JCSD_50%284%29407.pdf?sequence=1&isAllowed=y
5. ASTIN, Alexander W. Student involvement: A developmental theory for higher education. *Journal of college student personnel*, 1984, 25.4: 297-308. [Interaktyvus resursas]. Žiūrėta 2019 12 21. Prieiga per:
https://www.asec.purdue.edu/lct/hbcu/documents/Student_Involvement_A_Developmental_Theory_for_HE_Astin.pdf
6. TINTO, Vincent. Theories of student departure revisited. *Higher education: Handbook of theory and research*, 1986, 2.359-384.
7. FREDRICKS, Jennifer A.; BLUMENFELD, Phyllis C.; PARIS, Alison H. School engagement: Potential of the concept, state of the evidence. *Review of educational research*, 2004, 74.1: 59-109. [Interaktyvus resursas]. Žiūrėta 2019 12 19. Prieiga per:
<http://www.inquirylearningcenter.org/wp-content/uploads/2015/08/Fredricks2004-engagemt.pdf>
8. ANDERSON, Amy R., et al. Check & Connect: The importance of relationships for promoting engagement with school. *Journal of School Psychology*, 2004, 42.2: 95-113.
9. LANE, Erin S.; HARRIS, Sara E. A new tool for measuring student behavioral engagement in large university classes. *Journal of College Science Teaching*, 2015, 44.6: 83-91 [Interaktyvus resursas]. Žiūrėta 2019 12 29. Prieiga per:
<https://pdfs.semanticscholar.org/72fa/aadd6c296a816266dda0619057d0c1ec2003.pdf>
10. AINLEY, Mary. Students' interest and engagement in classroom activities. In: *Handbook of research on student engagement*. Springer, Boston, MA, 2012. p. 283-302. [Interaktyvus resursas]. Žiūrėta 2019 12 29. Prieiga per:
https://www.researchgate.net/profile/Azkananda_Widiasani/publication/310773130_Handbook_of_Student_Engagement/links/5836a0dd08aed45931c772b7/Handbook-of-StudentEngagement.pdf

- ndbook_of_Student_Engagement/links/5836a0dd08aed45931c772b7/Handbook-of-Student-Engagement.pdf - page=301Engagement.pdf#page=301
11. LAM, Shui-fong, et al. Understanding student engagement with a contextual model. In: Handbook of research on student engagement. Springer, Boston, MA, 2012. p. 403-419. [Interaktyvus resursas]. Žiūrėta 2019 12 28. Prieiga per: [https://www.researchgate.net/profile/Azkananda_Widiasani/publication/310773130_Handbook_of_Student_Engagement/links/5836a0dd08aed45931c772b7/Handbook-of-Student-Engagement.pdf - page=418Engagement.pdf#page=418](https://www.researchgate.net/profile/Azkananda_Widiasani/publication/310773130_Handbook_of_Student_Engagement/links/5836a0dd08aed45931c772b7/Handbook-of-Student-Engagement/links/5836a0dd08aed45931c772b7/Handbook-of-Student-Engagement.pdf - page=418Engagement.pdf#page=418)
 12. MARTIN, Florence; BOLLIGER, Doris U. Engagement matters: Student perceptions on the importance of engagement strategies in the online learning environment. Online Learning, 2018, 22.1: 205-222 [Interaktyvus resursas]. Žiūrėta 2019 12 29. Prieiga per: <https://files.eric.ed.gov/fulltext/EJ1179659.pdf>
 13. BANNA, Jinan, et al. Interaction matters: Strategies to promote engaged learning in an online introductory nutrition course. Journal of online learning and teaching/MERLOT, 2015, 11.2: 249 [Interaktyvus resursas]. Žiūrėta 2019 12 21. Prieiga per: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4948751/pdf/nihms801219.pdf>
 14. LEAR, Janet L.; ANSORGE, Charles; STECKELBERG, Allan. Interactivity/community process model for the online education environment. Journal of online learning and teaching, 2010, 6.1: 71-77. [Interaktyvus resursas]. Žiūrėta 2019 11 21. Prieiga per: http://jolt.merlot.org/vol6no1/lear_0310.pdf
 15. BIXLER, Robert; D'MELLO, Sidney. Detecting boredom and engagement during writing with keystroke analysis, task appraisals, and stable traits. In: Proceedings of the 2013 international conference on Intelligent user interfaces. ACM, 2013. p. 225-234 [Interaktyvus resursas]. Žiūrėta 2019 12 31. Prieiga per: <https://sites.google.com/site/sidneydmello/bixler-iui2013.pdf>
 16. GIRI, Vijai N. Culture and communication style. The Review of Communication, 2006, 6.1-2: 124-130.
 17. MITKUS, Tomas. Neverbalinė komunikacija: kodavimas ir efektyvus panaudojimas kūrybinėse industrijose. Santalka: filosofija, komunikacija, 2012, 20.2: 159-170. [Interaktyvus resursas]. Žiūrėta 2021 01 21. Prieiga per <https://etalpykla.lituanistikadb.lt/object/LT-LDB-0001:J.04~2012~1367186339611/J.04~2012~1367186339611.pdf>
 18. BIRDWHISTELL, Ray L. Introduction to kinesics: An annotation system for analysis of body motion and gesture. Department of State, Foreign Service Institute, 1952.
 19. EKMAN, Paul; FRIESEN, Wallace V. Nonverbal behavior and psychopathology. *The psychology of depression: Contemporary theory and research*, 1974, 3-31.
 20. EKMAN, Paul. Methods for measuring facial action. *Handbook of methods in nonverbal behavior research*, 1982, 45-90. [Interaktyvus resursas]. Žiūrėta 2021 01 21. Prieiga per <https://www.paulekman.com/wp-content/uploads/2013/07/Analyzing-Nonverbal-Behavior.pdf>
 21. NIKITINAITĖ, Lina, et al. Tarpkultūrinės kompetencijos aspektai: neverbalinės komunikacijos reikšmė mokymosi procese. Socialinis ugdymas, 2019, 51.1: 76-82. [Interaktyvus resursas]. Žiūrėta 2021 01 24. Prieiga per: <https://repository.mruni.eu/bitstream/handle/007/16123/49425202..pdf>

22. BLATCHFORD, Peter; BASSETT, Paul; BROWN, Penelope. Examining the effect of class size on classroom engagement and teacher–pupil interaction: Differences in relation to pupil prior attainment and primary vs. secondary schools. *Learning and Instruction*, 2011, 21.6: 715-730. [Interaktyvus resursas]. Žiūrėta 2021 01 24 Prieiga per: <https://www.classsizematters.org/wp-content/uploads/2011/04/Examining-the-effect-of-class-size-on-classroom-engagement-and-Teacher-pupil-interaction-Differences-in-relation-to-pupil-prior-attainment-and-primary-vs.-secondary-schools.pdf> [Interaktyvus resursas].
23. FENOLLAR, Pedro; ROMÁN, Sergio; CUESTAS, Pedro J. University students' academic performance: An integrative conceptual framework and empirical analysis. *British Journal of Educational Psychology*, 2007, 77.4: 873-891. [Interaktyvus resursas]. Žiūrėta 2021 01 24 Prieiga per: https://www.researchgate.net/profile/Pedro_Cuestas_Diaz/publication/23534566_The_Perceptions_of_Consumers_Regarding_Online_Retailers%27_Ethics_and_Their_Relationship_with_Consumers%27_General_Internet_Expertise_and_Word_of_Mouth_A_Preliminary_Analysis/links/5f4f64b6458515e96d22bca9/The-Perceptions-of-Consumers-Regarding-Online-Retailers-Ethics-and-Their-Relationship-with-Consumers-General-Internet-Expertise-and-Word-of-Mouth-A-Preliminary-Analysis.pdf
24. YOUNG, Mark S.; ROBINSON, Stephanie; ALBERTS, Phil. Students pay attention! Combating the vigilance decrement to improve learning during lectures. *Active Learning in Higher Education*, 2009, 10.1: 41-55. [Interaktyvus resursas]. Žiūrėta 2021 01 24. Prieiga per: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.975.599&rep=rep1&type=pdf>
25. MOLLAHOSSEINI, Ali; HASANI, Behzad; MAHOOR, Mohammad H. Affectnet: A database for facial expression, valence, and arousal computing in the wild. *IEEE Transactions on Affective Computing*, 2017, 10.1: 18-31. [Interaktyvus resursas]. Žiūrėta 2021 03 24. Prieiga per: <https://www.frontiersin.org/articles/10.3389/fpsyg.2020.01388/full?report=reader>
26. HÖFLING, T. Tim A., et al. Read my face: Automatic facial coding versus psychophysiological indicators of emotional valence and arousal. *Frontiers in psychology*, 2020, 11: 1388. [Interaktyvus resursas]. Žiūrėta 2021 03 25. Prieiga per: <https://www.frontiersin.org/articles/10.3389/fpsyg.2020.01388/full?report=reader>
27. EKMAN, Paul. Atlas of Emotion. 2018.
28. EKMAN, Paul; FRIESEN, Wallace V. Felt, false, and miserable smiles. *Journal of nonverbal behavior*, 1982, 6.4: 238-252.
29. LOZA, David, et al. Application of the FACS in the Design and Construction of a Mechatronic Head with Realistic Appearance. 2013. [Interaktyvus resursas]. Žiūrėta 2021 03 26. Prieiga per: http://rua.ua.es/dspace/bitstream/10045/26260/1/JoPhA_07_01_05.pdf
30. LEWINSKI, Peter; DEN UYL, Tim M.; BUTLER, Crystal. Automated facial coding: Validation of basic emotions and FACS AUs in FaceReader. *Journal of Neuroscience, Psychology, and Economics*, 2014, 7.4: 227. [Interaktyvus resursas]. Žiūrėta 2021 03 27. Prieiga per: https://www.researchgate.net/profile/Peter_Lewinski2/publication/266298566_Automated_facial_coding_validation_of_basic_emotions_and_facs_au_recognition_in_noldus_facereader/links/55ffdb0d08ae07629e51de1e.pdf
31. ZHANG, Li, et al. Intelligent facial emotion recognition and semantic-based topic detection for a humanoid robot. *Expert Systems with Applications*, 2013, 40.13: 5160-5168.

32. DU, Shichuan; TAO, Yong; MARTINEZ, Aleix M. Compound facial expressions of emotion. *Proceedings of the National Academy of Sciences*, 2014, 111.15: E1454-E1462. [Interaktyvus resursas]. Žiūrėta 2021 03 27. Prieiga per: <https://www.pnas.org/content/pnas/111/15/e1454.full.pdf>
33. SCHLOSBERG, Harold. The description of facial expressions in terms of two dimensions. *Journal of experimental psychology*, 1952, 44.4: 229.
34. RUSSELL, James A. A circumplex model of affect. *Journal of personality and social psychology*, 1980, 39.6: 1161.
35. LANG, Peter J., et al. Motivated attention: Affect, activation, and action. *Attention and orienting: Sensory and motivational processes*, 1997, 97: 135.
36. LARSEN, Randy J.; DIENER, Ed. Affect intensity as an individual difference characteristic: A review. *Journal of Research in personality*, 1987, 21.1: 1-39.
37. DIENER, Ed, et al. Intensity and frequency: dimensions underlying positive and negative affect. *Journal of personality and social psychology*, 1985, 48.5: 1253.
38. SCHULLER, Björn; EYBEN, Florian; RIGOLL, Gerhard. Static and dynamic modelling for the recognition of non-verbal vocalisations in conversational speech. In: *International Tutorial and Research Workshop on Perception and Interactive Technologies for Speech-Based Systems*. Springer, Berlin, Heidelberg, 2008. p. 99-110. [Interaktyvus resursas]. Žiūrėta 2021 04 07. Prieiga per: <https://mediatum.ub.tum.de/doc/980135/file.pdf>
39. ABERCROMBIE, David. Paralanguage. *British journal of disorders of communication*, 1968, 3.1: 55-59.
40. CRYSTAL, David; QUIRK, Randolph. *Systems of prosodic and paralinguistic features in English*. De Gruyter Mouton, 1964.
41. SCHANDORF, Michael. Mediated gesture: Paralinguistic communication and phatic text. *Convergence*, 2013, 19.3: 319-344. [Interaktyvus resursas]. Žiūrėta 2021 02 21 Prieiga per: https://www.researchgate.net/profile/MichaelSchandorf/publication/258129802_Mediated_gesture_Paralinguistic_communication_and_phatic_text/links/02e7e52dd5abcbe6f5000000/Mediated-gesture-Paralinguistic-communication-and-phatic-text.pdf
42. SOLANKI, Rinky; SHUKLA, Pragma. Estimation of the User's Emotional State by Keystroke Dynamics. *International Journal of Computer Applications*, 2014, 94.13. [Interaktyvus resursas]. Žiūrėta 2021 02 21 Prieiga per: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.682.6545&rep=rep1&type=pdf>
43. EPP, Clayton; LIPPOLD, Michael; MANDRYK, Regan L. Identifying emotional states using keystroke dynamics. In: *Proceedings of the sigchi conference on human factors in computing systems*. ACM, 2011. p. 715-724. [Interaktyvus resursas]. Žiūrėta 2020 02 21 Prieiga per: <http://www.hci.usask.ca/uploads/203-p715-epp.pdf>
44. TAO, Jianhua; TAN, Tieniu. Affective computing: A review. In: *International Conference on Affective computing and intelligent interaction*. Springer, Berlin, Heidelberg, 2005. p. 981-995. [Interaktyvus resursas]. Žiūrėta 2020 02 21 Prieiga per: https://www.researchgate.net/profile/Jianhua_Tao/publication/220270285_Affective_Computing_A_Review/links/0c9605322563305a8e000000/Affective-Computing-A-Review.pdf
45. CHAOUACHI, Maher, et al. Affect and mental engagement: towards adaptability for intelligent systems. In: *Proceedings of the 23rd International FLAIRS Conference*. Daytona Beach, FL:

- Citeseer, 2010. [Interaktyvus resursas]. Žiūrėta 2020 03 21. Prieiga per: <https://www.hindawi.com/journals/ahci/2014/632630/abs/>
46. JONES, Michael; VIOLA, Paul. Fast multi-view face detection. Mitsubishi Electric Research Lab TR-20003-96, 2003, 3.14: 2. [Interaktyvus resursas]. Žiūrėta 2019 11 21. Prieiga per: https://www.researchgate.net/profile/Michael_Jones20/publication/228362107_Fast_multi-view_face_detection/links/0fcfd50d35f8570d70000000.pdfview_face_detection/links/0fcfd50d35f8570d70000000.pdf
47. WILSON, Phillip Ian; FERNANDEZ, John. Facial feature detection using Haar classifiers. *Journal of Computing Sciences in Colleges*, 2006, 21.4: 127-133. . [Interaktyvus resursas]. Žiūrėta 2019 11 21. Prieiga per: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.159.8722&rep=rep1&type=pdf>
48. MCCONNELL, Robert K. *Method of and apparatus for pattern recognition*. 1986.
49. DALAL, Navneet; TRIGGS, Bill. Histograms of oriented gradients for human detection. In: *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)*. Ieee, 2005. p. 886-893. [Interaktyvus resursas]. Žiūrėta 2019 12 01. Prieiga per: https://hal.inria.fr/docs/00/54/85/12/PDF/hog_cvpr2005.pdf
50. JULINA, J. Kulandai Josephine; SHARMILA, T. Sree. Facial recognition using histogram of gradients and support vector machines. In: *2017 International Conference on Computer, Communication and Signal Processing (ICCCSP)*. IEEE, 2017. p. 1-5. [Interaktyvus resursas]. Žiūrėta 2019 12 01. Prieiga per: https://www.researchgate.net/profile/Josephine_Julina_J_K/publication/317418143_Facial_recognition_using_histogram_of_gradients_and_support_vector_machines/links/5a02cf214585155c96d2a83a/Facial-recognition-using-histogram-of-gradients-and-support-vector-machines.pdf
51. DÉNIZ, Oscar, et al. Face recognition using histograms of oriented gradients. *Pattern Recognition Letters*, 2011, 32.12: 1598-1603. [Interaktyvus resursas]. Žiūrėta 2019 12 01. Prieiga per: <https://lms.ctl.cyut.edu.tw/sysdata/26/21126/doc/555f4d2e898da8b3/attach/994939.pdf>
52. ZHANG, Kaipeng, et al. Joint face detection and alignment using multitask cascaded convolutional networks. *IEEE Signal Processing Letters*, 2016, 23.10: 1499-1503. [Interaktyvus resursas]. Žiūrėta 2021 02 01. Prieiga per: <https://arxiv.org/pdf/1604.02878>
53. PEÑA, Alejandro, et al. Facial Expressions as a Vulnerability in Face Recognition. *arXiv preprint arXiv:2011.08809*, 2020. [Interaktyvus resursas] Žiūrėta 2021 03 01. Prieiga per: <https://arxiv.org/pdf/2011.08809>
54. MOHAMMADI, Mohammad Reza; FATEMIZADEH, Emad; MAHOOR, Mohammad H. PCA-based dictionary building for accurate facial expression recognition via sparse representation. *Journal of Visual Communication and Image Representation*, 2014, 25.5: 1082-1092. [Interaktyvus resursas] Žiūrėta 2021 03 01. Prieiga per: https://www.academia.edu/download/53264043/PCA-based_dictionary_building_for_accura20170524-8067-1kg0svv.pdf
55. CHEN, Jiachen; JENKINS, W. Kenneth. Facial recognition with PCA and machine learning methods. In: *2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS)*. IEEE, 2017. p. 973-976. [Interaktyvus resursas] Žiūrėta 2021 03 01. Prieiga per: https://www.researchgate.net/profile/Kenneth_Jenkins2/publication/320603402_Facial_recognit

- ion_with_PCA_and_machine_learning_methods/links/5e9324d0a6fdcca7890ef5e2/Facial-recognition-with-PCA-and-machine-learning-methods.pdf
56. TURK, Matthew A.; PENTLAND, Alex. Face Recognition without Features. In: *MVA*. 1990. p. 267-270. [Interaktyvus resursas] Žiūrėta 2021 03 01. Prieiga per: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.139.1525&rep=rep1&type=pdf>
 57. CHOI, Jae Young; PLATANIOTIS, Konstantinos N.; RO, Yong Man. Using colour local binary pattern features for face recognition. In: *2010 IEEE International Conference on Image Processing*. IEEE, 2010. p. 4541-4544. [Interaktyvus resursas] Žiūrėta 2021 04 01. Prieiga per: <https://koasas.kaist.ac.kr/bitstream/10203/22823/1/USING%20COLOUR%20LOCAL%20BINARY%20PATTERN%20FEATURES%20FOR%20FACE%20RECOGNITION.pdf>
 58. AHMED, Faisal, et al. Compound local binary pattern (CLBP) for robust facial expression recognition. In: *2011 IEEE 12th International Symposium on Computational Intelligence and Informatics (CINTI)*. IEEE, 2011. p. 391-395. [Interaktyvus resursas] Žiūrėta 2021 04 01. Prieiga per: https://www.researchgate.net/profile/Yongsheng_Gao2/publication/224611962_Local_Derivative_Pattern_Versus_Local_Binary_Pattern_Face_Recognition_With_High-Order_Local_Pattern_Descriptor/links/0fcfd510344e6d065c000000/Local-Derivative-Pattern-Versus-Local-Binary-Pattern-Face-Recognition-With-High-Order-Local-Pattern-Descriptor.pdf
 59. KAZEMI, Vahid; SULLIVAN, Josephine. One millisecond face alignment with an ensemble of regression trees. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2014. p. 1867-1874. [Interaktyvus resursas] Žiūrėta 2021 04 05. Prieiga per: http://openaccess.thecvf.com/content_cvpr_2014/papers/Kazemi_One_Millisecond_Face_2014_CVPR_paper.pdf
 60. KOLLIAS, Dimitrios, et al. Analysing Affective Behavior in the First ABAW 2020 Competition. In: *2020 15th IEEE International Conference on Automatic Face and Gesture Recognition (FG 2020)(FG)*. IEEE Computer Society. p. 794-800.
 61. KOLLIAS, Dimitrios; ZAFEIRIOU, Stefanos. Expression, Affect, Action Unit Recognition: Aff-Wild2, Multi-Task Learning and ArcFace.
 62. KOLLIAS, Dimitrios; SHARMANSKA, Viktoriia; ZAFEIRIOU, Stefanos. Face Behavior a la carte: Expressions, Affect and Action Units in a Single Network. *arXiv e-prints*, 2019, arXiv: 1910.11111.
 63. KOLLIAS, Dimitrios, et al. Deep affect prediction in-the-wild: Aff-wild database and challenge, deep architectures, and beyond. *International Journal of Computer Vision*, 2019, 127.6: 907-929.
 64. ZAFEIRIOU, Stefanos, et al. Aff-wild: valence and arousal 'In-the-Wild' challenge. In: *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*. 2017. p. 34-41.
 65. KOLLIAS, Dimitrios, et al. Recognition of affect in the wild using deep neural networks. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. 2017. p. 26-33.
 66. ILONEN, Jarmo. Keystroke dynamics. *Advanced Topics in Information Processing-Lecture*, 2003, 03-04. [Interaktyvus resursas] Žiūrėta 2021 04 05. Prieiga per: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.99.9014&rep=rep1&type=pdf>
 67. KHANNA, Preeti; SASIKUMAR, Mukundan. Recognising emotions from keyboard stroke pattern. *International journal of computer applications*, 2010, 11.9: 1-5. [Interaktyvus resursas]

Žiūrėta 2021 04 05. Prieiga per:
[https://www.academia.edu/download/45795162/Recognising Emotions from Keyboard Strok
20160519-7171-2jl0y0.pdf](https://www.academia.edu/download/45795162/Recognising_Emotions_from_Keyboard_Strok_20160519-7171-2jl0y0.pdf)

68. BIXLER, Robert; D'MELLO, Sidney. Detecting boredom and engagement during writing with keystroke analysis, task appraisals, and stable traits. In: Proceedings of the 2013 international conference on Intelligent user interfaces. ACM, 2013. p. 225-234. [Interaktyvus resursas] Žiūrėta 2021 04 05. Prieiga per: <https://sites.google.com/site/sidneydmello/bixler-iui2013.pdf>
69. SHIKDER, Rayhan, et al. Keystroke/mouse usage based emotion detection and user identification. In: *2017 International Conference on Networking, Systems and Security (NSysS)*. IEEE, 2017. p. 96-104. [Interaktyvus resursas] Žiūrėta 2021 04 05. Prieiga per: https://www.researchgate.net/profile/Rayhan_Shikder/publication/315865602_Keystrokemouse_usage_based_emotion_detection_and_user_identification/links/5a83aa760f7e9bda86a46451/Keystroke-mouse-usage-based-emotion-detection-and-user-identification.pdf
70. KOŁAKOWSKA, Agata. Usefulness of keystroke dynamics features in user authentication and emotion recognition. In: *Human-Computer Systems Interaction*. Springer, Cham, 2018. p. 42-52.
71. OSHIRO, Thais Mayumi; PEREZ, Pedro Santoro; BARANAUSKAS, José Augusto. How many trees in a random forest?. In: *International workshop on machine learning and data mining in pattern recognition*. Springer, Berlin, Heidelberg, 2012. p. 154-168. [Interaktyvus resursas] Žiūrėta 2021 04 05. Prieiga per: https://www.researchgate.net/profile/Jose_Baranauskas/publication/230766603_How_Many_Trees_in_a_Random_Forest/links/0912f5040fb35357a1000000/How-Many-Trees-in-a-Random-Forest.pdf
72. MAALEJ, Aicha; KALLEL, Ilhem. Does Keystroke Dynamics tell us about Emotions? A Systematic Literature Review and Dataset Construction. In: *2020 16th International Conference on Intelligent Environments (IE)*. IEEE, 2020. p. 60-67.