



VILNIAUS UNIVERSITETAS
MATEMATIKOS IR INFORMATIKOS FAKULTETAS
INFORMATIKOS STUDIJŲ PROGRAMA

**Skatinamojo mokymosi modelis, palengvinantis bendravimą
autizmo spektro sutrikimą turintiems vaikams**

**Reinforcement learning model for facilitating
communication for children with autism spectrum disorder**

Baigiamasis magistro darbas

Atliko: Andrius Lukas Maslovas

Vadovas: Doc., dr. Asta Slotkienė

Vilnius – 2026

Padėka

Darbo autorius dėkoja Vilniaus universiteto ligoninės Santaros klinikų vaiko raidos centro specialistams už suteiktą informaciją apie autizmo spektro sutrikimą turinčių vaikų elgsenos scenarijus, kurie padėjo modeliuoti skatinamojo mokymosi algoritmus.

Santrauka

Autizmo spektro sutrikimą turintys vaikai dažnai susiduria su bendravimo sunkumais, dėl šios priežasties yra svarbu ieškoti sprendimų, galinčių palengvinti jų komunikaciją. Skatinamojo mokymosi metodų ir paveikslėlių apsikeitimo komunikacijos sistemų (toliau – PECS) suderinimas suteikia galimybę individualizuoti komunikacines sistemas, siekiant pagerinti vaikų socialinius gebėjimus, pagal jų individualius poreikius. Darbe yra siekiama pasiūlyti skatinamojo mokymosi modelį, kuris padėtų autizmo spektro sutrikimą turintiems vaikams efektyviau bendrauti naudojant PECS korteles ir emocijų atpažinimą. Tyrimo metu sukurtas ir ištirtas „CardFinder+ Sense“ algoritmas, gebantis išmokti pasiūlyti teisingą PECS kortelę. Gauti rezultatai parodė, kad tam tikrais atvejais emocijų duomenų integravimas algoritmui pagerino modelio efektyvumą.

Raktiniai žodžiai – skatinamasis mašininis mokymasis, autizmo spektro sutrikimas, PECS, veido emocijos atpažinimas.

Summary

Children with autism spectrum disorder often face communication difficulties, therefore it is important to seek solutions that could enhance their communication. The combination of reinforcement learning methods and the Picture Exchange Communication System (hereinafter - PECS) provides a way to individualize communication systems in order to improve children's social skills according to their individual needs. The aim of this thesis is to propose a reinforcement learning model that would help children with autism spectrum disorder communicate more effectively using PECS cards and emotion recognition. During the research, the „CardFinder+ Sense“ algorithm was developed and investigated, which is capable of learning to suggest the correct PECS card. The obtained results showed that, in certain cases, the integration of emotion data into the algorithm improved the model's effectiveness.

Keywords - reinforcement learning, autism spectrum disorder, PECS, facial emotion recognition.

Turinys

Ivadas	6
1. Autizmo spektro sutrikimo analizė ir mašininio mokymosi tyrimai	9
1.1. Autizmo spektro sutrikimo analizė	9
1.1.1. Komunikacijos sunkumai	10
1.1.2. Kognityviniai ir mokymosi skirtumai	11
1.1.3. Taikomi sprendimai problemai	11
1.2. Mašininio mokymosi tyrimai autizmo spektro sutrikimo srityje	12
1.2.1. Mašininio mokymosi technologijų analizė	14
1.2.2. Skatinamasis mokymasis ir jo pritaikymas	17
1.2.3. Veido ir emocijos atpažinimas, jam taikomos technologijos	22
1.2.4. Kitų autorių tyrimai	23
1.2.5. Duomenų rinkinių palyginimas	25
1.3. Išvados	28
2. Skatinamojo mokymosi modelio sudarymo metodologija, tyrimai ir rezultatai .	29
2.1. Skatinamojo mokymosi modelio sudarymo metodologija	29
2.1.1. Augusto Mikulėno „CardFinder“ algoritmo analizė	29
2.1.2. Modelio rezultato stabilizavimo metodologija	33
2.1.3. Modelio rezultato gerinimo metodologija	34
2.1.4. Veido emocijos duomenų integravimo metodologija	34
2.1.5. Kelių aplinkų pritaikymo metodologija	35
2.2. Modelio tyrimai ir rezultatai	36
2.2.1. Modelio rezultato stabilizavimo eksperimentai	36
2.2.2. Modelio rezultato gerinimo eksperimentai	38
2.2.3. Veido emocijos duomenų pritaikymas algoritmo naudojimui	42
2.2.4. Mokymosi ir testavimo keliose aplinkose pritaikymas	45
2.3. Modelio analizė	47
2.4. Modelio validavimas	49
2.5. Tyrimo apibendrinimas	50
Rezultatai ir išvados	52
Literatūra ir šaltiniai	53
Terminų ir santrumpų žodynas	60
Priedas 1. Darbo temos pristatymo pažymėjimas „Lietuvos magistrantų informati- kos ir IT tyrimai“ VII-ojoje konferencijoje	61

Įvadas

Temos aktualumas ir naujumas. Komunikacija yra viena iš svarbiausių žmonijos egzistencijos dalių ir yra neatsiejama nuo kasdienio gyvenimo. Ji naudojama ekspresijai, socialinių ryšių kūrimui ir plėtojimui, mokymuisi ir savęs tobulinimui ar kitokiam informacijos perteikimui. Šis gyvenimiškas aspektas yra itin svarbus, kai žmogus dar auga, kad perteiktų savo išgyvenimui reikalingus norus, pavalgyti, atsigerti ar miegoti. Deja, egzistuoja faktorių, dėl kurių žmonių grupėms yra sunkiau komunikuoti. Viena iš tokių žmonių grupių yra autizmo spektro sutrikimą (toliau – ASS) turintys asmenys. ASS – tai įvairių neurologinės raidos būklių grupė, kuriai charakteringi socialiniai ir bendravimo sunkumai, elgesio ypatumai, dėmesys detalėms arba neįprastos reakcijos į veiksmus [Wor23]. ASS turintys asmenys, ypač vaikai, vietoje kalbos, savo komunikaciją perteikia įvairiais veiksmais – kūno kalba, veido mimika, garsais, emocija, ar naudojantis kokiais nors daiktais.

Šiuo metu, yra kuriamos ir tobulinamos sistemos, kurios palengvina bendravimą asmenims, turintiems komunikacijos sutrikimų. S. A. Sankardas ir J. Rajanahally autorių išleistame straipsnyje yra aptariama, kaip veiksmingai planšetinis kompiuteris su AVAZ programine įranga padeda ASS turintiems vaikams mokykloje. Ši sistema – tai alternatyviosios ir papildomosios komunikacijos priemonė, skirta asmenims, turintiems kalbinio bendravimo sunkumų ir pritaikyta Indų kalbai. Ji gali būti naudojama, kad išreikšti naudotojo norus, mintis ar jausmus. Tyrimo metu užfiksuota, kad visi vaikai buvo suinteresuoti naudotis jiems pateiktu įrankiu ir jų mokytojai pastebėjo, kad vaikų dėmesingumas pagerėjo, kai buvo pasitelkta naudotis planšetiniu kompiuteriu [SR17].

2023 metų straipsnyje yra aprašomas eksperimentas, kuris vyko keliais etapais, pasitelkiant humanoidinį robotą ir planšetinio kompiuterio tipo įrenginį. Dalyviams buvo rodomos nuotraukos planšetėje arba jos buvo pateikiamos balsu, roboto pagalba. Jose atsispindi viena ar kita istorija. Tuo metu dalyviai turėjo atspėti istorijos perteikiama emociją. Yra pastebėta, jog vaikai sutelkia daugiau dėmesio į planšetinį kompiuterį, negu į robotą, kuris primena vaiką iš animacinio filmo [SPS⁺23]. Tyrimas parodo, kad naujos technologijos yra įdomios ir intriguojančios ASS turintiems asmenims.

Paveikslėlių apsikeitimo komunikacijos sistema (toliau – PECS), yra viena populiariesnių efektyvių komunikacijos sistemų [LEC⁺13]. T. Ariwijaya savo darbe mini, kad tyrimai rodo PECS veiksmingumą didinant komunikacijos įgūdžius ir savarankiškumą priimant sprendimus tarp ASS turinčių asmenų. Taip pat sujungiant PECS ir planšetinį kompiuterį kaip intervenciją mokymosi tikslais, gali pagerinti šiuos rezultatus [Ari20]. Esant pasirinkimui, koku būdu komunikuoti, naudotis – PECS, ženklais ar kalba, tyrimo rezultatuose matoma, kad naudojimasis PECS kortelėmis buvo pageidaujamas metodas ASS turinčiam asmeniui dalyvaujančiam tyrime [RMB20].

Paskutiniu metu, dirbtinio intelekto (toliau – DI) naudojimas, vienaip ar kitaip, tampa kasdienybe. Vis daugiau žmonių pasitelkia DI įrankius informacijos paieškai ar kasdinių užduočių sprendimui palengvinti. Tuo pačiu, yra bandoma pasitelkti į tokio tipo įrankius, kad palengvinti tarpusavio komunikaciją. Straipsnyje, išleistame 2017 metais, yra nagrinėjama, kaip DI įrankiai gali padėti vaikams bendrauti ir mokytis, atsižvelgiant į tam tikrus socialinius ženklus. Buvo nagrinėjami DI įrankiai naudojantys įvairius sensorius, kad atpažinti veido mimiką, kūno kalbą ir skleidžiamus

garsus. Tyrimai parodo, kad DI įrankiai teigiamai įtakoja mokymosi sugebėjimus. Iš straipsnyje pateiktųjų duomenų yra matoma, kad skaitmenines programas, komunikacijos gerinimui, yra daugiausia kuriama pritaikymui ASS turintiems vaikams [BVG⁺22].

C. Aldred paskelbtame straipsnyje apie vaikų autizmo komunikacijos terapiją galima įžvelgti, kad naudojamas metodas gali būti pasiekiamas pasitelkiant į mašininio mokymo metodus (toliau – MM). Terapijos metu yra naudojama vaizdo medžiaga, kurioje yra trumpai užfiksuojamas bendravimas arba žaidimas su vaiku. Vėliau įrašas yra peržvelgiamas ir įvertinamas terapeuto, kad pasiūlyti naujas strategijas, ką išmėginti sekančio užsiėmimo su vaiku metu. Ankstyvos socialinės intervencijos rodo pagerėjimą vaikų socialiniame įsitraukime [Ald23]. Tokio pobūdžio metodologija gali būti pritaikyta su MM, kad nereikėtų ryšio tarp terapeuto ir vaizdo medžiagos, kad įvertinti ir pasiūlyti naujas strategijas komunikacijos gerinimui.

Paprasčiausi skatinamojo mokymosi (toliau – SK) algoritmai remiasi mintimi – jeigu po veiksmo seka teigiamas atoveiksmis arba situacijos pagerėjimas, tuomet tendencija atlikti tą patį veiksmą yra sustiprinama [BD08]. Straipsnyje, paskelbtame 2019 metais, yra kalbama apie pagalbinę terapinę sistemą vaikams, turintiems ASS, kuri paremta skatinamojo mokymosi metodais, kad atpažinti emociją iš veido mimikos. Tyrimo metu, buvo atlikti socialinio reagavimo skalės (toliau – SRS) [Bol11] matavimai, kurie skirti įvertinti simptomų pokyčius po terapijos. Atlikus tyrimus, daugumai ASS turinčių vaikų SRS įvertinimo balas tapo mažesnis, tačiau terapinis poveikis vaikų bendravimo sugebėjimams buvo skirtingas [LLX⁺19]. Straipsnyje minima, kad terapinis efektas gali būti tiriamas giliau, dėl nedidelio kiekio dalyvių ir trumpų terapijos sesijų būvimo tyrimo metu.

Skatinamojo mokymo metodai yra taikomi įvairioms programinėms įrangoms. 2019 metų straipsnyje kalbama, kaip mokymosi strategijos apimančios SK metodus padeda pagerinti socialinį vaiko elgesį [AMA⁺19]. Tyrimo metu buvo naudojama roboto intervencija, kad atpažinti, kas labiauusiai stimuliuoja vaiką – spalvų variacijos, kalba ar judesiai. Iš gautų rezultatų matoma, kad vizualinė stimuliacija buvo efektyviausia.

Atsižvelgiant į minėtas detales, skatinamojo mokymo metodais paremta ir apmokoma PECS sistema galėtų pagerinti asmenų, turinčių autizmo spektro sutrikimą, komunikacijos sugebėjimus.

Tyrimo objektas – vaikų, turinčių autizmo spektro sutrikimą skaitmenizuotas bendravimas taikant PECS.

Darbo tikslas – pasiūlyti skatinamojo mokymosi modelį, palengvinantį autizmo spektro sutrikimą turinčių vaikų bendravimą, pasitelkiant emocijos nustatymą ir PECS kortelių sistemą.

Darbo uždaviniai:

1. Išnagrinėti autizmo spektro sutrikimą turinčių vaikų elgsenos modelius ir juos galinčius realizuoti skatinamojo mokymosi modelius.
2. Sudaryti skatinamojo mokymosi modelį, ištiriant „CardFinder“ algoritmo stabilumą ir panaudojamumą.
3. Iširti pasiūlytą modelį, integruojant emocijos nuskaitymą iš veido duomenų.

Tyrimo atlikimo planas:

1. Išanalizuoti autizmo spektro sutrikimą turinčių vaikų elgsenos modelius – komunikacijos ir išraiškos būdus.
2. Atlikti sisteminę literatūros analizę apie skatinamojo mokymosi modelių ir metodų pritaikymą autizmo spektro sutrikimą turinčių vaikų elgsenos modelių apmokymui ir pritaikymui.
3. Išanalizuoti ir pasirinkti mašininio mokymo metodus įgalinančius veido mimikos atpažinimą.
4. Sukurti skatinamuoju mokymu grindžiamą modelį, patikrintą pagal tikslumo metrikas ir apmokomą veido mimikos duomenimis.

Hipotezė – skatinamuoju mokymusi grindžiamas modelis, papildomai integruojantis veido emocijos duomenis, efektyviau suranda tinkamą PECS kortelę, sumažindamas reikiamų žingsnių skaičių tikslui pasiekti.

Numatomi rezultatai:

1. Ištirtas ir pasiūlytas tinkamas skatinamojo mokymosi algoritmas ir ištirtos geriausio rezultato vertės.
2. Surastas modelis galintis atpažinti veido emociją ir galintis būti integruojamas skatinamojo mokymuisi grindžiamam modeliui apmokyti.
3. Sukurtas skatinamuoju mokymusi grindžiamas modelis, kuris gali būti apmokomas iš veido emocijos duomenų.

Tyrimo rezultatų sklaida.

Remiantis šio tyrimo rezultatais parengta mokslinė publikacija nacionalinei konferencijai „Lietuvos magistrantų informatikos ir IT tyrimai“. Konferencijos darbų leidinyje publikuotas straipsnis: Andrius Lukas Maslovas, Asta Slotkienė. Sustiprinto mokymosi modelio jautrumo parametrų ir stabilumo tyrimas: PECS kortelių atvejis. Lietuvos magistrantų informatikos ir IT tyrimai: konferencijos darbai, 2026 m. gegužės 6 d., Vilnius: Vilniaus universiteto leidykla. eISSN 2783784X. 2026, p. 158-165. Vilnius University Open Series, eISSN26690535.DOI: <https://doi.org/10.15388/LMITT.2026.17>


Šio tyrimo rezultatai pristatyti stendiniu pranešimu nacionalinėje konferencijoje „Lietuvos magistrantų informatikos ir IT tyrimai“. Andrius Lukas Maslovas, Asta Slotkienė. Sustiprinto mokymosi modelio jautrumo parametrų ir stabilumo tyrimas: PECS kortelių atvejis. 2026 m. gegužės 6 d., Vilnius

1. Autizmo spektro sutrikimo analizė ir mašininio mokymosi tyrimai

1.1. Autizmo spektro sutrikimo analizė

Autizmo spektro sutrikimas dažniausiai diagnozuojamas ankstyvoje vaikystėje, yra sudėtingas, nevienalytis raidos sutrikimas, pasižymintis ankstyvu elgesio sutrikimų, socialinių gebėjimų sutrikimų ir komunikacijos trūkumų pasireiškimu [HMA23]. Pasak JAV ligų kontrolės ir prevencijos centro, ankstyvi ASS požymiai gali būti pastebimi žvelgiant į socialines sąveikas [OOO⁺23]. Keli iš tokių požymių yra – akių kontakto vengimas arba išlaikymas, atsako nebuvimas, kai kreipiamasi į asmenį vardu, žaidimas su žaislais su kaskart pasikartojančiomis manieromis ir smarki reakcija į smulkius pokyčius [OOO⁺23]. ASS turintiems vaikams taip pat būdingi kalbos sutrikimai, nerimo sutrikimai, hiperaktyvumas arba mokymosi sutrikimai [OOO⁺23]. ASS sutrikimą turintys vaikai gali būti yra linkę laikytis rutinos, gali turėti sensorinių sutrikimų, jautrumą arba silpnumą ryškioms spalvoms, tam tikriems garsams ir kitiems pojūčiams [SM23].

Žvelgiant į paskutinių 5 metų užklausų kiekį „Google“ paieškos sistemoje, matome, kad žmonės vis dažniau naršo internete, ieškodami informacijos, apie autizmo spektro sutrikimą (1 paveikslėlis). Yra didelė problema, kad nuo 25% iki 30% vaikų, turinčių ASS, nesugeba komunikuoti kalba arba jie yra įvaldę tik siaurą žodyną (mažesnę negu 30 žodžių) [BCS⁺18a]. Vėluojantis kalbos vystymasis, mokymosi sutrikimai ir sunkumai socialinėse aplinkybėse, dažnai pasireiškia tarp ASS turinčių asmenų, jie dažnai nėra linkę sąveikauti su aplinka, ypač socialiniame aspekte [SSH⁺21]. Vaikų elgesio problemos taip pat gali paveikti tėvų psichologinę savijautą, galimai kelti stresą, depresiją arba nerimą [BML⁺14]. ASS turintiems vaikams yra sunkiau bendrauti, perteikti savo norus ir įsiterpti į socialines veiklas, dėl to kenčia jų raida, tėvams gali tapti emociškai ir psichologiškai sunku, nes vaikui dažniausiai reikia skirti papildomo dėmesio. Yra vykdomi tyrimai, tiek ASS identifikavime, tiek ieškant būdų, kaip vienu ar kitu būdų padėti vaikui mokytis, tobulėti ar išmokyti bendrauti.



1 pav. 5 metų laikotarpio „autism“ raktažodžio „Google“ paieškose rezultatai, iki 2025m. Iš viešai prieinamo „Google Trends“ įrankio [Goo25].

Kalbant apie inovacijas iš diagnostinės pusės, yra bandoma sutrikimą nustatyti ne tik standartiniais mediciniais procesais, bet ir pasinaudojant dirbtinio intelekto pagalba. Spartus dirbtinio intelekto įrankių tobulėjimas skatina pasitelkti juo įvairiuose srityse, siekiant pagerinti rezultatus, greitį ar atrasti ne visada matomus duomenų sąryšius. Yra gausu tyrimų, kaip dirbtinio intelekto įrankiai gali padėti identifikuoti ankstyvus autizmo spektro sutrikimo reiškinius arba yra tiriama kokie DI modeliai pasiekia didžiausią sutrikimo identifikavimo tikslumo rezultatą. Vieno iš tyrimų pateiktų rezultatų matome, kad gilaus mokymosi modeliai sugeba pasiekti iki 87% ASS identifikavimo tikslumo rezultatą [RGB⁺24].

DI įrankiais yra taip pat pasitelkiama ir terapinėms intervencijoms. Yra tiriami poveikiai vaikų mokymosi gebėjimams ties kalbos ar emocijos atpažinimu, kai yra pasitelkiama į žaidimus su integruotomis dirbtinio intelekto priemonėmis. Vienas iš tokių pavydžių – „EMooly“, žaidimas planšetiniame kompiuteryje, kuris papildo tradicines socialines ir emocines intervencijas personalizuotomis istorijomis, didesniu globėjų įsitraukimu ir suteikia smagią ir įtraukiančią veiklą vaikams, turintiems ASS [LLA⁺24]. Žaidime yra naudojamas „GPT-4“ DI modelis, kurio vienas iš pagrindinių tikslų – suprasti ir sugeneruoti natūralios kalbos tekstą, ypač sudėtingesniuose scenarijuose [AAA⁺23]. Šis modelis leidžia žaidime efektyviai sugeneruoti istoriją, pagal individualius vaiko poreikius [LLA⁺24]. Toks žaidimo individualizavimas kiekvienam vaikui gali jį labiau įtraukti į veiklą ir suteikti teigiamą naudą jo ugdymui.

1.1.1. Komunikacijos sunkumai

Kalbos sutrikimai tarp ASS turinčių vaikų pasitaiko ganėtinai dažnai [VSC⁺22], jiems sunku suprasti kalbą arba ją kalbėti. Pokalbis su ASS asmenimis, klinikiniuose tyrimuose būna įvardintas kaip monotoninis, robotinis ar trūkčiojantis [VSC⁺22]. Galime įžvelgti, kokias pasekmes minimi kalbos sutrikimai gali sukelti vaikams. Jiems gali būti sunkiau susirasti draugų, mokytis, būti atstumtam ir to dėl šių priežasčių jaustis emociškai prastai. Suprastėjusios burnos motorinės funkcijos taip pat įtakoja jų komunikabilumą [VSC⁺22].

Vaikams, turintiems autizmo spektro sutrikimą, būdingi neįprasti kalbos ir bendravimo ypatumai, tokie kaip pasikartojanti kalba ar garsai ir keisto pobūdžio manieros [IPR⁺21]. Toks vaiko elgesys gali sukelti sunkumų tėvams, kurie leidžia laiką su vaikais viešose vietose, aplinkiniai žmonės gali neteisingai suprasti ar interpretuoti vaiko elgesį [IPR⁺21].

Komunikacijos sutrikimai tarp autizmo spektro sutrikimą turinčių vaikų yra skirtingų lygių. Dažniausiai ASS turintys vaikai dažniausiai sugeba sekti nesudėtingas instrukcijas, supranta žodžių arba frazių junginius, ištaria pavienius žodžius ir atkreipia dėmesį, kai yra minimas jo vardas, tačiau rečiausiai jiems gaunasi atsakyti sudėtingus klausimus ir sudaryti sakinius [IPR⁺21].

Yra bandoma pritaikyti ir įvertinti skirtingų intervencinių metodų įtaką, kad pagerinti vaikų, turinčių ASS, verbalinį komunikabilumą. 2018 metų atliktame tyrime yra įvertinama taikyta verbalinė intervencija su papildyto komunikabilumo priemonėmis – PECS kortelėmis [BCS⁺18b]. Vaikai kurie naudojami minėtomis kortelėmis buvo labiau linkę bendrauti.

1.1.2. Kognityviniai ir mokymosi skirtumai

Priekinė smegenų sritis yra ypatingai svarbi mąstymo lankstumui ir naujų problemų sprendimui, tuo tarpu smegenų smilkininė sritis yra svarbi gebėjimui atlikti veiksmus tam tikra seka [SFB14]. Neurovizualizavimo tyrimai atskleidė, kad vaikai, turintys autizmo spektro sutrikimą, turi neurologinių skirtumų, kurie gali būti susiję su žmogiškosiomis funkcijomis, ypač tomis, kurios susijusios su mąstymo lankstumu ir gebėjimu spręsti naujas problemas [SFB14].

Viena iš problemų susijusių su autizmo spektro sutrikimu yra tai, kad mokymosi metodai, kurie yra tinkami vienam vaikui, nebūtinai gali būti tinkami kitam. Yra svarbu, kad mokymosi aplinka būtų pritaikyta įvairiems vaikų poreikiams ir pagal jų individualius sugebėjimus, todėl neretai ASS skirtos sistemos bando vienu ar kitu būdu prisitaikyti prie naudotojo poreikių. Bet kuri programinė įranga, kuri skirta mokymosi tikslams, turi turėti galimybę ją personalizuoti arba kaip nors ją keisti [RSG12].

1.1.3. Taikomi sprendimai problemai

Didžioji dalis tyrimų susijusių su autizmo spektro sutrikimu tiria būtent sutrikimo nustatymo problemą. Kad palengvinti specialistų darbą ir suteikti tėvams laisvai prieinamas sąlygas prie įrankių, gebančių šį sutrikimą nustatyti, yra vykdomi tyrimai, kaip gerai tai gali atlikti dirbtinio intelekto metodai. Yra viešai prieinama sistema „Autism AI“, kuri gali nuspėti ar asmuo turi bruožų būdingų autizmo spektro sutrikimui. Ji naudoja dirbtinio intelekto algoritmais, kad numatyti elgsenos bruožus susijusius su ASS [ST20]. Vartotojui yra pateikiami bendriniai klausimai ir klausimai apie jo būdą. Užbaigus testą, duomenys yra sulyginami su duomenimis būdingais tarp ASS turinčių asmenų, kad nustatyti ar jam jie yra būdingi. Teigiama, kad šis metodas sėkmingai atpažįsta ASS būdingus bruožus 96% tikslumu, tačiau šiuo metu metodas yra skirtas tik tiriamaisiais tikslais, o visus gautus atsakymus yra rekomenduojama tikslintis pas medicinos specialistus [ST20].

Kadangi vaikams, turintiems autizmo spektro sutrikimą, yra būdinga turėti mokymosi sugebėjimų skirtumų, yra kuriamos prie jų prisitaikančios sistemos arba sistemų variacijos tinkančios įvairaus būdo vaikams. Panašiu principu „Kinems“ platforma siūlo įvairius kompiuterinius žaidimus vaikams, turintiems mokymosi sutrikimų. Žaidimai yra atrenkami pagal kiekvieno vaiko norus, o jų sudėtingumas gali būti keičiamas, kad išlaikyti vaiko norą žaisti. Tyrimo metu, kai buvo nagrinėjama sistemos nauda ASS turintiems vaikams nustatyta, kad „Kinems“ platformos žaidimai padarė teigiamą įtaką vaikų judrumui [FN25].

Vaikų, turinčių ASS, komunikaciniams gebėjimams lavinti, dažnai yra pasitelkiama į komunikacines sistemas, kaip jau minėtas PECS kortelės (2 paveikslėlis). Kiekviena kortelė atspindi kokį nors daiktą, veiksmą ar emociją. Jos yra dažnai naudojamos vaikų, turinčių komunikacijos problemų. Šiuo metu PECS yra labiausiai naudojama komunikacijos sistema vaikams, turintiems ASS ir komunikacijos sunkumų [SBS⁺21]. Kortelėmis galima naudotis įvairiais būdais, pavyzdžiui, vaikas gali paduoti ar parodyti vieną kortelę tėvams ar prižiūrėtojai, kuri duotų suprasti vaiko norą, arba labiau pažengusių arba užaugusių vaikų atveju, jie gali sudaryti ištisą sakinį, nusakantį veiksmą, daiktą ir pavyzdžiui vietą.



2 pav. PECS kortelių rinkinys [Pre25].

Yra sukurtos įvairios komunikacinio pobūdžio programėlės išmaniesiems įrenginiams. Viena iš tokių programėlių yra įmonės „LITALICO“ – „Card Talk“ [LIT17]. Ji leidžia sudaryti ištisus sakinius pasirenkant PECS korteles ir įgarsina pasirinkimus. Programėlėje yra galimybė naudotis pilną kortelių rinkinį arba apriboti korteles ir sudaryti individualų kortelių rinkinį. Panašaus tipo programėlė yra įmonės „Spoken Inc.“ – „Spoken“ [Spo20]. Joje leidžiama pasirinkti žodžius, kad sudaryti sakinius, kurie tampa įgarsinami. Žodžius galima pridėti arba išmesti iš esamo žodyno. Pagrindinis šios programėlės privalumas yra tai, kad ji mokosi iš naudotojo pasirinkamų žodžių ir bando numatyti kokius žodžius naudotojas galėtų norėti pasirinkti kaip sekančius sakinyje.

Atvejams, kai vaikams yra problematiška išlaikyti dėmesį arba bendrauti, bandoma į intervenciją įtraukti robotą, kuris atstovautų pašnekovą. Be robotų dar yra naudojami planšetiniai kompiuteriai. Technologijų naudojimas intervencijų metu gali skatinti ASS turinčius vaikus labiau įsitraukti į atliekamą veiklą, bei skatinti mokytis. Yra atliekami tyrimai, kokią įtaką vaikui suteikia pagalbiniai socialiniai robotai, kurie naudojami su intencija pagerinti jų komunikacinius gebėjimus. Yra pastebima, kad intervencijų metu, kai užsiėmimo metu buvo naudojamas robotas, vaikai kalbėjosi dažniau, negu atvejais, kai robotas nebuvo naudojamas [SG22].


Autizmo spektro srityje yra išbandomos įvairios skaitmenizuotos technologijos, norint automatizuoti, pagerinti arba taikyti jau taikomus metodus.

1.2. Mašininio mokymosi tyrimai autizmo spektro sutrikimo srityje

Šiais, skaitmeninio amžiaus laikais, gyvenimas yra neatsiejamas be skaitmenizuotų prietaisų, interneto platybų, socialinių tinklų ar kitų informacijos šaltinių. Informacija dalinamės su savo artimaisiais, darbo kolegomis ar bendruomenės dalyviais, dar niekada žmonija neturėjo tokio didelio duomenų kiekio užfiksuoto vienokioje ar kitokioje terpėje. Didelė dalis informacijos yra laisvai prieinama ir yra labai vertinga siekiant atlikti analizę, paskaičiuoti statistiką ar pavyzdžiui būti panaudota mokymosi tikslais. Turint prieigą prie tokio kiekio duomenų, ne visada žmogaus galimybės leidžia jį apčiuopti ar suprasti. Dėl tos priežasties yra kuriami ir nuolat tobulinami automatizuoti duomenų analizavimo ir apdorojimo sprendimai, kaip pavyzdžiui dirbtinis intelektas. DI leidžia

efektyviai interpretuoti didelio masto duomenų rinkinius, rasti paslėptus duomenų sąryšius ar atlikti spėjimus.

Tyrime nagrinėjamas mašininis mokymasis, kuris yra ko ne populiariausia ir labiausiai naudojama DI atšaka (3 paveikslėlis). Jis suteikia galimybę sistemai mokytis pačiai iš turimų duomenų. Įvairūs dirbtinio intelekto metodai yra naudojami įvairiose srityse, kartu ir ASS identifikavimui ir DI panaudojimui intervencijose. Yra tiriami MM metodų rezultatai skirtinguose ASS aspektuose. Pavyzdžiui, mašininis mokymas gali padėti nustatyti ankstyvąją ASS diagnozę įvairaus amžiaus pacientams, vaikams ir suaugusiems [FTS⁺23].



3 pav. *Dirbtinis intelektas ir jo poaibiai (sudaryta remiantis [Sar22]).*

Ankstyva intervencija, kritinio neurologinio vystymosi metu, pagerina ilgalaikius rezultatus, kaip pavyzdžiui lavinant komunikabilumą [MDM⁺22]. Dėl to yra gausu tyrimų ankstyvai ASS diagnozei nustatyti, pasitelkus į DI įrankius. 2022 metų tyrime, yra nagrinėjami mašininio mokymosi metodai, naudojantys akių judesio duomenis, kad identifikuoti ASS. Tyrimo metu, buvo lyginami skirtingi dirbtiniai neuroniniai tinklai (vienas iš MM metodų) ir rezultate, buvo pasiektas 97.60% tikslumas nustatant ASS [ASR⁺22]. Kito tyrimo metu, buvo naudojami MM ir giliojo mokymosi algoritmai naudojantys magnetinio rezonanso vaizdus ASS nustatymui. ASS klasifikavimui buvo palyginamas tikslumo rezultatas tarp atsitiktinio miško (angl. random forest) metodo (MM metodas, jungiantis daugybę sprendimų medžių, kad sumažinti koreliaciją tarp duomenų [SKS24]) ir konvoliucinių neuroninių tinklų (MM metodas naudojantis dirbtinius neuroninius tinklus). Tuo atveju aukščiausią rezultatą pasiekė atsitiktinio miško klasifikavimo metodas, pasiekęs 100% tikslumą [SMW⁺23]. Kadangi magnetinio rezonanso tyrimai yra brangūs, reikalaujantys laiko ir specializuotos technikos, yra atliekami tyrimai, kaip efektyviai MM pagalba galima nustatyti ASS iš veido nuotraukų. 2022 metų tyrime buvo naudojami mašininio mokymosi „AutoML“ metodai, pasitelkiant vaikų veidų nuotraukomis, turinčių autizmo spektro sutrikimą ir neturinčių jo. MM pagalba buvo gautas apytiksliai 96% tikslumas, nustatant sutrikimą vaikams [EYA⁺22].

Kiti, ne ASS klasifikavimo ar identifikavimo tyrimų autoriai, tiria pasiektus rezultatus, kai DI yra naudojamas užsiėmimų metu su ASS turinčiais vaikais, bandant vienaip ir kitaip pritaikyti DI taikomoms intervencijoms. Kadangi autizmo spektro sutrikimą turintiems vaikams taikomos intervencijos dažnai yra individualizuojamos, į jas yra bandoma integruoti MM, kad nustatyti ar pritaikyti personalizuotus sprendimus. 2022 metų tyrime mašininio mokymo pagalba bandoma gauti individualiai pritaikytus gydymo metodus. Lyginant su kliniškai paruoštomis rekomendacijomis, MM metodai teisingai pateikė gydymo rekomendacijas apytiksliai 81-84% tikslumu [KKB⁺22].

Mašininis mokymasis gali būti itin naudingas sprendimas, galintis identifikuoti ASS arba vienu ar kitu būdu suteikti pagalbą vaikams, turintiems autizmo spektro sutrikimą. Tiriant didelius duomenų rinkinius MM gali aptikti detales, kurios įprastai gali likti nepastebėtos, taip pat pagreitinti atitinkamus procesus susijusius su sutrikimo diagnostika.

1.2.1. Mašininio mokymosi technologijų analizė

Mašininis mokymasis – tai duomenų analizės metodas, automatizuojantis analitinio modelio sukūrimą [SA23]. Jis leidžia sistemoms, jų vykdymo metu, automatiškai mokytis ir tobulėti iš savo patirties. MM yra skirstomas į atšakas pagal skirtingas naudojamas mokymosi iš duomenų metodus. Keletas tokių skirstymų yra – prižiūrimas mokymasis (angl. supervised learning), neprižiūrimas mokymasis (angl. unsupervised learning), dalinai prižiūrimas mokymasis (angl. semi-supervised learning) ir skatinamasis mokymasis (angl. reinforcement learning) [Mah⁺20]. Skirtingi MM mokymosi metodai yra dažnai naudojami skirtingiems tikslams pasiekti ir gali būti naudojami pagal tai, kokie duomenys yra turimi ir kokio tipo rezultato yra tikimasi iš duomenų, pavyzdžiui ar yra poreikis nuspėti skaitinę reikšmę ar poreikis klasifikuoti nežinomą objektą pagal jo ypatybes.


Prižiūrimas mokymasis yra naudojamas, kai yra žinoma, kokie yra įvadiniai duomenys ir kokie yra jų išeitiniai duomenys. Šio mokymosi metodo algoritmai sukuria funkciją, kuri sudaro sąryšį tarp įvadinio duomenų ir išeitinių duomenų [Nas17]. Modelio apmokymo procesas, naudojant šį mokymosi metodą, yra skaidomas į du etapus – apmokymo ir testavimo, kas yra būdinga daugumai MM metodų. Apmokymo metu, yra naudojami įvadiniai ir išeitiniai duomenys, kad sukurti modelį. Tuomet modeliui testavimo metu yra pateikiami tik įvadiniai duomenys iš kurių bus spėjami išeitiniai duomenys. Toks mokymosi metodas yra dažniausiai naudojamas klasifikavimo problemoms spręsti [Nas17].

Priešingai negu prižiūrimas mokymasis, neprižiūrimas mokymasis bando rasti sąryšius tarp duomenų, kai rezultatas nėra žinomas. Modelio apmokymo metu yra randamos duomenų savybės. Tuomet testavimo metu apmokytam modeliui yra perduodamos naujos reikšmės, kurios tampa klasifikuojamos pagal prieš tai išmoktas duomenų savybes [Mah⁺20]. Neprižiūrimas mokymosi metodas yra dažnai naudojamas klasterizavimo problemoms (duomenų sugrupavimui).

Dalinai prižiūrimas mokymasis apjungia prižiūrimą ir neprižiūrimą mokymąsi. Jam apmokyti yra naudojami sužymėti duomenys (įvesties duomenys su jiems priklausančiais išeities duomenimis) ir nežymėti duomenys (tik įvesties duomenys). Apmokymo metu yra išvedama funkcija arba klasifikatorius [Nas17].


Visi trys paminėti mašininio mokymosi metodai gali būti pritaikomi tiek dirbtiniuose neuroniniuose tinkluose tiek giliuose neuroniniuose tinkluose. Dirbtiniai neuroniniai tinklai (toliau – DNT) yra apibūdinami kaip struktūra duomenų apdorojimui, susidedanti iš dirbtinių neuronų, turinčių tarpusavio sąryšius. Gilusis mokymasis yra dalis DNT ir yra dažnai naudojamas, kad išspręsti sudėtingas problemas. Jis vadinamas giliuoju, kadangi jo neuroninių tinklų gylis didėja su laiku [DKA⁺20], tai leidžia pasiekti didelį tikslumą sprendžiant problemas, bet dažnai reikalauja didelio kiekio duomenų. Yra skirtingų DNT skirtingoms problemoms ir užduotims spręsti [Ye20]. Keli iš plačiai naudojamų giliųjų neuroninių tinklų tipų [SPM⁺23]:

- Daugiasluoksnis perceptronas (MLP) – susideda iš įvesties, išvesties ir paslėptųjų sluoksnių. Įvesčiai pateikiami duomenys kuriems yra atliekama normalizacija, paslėpti sluoksniai apdoroja duomenis ir galiausiai išvestis atlieka sprendimus arba spėjimus pagal apdorotą informaciją (4 paveikslėlis).
- Konvoliuciniai neuroniniai tinklai (CNN) – automatiškai mokinasi ir atpažįsta reikšmingus parametrus duomenyse. Jie susideda iš konvoliucinių sluoksnių – kurie išskiria individualius parametrus iš įvesties; sujungiančio sluoksnio – skirto pagreitinti tinklų veikimą, pašalinant mažai reikšmingus duomenis; visiškai sujungto sluoksnio – leidžiančio atlikti spėjimus. Jiems gali būti pritaikyti ir giliojo mokymosi metodai (DCNN). Dažnai būna naudojami spręsti problemoms su nuotraukomis [Ye20].
- Pasikartojantys neuroniniai tinklai (RNN) – turi savybę naudoti vidinę atmintį, kad užfiksuoti sekvenčines priklausomybes. Dažnai naudojami teksto generavimui paradižiui [Ye20].



4 pav. Pavienio neurono ir neuronų tinklo struktūra. [KH20]

Skatinamasis mokymasis yra dar viena mašininio mokymosi atšakų, kurioje yra naudojamas vadinamas agentas, kuris bando pasiekti tikslą gaudamas didžiausią atlygį [SMB23]. SK yra viena iš trijų mašininio mokymosi paradigimų, kartu su prižiūrimu ir neprižiūrimu mokymusi [Mah⁺20]. SK veikia Markovo grandinės principu, kur tikimybė pereiti iš vienos būsenos į kitą lemia tik esama būseną [CBC23].



5 pav. Markovo grandinės su tikimybių įverčiais pereiti į kitas būsenas [CBC23].

Pateiktame pavyzdyje (5 paveikslėlis) matoma, kad esant ramybės būsenoje yra didžiausia tikimybė pereiti į įsitraukimo būseną. Esminiai skirtumai tarp Markovo grandinės principų ir skatinamojo mokymosi, kad:

- SK figūruoja agentas, priimančias sprendimus, į kurią būseną pereiti.
- Būsenų įverčiai Markovo grandinėje yra statiniai, nekintantys, o SK jie priklauso nuo agento priimtų sprendimų (pasirinktų būsenų į kurias pereiti).

Skatinamojo mokymosi modeliai yra apmokomi per daugybę agento veiksmų iteracijų, bandant rasti trumpiausią ir rezultatyviausią kelią iki tikslo. Jie yra labai populiarūs kuriant sistemas žaidžiančias kompiuterinius žaidimus. Per daugybę žaidimo etapų SK algoritmai sukuria optimaliausią strategiją kaip ją įveikti.

Regresinė analizė leidžia nagrinėti sąryšius tarp kintamųjų ir turi keturis pagrindinius tikslus: apibūdinti, įvertinti, nuspėti ir kontroliuoti [AY21]. Populiariausia iš jų regresinės analizės metodų yra linijinė analizė, kuri nagrinėja sąryšį tarp priklausomo ir nepriklausomo kintamojo [AY21].

Minėti MM metodai yra vienaip ar taikomi tyrimuose susijusiuose su autizmo spektro sutrikimu, tačiau yra svarbu nustatyti, kurie metodai gali būti panaudojami, kad individualiai atrinkti PECS korteles ASS turintiems vaikams, pagal užfiksuojamą veido emocinę būklę. Tam nustatyti sudaryta MM metodų naudojamų pradinių ir gaunamų duomenų apžvalga (žr. 1 lentelę):

1 lentelė. Skirtingų mašininio mokymosi metodų apžvalga (sudaryta remiantis [AY21] [Mah⁺20])

Metodas	Pradiniai duomenys	Mokymosi būdas	Gaunamas rezultatas
Prižiūrimas mokymasis	Įvesties ir išeities duomenys	Įvesties susiejimas su išeitimi	Įvesčiai priskiriama vertė arba klasė
Dalinai prižiūrimas mokymasis	Įvesties ir išeities duomenys ir įvesties be išeities duomenys	Hybridinis metodas, apjungiantis prižiūrimą ir neprižiūrimą mokymą	Įvesčiai priskiriama vertė arba klasė
Neprižiūrimas prižiūrimas mokymasis	Įvesties be išeities duomenys	Sąryšių atpažinimas	Įvesčiai priskiriama klasė
Gilusis mokymasis	Didelio kiekio įvesties ir išeities duomenys arba įvesties be išeities duomenys	Giliojo neuroninio tinklo taikymas	Priklauso nuo to kur yra pritaikomas
Skatinamasis mokymasis	Įvesties be išeities duomenys	Bandymų ir klaidų metodas	Taisyklės rezultatui pasiekti
Regresinė analizė	Įvesties ir išeities duomenys	Sąryšių atpažinimas	Numatoma skaitinė reikšmė

Kad pasirinkti tinkamą mašininio mokymosi metodą, yra svarbu įvertinti, kokie bus pirminiai duomenys modelio apmokymui ir kokių duomenų yra tikimasi gauti. Atsižvelgiant, kad kiekvienas

autizmo spektro sutrikimą turintis vaikas gali naudotis specifinėmis, pavyzdžiui, pagal jam patinkančią veiklą, PECS kortelėmis ir, kad kortelės bus atrenkamos pagal vaiko atsaką į gaunamas korteles, ne visi MM metodai yra tinkami šiai problemai. Remiantis sudaryta MM skirtumų lentelė, galime teigti, kad:

- Prižiūrimas mokymasis yra netinkamas, nes kiekvienas vaikas gali naudoti skirtingas PECS korteles ir iš anksto nėra žinomi įverčiai, kurie yra būtini algoritmui vykdyti, kokios kortelės ar kortelių kategorijos yra tinkamos naudotojui.
- Dalinai prižiūrimas mokymasis yra netinkamas, nes kiekvienas vaikas gali naudoti skirtingas PECS korteles ir iš anksto nėra žinomi įverčiai, kurie yra būtini algoritmui vykdyti, kokios kortelės ar kortelių kategorijos yra tinkamos naudotojui.
- Neprižiūrimas mokymasis yra tinkamas, nes jis nereikalauja pradinių išvesties duomenų.
- Gilusis mokymasis yra netinkamas, nes jam reikalingas didelis duomenų kiekis, o individualūs vaikų PECS naudojimo įpročiai įvairūs ir gali būti nepakankami.
- Skatinamasis mokymasis yra tinkamas, nes yra sudaromos individualios taisyklės bandymų ir klaidų metodu, tai suteiktų galimybę pritaikyti siūlomas korteles individualiam naudotojui. Tuo pačiu jis pradinių išvesties duomenų.
- Regresinė analizė yra netinkama, nes PECS kortelės atspindi kategorinius duomenis, o ne skaitinius sąryšius.

Mašininio mokymosi metodai, kurie yra tinkami spręsti problemai – pasiūlyti tinkamas PECS korteles atsižvelgiant į veido emocinę reakciją, yra neprižiūrimo mokymosi metodai arba skatinamojo mokymosi metodai. Būtent šiai problemai yra didesnis privalumas naudotis SK metodu, kadangi jie nuolatos mokosi iš saveikų su esama aplinka ir sudaro taisyklės, kad pasiekti maksimalų rezultatą. Toks privalumas koreliuoja su tuo, kad ASS dažnai pasireiškia skirtingai tarp skirtingų asmenų, tuo pačiu PECS kortelės yra įvairios ir ne visi vaikai naudoja tas pačias korteles.

1.2.2. Skatinamasis mokymasis ir jo pritaikymas


Skatinamasis mokymasis yra vienas iš mašininio mokymosi tipų, pasižymintis tuo, kad jame figūruoja vadinamas agentas, kurio užduotis – rasti optimalų kelią iki tikslo. Savo veikimo metu, agentas vykdo atsitiktinius veiksmus, už kuriuos gauna atlygį ir mokinasi vadinamų strategijų (angl. policy), kad išmokti pasirinkti optimalius veiksmus, visumoje gražinančius didžiausią atlygį [PV20]. Ši SK savybė ypatinga tuo, kad algoritmas pats generuoja duomenis sąveikaudamas su aplinka. Dirbtinis intelektas skatinamojo mokymosi pagalba sugebėjo nugalėti žaidimo „Go“ pasaulio čempioną, valdyti robotines rankas ir net nutapyti paveikslą [GO19].

Standartinis skatinamojo mokymosi modelis susideda iš trijų dalių:

- Aplinkos būsenų rinkinio, pavyzdžiui žemėlapiu koordinatės.

- Agento veiksmų rinkinio, pavyzdžiui galimos judėjimo kryptys (pirmyn, atgal).
- Signalų arba atlygių rinkinio, kurie susideda iš elementų 0, 1 arba realūs skaičiai.

Kiekviename žingsnyje, agentas gauna informaciją apie dabartinę aplinką ir galimus veiksmus, tuomet agentui pasirinkus veiksmą, aplinka pasikeičia ir jam yra perduodamas atlygio signalas [KLM96] (6 paveikslėlis). Agento tikslas yra rasti kelią iki galutinio taško, kuris suteiktų aukščiausią atlygio signalų sumą, dar vadinama sudedamuoju atlygiu (angl. cumulative reward), per daugybę bandymų. Kuo didesnis naudojamų duomenų kiekis, tuo apmokymo proceso ilgumas gali eksponentiškai didėti.



6 pav. Standartinis skatinamojo mokymosi modelis (sudaryta remiantis [KLM96]).

Sudedamajam atlygiui G_t formuluoti, galime apibrėžti R_i , kaip atlygį gautą laiko momentu i , tuomet sudedamasis atlygis apibrėžiamas kaip gautų atlygio signalų suma nuo sekančio laiko momento iki paskutinio laiko momento T [Efi24]:

$$G_t = R_{t+1} + R_{t+2} + \dots + R_T. \quad (1)$$

Ši formuluotė yra labai paprasta ir visus atlygio signalus R laiko vienodais, tai pasidaro problematiška, kai užduočiai išspręsti yra reikalingas kuo mažesnis veiksmų kiekis. Dėl šios priežasties dažnai yra naudojamas sudedamasis atlygis G_t su nuolaidos koeficientu γ (angl. discounted cumulative reward). Tuo atveju kiekvienas individualus atlygis sumoje yra padauginamas iš eksponentiškai mažėjančio nuolaidos koeficiento, apibrėžiamo kaip reikšmė tarp 0 ir 1 [Efi24]:

$$G_t = R_{t+1} + \gamma R_{t+2} + \gamma^2 R_{t+3} + \dots \quad (2)$$

Nuolaidos koeficiento įvedimas į funkciją užtikrina, kad agentas prioretizuotų veiksmus per trumpą laiko etapą [Efi24].

Strategija π (angl. policy) tai sąryšis tarp visų įmanomų būsenų $s \in S$ ir tikimybių p atlikti bet kokią galimą veiksmą būsenoje s [Efi24]. Kitaip tariant strategija nusako kokią veiksmą ar veiksmus su kokiomis tikimybės galima atlikti bet kurioje iš būsenų.

Skatinamajame mokyme yra naudojamos vertės funkcijos (angl. value functions), kurios apibūdina kaip gerai ar blogai (iš gaunamo atlygio pusės) yra agentui būti tam tikroje aplinkoje arba pasirinkti atitinkamą veiksmą esamoje būsenoje [Efi24]. Vertės funkcijos yra dviejų rūšių [Efi24]:

- Būsenos vertės funkcija $V(s_t)$ arba V-funkcija – sąryšis tarp kiekvienos aplinkos būsenos ir sudedamojo atlygio kurį gautų agentas, jeigu jis pradėtų nuo tos būsenos pagal specifinę strategiją π . Gali būti išreiškiama kaip 1 dimensijos lentelė $|S|$ ir apibrėžiama kaip:

$$V_\pi(s) \doteq \mathbb{E}_\pi[G_t \mid S_t = s_t], \quad (3)$$

kur $v_\pi(s)$ yra būsenos vertės funkcija specifinei būsenai s ir strategijai π ; $\mathbb{E}_\pi[\cdot]$ numatoma reikšmė; G_t sudedamasis atlygis su nuolaidos koeficientu γ ; S_t aplinkos būsena momento t .

- Veiksmo vertės funkcija $Q(s,a)$ arba Q-funkcija – sąryšis tarp kiekvienos aplinkos būsenos $s \in S$ kartu su visais įmanomais agento veiksmais $a \in A$ ir numatomo atlygio kurį gautų agentas, jeigu jis pradėtų nuo tos būsenos ir pasirinktų atitinkamą veiksmą pagal specifinę strategiją π . Kiekvienai būsenos ir veiksmo porai yra priskiriama vadinama Q-reikšmė (angl. Q-value). Funkcija gali būti išreiškiama kaip lentelė $|S| \times |A|$ ir apibrėžiama kaip:

$$Q_\pi(s_t, a_t) \doteq \mathbb{E}_\pi[G_t \mid S_t = s_t, A_t = a_t], \quad (4)$$

kur $Q_\pi(s_t, a_t)$ yra veiksmo vertės funkcija specifinei būsenos ir veiksmo porai (s_t, a_t) ir strategijai π ; $\mathbb{E}_\pi[\cdot]$ numatoma reikšmė; G_t sudedamasis atlygis su nuolaidos koeficientu γ ; S_t aplinkos būsena momento t ; A_t agento pasirinktas veiksmas momento t .

Skatinamojo mokymosi modeliui apmokyti yra pasitelkiama į skirtingus algoritmus, pagal tai, ar yra iš anksto numatomi įverčiai būsenoms arba atlygiams (vadinama modeliais [KLM96], SK kontekste). Algoritmai pagrįsti modeliais (angl. model-based) gali vykdyti spėjimus apie būsenas ir numatomus atlygius iš iš anksto išmuktų žinių [NRC20]. Tuo tarpu algoritmai nepagrįsti modeliais (angl. model-free) žinias gauna bandymų ir klaidų metodu, kadangi jie neturi išankstinių žinių [NRC20]. Kadangi yra svarbu turėti modelį, gebanti prisitaikyti prie individualių autizmo spektro sutrikimą turinčių vaikų, bus atsižvelgiama tik į algoritmus, kurie nenaudoja modelių, dėl savo savybės keisti rezultato siekimo taktiką daugybės iteracijų metu [NRC20].

Skatinamojo mokymosi algoritmai dar skirstomi pagal tai, ar jie remiasi optimalia strategija (angl. on-policy) ar jomis nesiremia (angl. off-policy) [Kun18]:

- Besiremiantys optimalia strategija algoritmai – agentas mokosi vertės remdamasis dabartiniu veiksmu, gautu iš esamos strategijos.
- Nesiremiantys optimalia strategija algoritmai – agentas mokosi vertės remdamasis veiksmu, gautu iš kitos strategijos. Kitaip tariant šiose algoritmuose yra daugiau negu viena strategija vienu metu.

Skatinamojo mokymosi savybė prisitaikyti prie aplinkos, yra svarbus aspektas mašininio mokymosi pritaikymui autizmo spektro sutrikimų srityje. Kadangi ASS yra būdingi kognityvinių įgūdžių

skirtumai, yra bandoma jiems padėti mokymosi srityje, individualizuojant mokymosi būdus. 2020 metų tyrime yra siūloma mokymo sistema, apjungianti SK algoritmus, kad pasiūlyti individualius klausimus, pagal kiekvieno ASS turinčio studento sugebėjimus [MFG⁺20]. Kadangi SK metodai gali būti pritaikyti įvairiose srityse, bandoma juos integruoti ir į kompiuterinius žaidimus ar į programėles išmaniesiems įrenginiams. Kuriant žaidimus ASS vaikams, yra svarbu suteikti galimybę tėvams ar mokytojams atgrasinti žaidėją nuo tam tikrų poelgių, pavyzdžiui pasikartojančių veiksmų [ZMS14]. Vienas iš pavyzdžių, kai personalizavimas buvo panaudotas žaidime, yra aprašomas 2022 metų tyrime. Jame yra pristatomas kompiuterinis trijų dimensijų žaidimas, kuriame tikslas yra sudaryti produktų sąrašą ir apsipirkti parduotuvėje pagal jį [VBG⁺22]. Kitu atveju, buvo pasitelkta naudoti SK, kad adaptuoti žaidimo sudėtingumą, pagal žaidėjo sugebėjimus [KFP⁺23]. Visų vaikų žaidimo rezultatai, per 10 žaidimo ėjimų, pagerėjo apytiksliai vienodai. Žaidime buvo naudojami SARSA skatinamojo mokymosi algoritmai, kad pritaikyti sudėtingumą pagal individualius vaikų sugebėjimus.

Q-mokymasis (angl. Q-learning) yra vienas iš SK mokymosi algoritmų. Jie suteikia agentams galimybę išmokti veikti optimaliai Markovo grandinėse, patiriant veiksmų pasekmes ir nereikalaui, kad būtų sudaryti grandinių žemėlapių [CD92]. Mokymosi procesas vykdomas tokiu būdu: agentas atlieka veiksmą būdamas tam tikroje būsenoje ir įvertina to veiksmo pasekmes, – atlygį ar bausmę ir numatomą reikšmę būsenos, į kurią patenkama po veiksmo atlikimo [CD92]. Pakartotinai vykdant visus veiksmus visose būsenose, agentas sužino, kurios būsenos yra geriausios, vertinant pagal ilgalaikį atlygį su nuolaidos koeficientu γ [CD92]. Q-mokymosi algoritmų efektyvumas yra tiriamas kartu ir ASS klasifikavimo problemose. Lyginant su kitais MM modeliais, Q-mokymasis pranoko atsitiktinio miško ir sprendimų medžio (angl. decision tree) modelius rezultatu ir išlaikė konkurencingą „F1“ balą [AMS⁺21]. Jeigu modelio „F1“ balas yra aukštesnis už vidutinį „F1“ balą, skaitoma, kad modelis veikia geriau negu vykdant atsitiktinius spėjimus [AMS⁺21].

Q-mokymasis nesiremia optimalia strategija ir nėra pagrįstas modeliu – jo tikslas yra gauti maksimalią Q-reikšmę (sudėtinį atlygį) [Kun18]. Jis nesiremia optimalia strategija, nes optimali Q-reikšmė yra gaunama nepriklausomai nuo agento veiksmų, bet remiantis geriausiu galimu veiksmu. Q-mokymasis atnaujiną Q-reikšmes tokiu būdu:

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha \left[R_{t+1} + \gamma \max_a Q(s_{t+1}, a) - Q(s_t, a_t) \right]. \quad (5)$$

$Q(s_t, a_t)$ yra Q-reikšmė vykdant veiksmą a_t būsenoje s_t , α yra mokymosi dažnis, R_{t+1} yra gautas atlygis po veiksmo a_t , s_{t+1} aplinkos būseną po veiksmo ir $[r_{t+1} + \gamma \max_a Q(s_{t+1}, a) - Q(s_t, a_t)]$ nustato skirtumą tarp esamų ir naujų verčių.

Kad išvengti Q-verčių pervertinimo, yra galimybė naudoti dvigubą Q-mokymą. Pagrindinis skirtumas tarp Q-mokymosi ir dvigubos Q-mokymosi yra tas, kad dvigubas Q-mokymasis naudoja dvi nepriklausomas Q-verčių lenteles (Q_A ir Q_B). Viena lentelė skirta agentui pasirinkti veiksmą, sekanti saugo to veiksmo vertę.

$$Q_A(s_t, a_t) \leftarrow Q_A(s_t, a_t) + \alpha \left[R_{t+1} + \gamma Q_B(s_{t+1}, \arg \max_a Q_A(s_{t+1}, a)) - Q_A(s_t, a_t) \right]. \quad (6)$$

$$Q_B(s_t, a_t) \leftarrow Q_B(s_t, a_t) + \alpha \left[R_{t+1} + \gamma Q_A(s_{t+1}, \arg \max_a Q_B(s_{t+1}, a)) - Q_B(s_t, a_t) \right]. \quad (7)$$

Q-verčių atnaujinimo metu yra atnaujinama Q_A , pagal veiksmų įverčius lentelėje Q_B . Toks atnaujinimas yra naudojamas abiejose lentelėse modelio apmokymo metu, kurią lentelę atnaujinti yra pasirenkama atsitiktiniu būdu, su 50% tikimybe.

Gilusis Q-mokymasis tai Q-mokymo algoritmas, kuris naudoja DNT Q-reikšmėms nustatyti. Ji papildo standartinį Q-mokymosi algoritmą su gebėjimu numatyti Q-reikšmes, net toms būsenos, kurios dar nebuvo matytos ir nėra žinomi galimi veiksmai tose būsenose [Kun18].

Anksčiau minėtasis SARSA algoritmas yra panašaus tipo kaip ir Q-mokymasis, tačiau pagrindinis skirtumas yra tas, kad jis remiasi optimalia (esama) strategija. Optimali Q-reikšmė yra gaunama pagal veiksmus, atliktus remiantis esama strategija. SARSA atnauja Q-reikšmes tokių būdu:

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha [R_{t+1} + \gamma Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t)]. \quad (8)$$

Analogiškai kaip ir Q-mokymosi atveju $Q(s_t, a_t)$ nusako Q-reikšmę vykdant veiksmą ir α nusako mokymosi greitį. Pagrindinis SARSA skirtumas slypi $Q(s_{t+1}, a_{t+1})$, kur a_{t+1} yra konkretus veiksmas sekančioje būsenoje, pasirinktas pagal dabartinę strategiją.

Skatinamojo mokymosi algoritams, kurie remiasi optimalia strategija, papildomai gali būti taikomos optimizacijos, kaip pavyzdžiui proksimalinis strategijos optimizavimas PPO (angl. proximal policy optimisation). Tuo metu kai agentas kaupia duomenis apie būsenas, veiksmus ir atlygius pagal esama strategiją, Q-verčių atnaujinimas paveiks jau sukauptus duomenis, tai dažnai sukelia nestabilumą ir didelę variaciją [Ver24]. PPO agentą išskaido į dvi dalis, agentą, kuris pasirenka veiksmus ir mokosi strategijos ir vertintoją, kuris įvertina V-funkciją [Ver24]. Toks sprendimas leidžia efektyviai tirti naujus veiksmus išlaikant geriausių veiksmų naudojimą.

Q-mokymasis dažniausiai pasiekia rezultatą efektyviau ir sparčiau, negu algoritmai kurie remiasi optimalia strategija [GO19]. Jis bando surasti geriausią kelią iki tikslo visais atvejais, tuo tarpu SARSA mokosi geriausio kelio pagal esamą strategiją.

Įvertinant peržvelgtus skatinamojo mokymosi algoritmus, galime teigti, kad MM pritaikymui PECS kortelių personalizuotam atrinkimui:


- SARSA algoritmai nėra tinkami, dėl to, kad jie remiasi optimalia strategija ir yra mažiau lankstūs. Šiame tyrime yra svarbu išlaikyti kuo lankstesnį personalizavimą, dėl skirtingų ASS turinčių vaikų poreikių ir būdo.
- Gilusis Q-mokymasis yra tinkamas, tačiau būtina atkreipti dėmesį, kad modeliui apmokyti ir pasiekti kokybišką rezultatą reikia didesnio kiekio duomenų.
- Q-mokymasis ir dvigubas Q-mokymasis yra kartu tinkamas, nes optimalią Q-vertę atnauja pagal geriausią galimą veiksmą, suteikdamas didžiausią lankstumą ir tikslumą mokantis iš įvairių veiksmų, nepriklausomai nuo jau atliktų veiksmų.

1.2.3. Veido ir emocijos atpažinimas, jam taikomos technologijos

Bendravimo metu, atpažindami emociją žmogaus veide, dažnai galime suprasti, ar pokalbis sukelia teigiamas ar neigiamas emocijas ir padaryti išvadas, ar derėtų nukreipti pokalbį kita linkme. Panašiu principu, galime modeliuoti programinę įrangą, kuri galėtų stebėti žmogaus veidą ir pagal nustatomą emociją atnaujinti ekrano vaizdą atitinkantį emocinę būseną. Šiuo atveju, pagal ekranvaizdyje rodomas PECS korteles būtų galimybė užfiksuoti vaiko, turinčio autizmo spektro sutrikimą, emociją į jas ir pagal tai korteles filtruoti.

Norint atpažinti veido emociją, pirmiausia yra reikalinga atpažinti patį veidą. Yra kuriami įvairūs algoritmai, naudojantys skirtingus metodus, kurie aprašo veidą, naudojant kelis arba visus veido bruožus [KJA⁺20]. Algoritmai dažnai atvejais vaikų veidus atpažįsta prasčiau, negu suaugusiųjų [Sri19], dėl to yra svarbu ištirti ir pasirinkti tinkamą algoritmą, veido ir emocijos atpažinimui.

Veido atpažinimo struktūra susideda iš – veido nustatymo, veido bruožų išskyrimo ir galiausiai veido atpažinimo [KJA⁺20] (7 paveikslėlis). Veido atpažinimo sistema pirmiausia nustato veido sritį pateiktoje nuotraukoje, kad nustatyti ar nuotraukoje figūruoja žmogaus veidas [KJA⁺20]. Sekančiu etapu yra išskiriami veido bruožai, pavyzdžiui atskirų veido dalių struktūros, dydžiai arba atstumai tarp jų [KJA⁺20]. Kai yra išskiriami atitinkami bruožai, konvoliucinių neuroninių tinklų arba kitų panašių metodų pagalba galima vykdyti panašaus veido paiešką duomenų bazėje [KJA⁺20]. Vietoje panašaus veido paieškos galima vykdyti ir kitas užduotis, pavyzdžiui atpažinti emociją.



7 pav. Veido atpažinimo sistemos struktūra (sudaryta remiantis [KJA⁺20]).

Konvoliuciniais neuroniniais tinklais yra dažnai pasitelkiama, sprendžiant emocijos atpažinimo problemas, tai matoma autoriaus Amjad Rehman Khan tyrime, bei kitame autorių Wafa Mellouk, Wahida Handouzi tyrime. Didžioji dalis darbuose peržvelgiamų tyrimų pasitelkia būtent konvoliuciniais neuroniniais tinklais ir išlaiko vidutiniškai >90% tikslumo rezultatą [Kha22] [MH20]. Jie yra itin tinkami tokioms problemoms spręsti, nes gali automatiškai aptikti veido požymius, tačiau gali klysti, jeigu nuotraukose varijuoją apšvietimo lygis, skiriasi veido pasisukimo kryptys ar kitos panašios variacijos [KJA⁺20]. Dėl šios priežasties nuotraukos gali būti iš anksto apdorojamos įvairiais metodais, kad sumažinti riziką neigiamai paveikti modelio tikslumą. Keli iš galimų pritaikyti metodų nuotraukų apdorojimui [PWB⁺17]:

- Veido atpažinimas ir nuotraukos apkarpymas – pašalina foną ir apkarpo nuotrauką, kad joje liktų tik veidas.
- Globalus kontrasto normalizavimas – sumažina kontrasto variacijas tarp nuotraukų.
- Lokalus normalizavimas – suvienodina ryškumą ir kontrastą tik atitinkamose nuotraukos vietose.
- Histogramos išlyginimas – išlygina kiekvieno pikselio ryškumą, kad nuotrauka gautusi vientisesnė ryškumo atžvilgiu.
- Vizualinio triukšmo pridėjimas – iškraipo nuotrauką atsitiktinėse vietose (pavyzdžiui prideda juodus arba baltus taškus).

2017 metų tyrimo metu buvo vykdomi palyginimai tarp gaunamų emocijos atpažinimo tikslumo rezultatų. Jame buvo naudojami minėti nuotraukų apdorojimo metodai tarp trijų skirtingų duomenų rinkinių. Pritaikant tik vieną metodą nuotraukų apdorojimui, didžiausią teigiamą įtaką padarė veido atpažinimo ir nuotraukos apkarpymo metodas, kuris atpažinimo rezultatą pagerino 24.27% [PWB⁺17]. Apdorojant nuotraukas su minėtu metodu ir kartu pridedant triukšmą, šis rezultatas išaugo iki 31.33%. Rezultate, pritaikius nuotraukų apdorojimą, vidutinis emocijos atpažinimo tikslumo procentas gavosi 93.14%, palyginimui, nepritaikius apdorojimo metodų jis siekė 61.81%.

Gilieji konvoliuciniai neuroniniai tinklai geba itin aukštu tikslumu rezultatu atpažinti pyktį, baimę, džiaugsmą, liūdesį, nuostabą ir natūralią būseną iš veido nuotraukos. 2023 metų tyrimo metu buvo pasiūlyta struktūra, gebanti atpažinti emocijas 99.99% tikslumu [Tal23]. Ši struktūra susideda iš patobulinto giluminio mokymosi (EDL) metodo emocijoms klasifikuoti naudojant konvoliucinį neuroninį tinklą [Tal23].

Gilieji ir standartiniai konvoliuciniai neuroniniai tinklai yra tinkami veido ir emocijos atpažinimui, dėl automatinio požymių atpažinimo ir dėl galimybės juos apmokyti įvairaus tipo nuotraukomis.

1.2.4. Kitų autorių tyrimai

Kadangi mašininio mokymosi metodai egzistuoja jau sąlyginai ilgą laiką, jų pritaikymas yra tiriamas ir aprašomas daugelyje sričių. Svarbu apžvelgti į kitų autorių darbus, susijusius su skatinamojo mokymosi metodų pritaikymu autizmo spektro sutrikimą turintiems vaikams ir tyrimus kaip yra bandoma atpažinti emociją iš žmogaus veido. Žemiau esančioje lentelėje yra pateikiami panašių tyrimų autorių darbai (žr. 2 lentelę).

2 lentelė. Emocijos atpažinimo, pagal DI technologijas, darbų palyginimai

Autoriai	Tikslas	Taikytos DI technologijos	Duomenų rinkiniai	Gauti rezultatai
Talaat, Fatma M. [Tal23]	ASS turinčių asmenų veido ir emocijos atpažinimas	CDNN	Realūs duomenys	99.99% tikslumo rezultatas

Kumar, D., Zhang Zhang, and K. Q. Huang [KZH20]	Veido ir emocijos atpažinimas	CNN	CK+ ir MMI - veido emocijų nuotraukų rinkiniai	96.17% tikslumo rezultatas CK+ duomenų rinkinyje; 98.72% tikslumo rezultatas MMI duomenų rinkinyje
Hassouneh, Aya, A. M. Mutawa ir M. Murugappan [HMM20]	Veido ir emocijos atpažinimas	CNN	Realūs duomenys	99.81% tikslumo rezultatas
Haque, Md Inzamam Ul [Haq19]	ASS turinčių asmenų veido ir emocijos atpažinimas, naudojantis mobiliuoju telefonu su iOS operacine sistema	DCNN	FER2013 veido emocijų nuotraukų rinkinys	63.11% tikslumo rezultatas
Khattak, A., Asghar, M. Z., Ali, M. ir Batool, U. [KAA ⁺ 22]	Veido ir emocijos atpažinimas	CNN	Jaffe ir CK+ veido emocijų nuotraukų rinkiniai	95.65% tikslumo rezultatas Jaffe duomenų rinkinyje; 99.36% tikslumo rezultatas CK+ duomenų rinkinyje
Talaat, F. M., Ali, Z. H., Mostafa, R. R. ir El-Rashidy, N. [TAM ⁺ 24]	Veido ir emocijos atpažinimas	DCNN emocijos atpažinimui su integruotu iš anksto apmokytu modeliu Xception, klasifikavimo rezultatui pagerinti	Realūs duomenys	95.23% tikslumo rezultatas

Zahara, L., Musa, P., Wibowo, E. P., Karim, I. ir Musa, S. B. [ZMW ⁺ 20]	Veido ir emocijos atpažinimas	CNN paremtu Xception mini architektūra	FER2013 veido emocijų nuotraukų rinkinys	94.3% tikslumo rezultatas
Milani, S., Fan, Z., Gulati, S., Nguyen, T., Fang, F. ir Yadav, A [Mil20]	Personalizuota mokymosi aplinka ASS vaikams	SK su PPO optimizacija	Sintetiniai duomenys	vidutinis PPO strategijos pagerėjimo rodiklis: 9.83, gavosi aukštesnis už vidutinis randomizuotos strategijos pagerėjimo rodiklį: 8.80
Xia, Bo ir Shouyao Liu [XL25]	Interaktyvios sistemos sukūrimas, pagal SK metodus, lavinti ASS vaikų susitelkimą	SK, gilusis Q-mokymasis	Realūs duomenys	Intervencijų metu vaikų dėmesys padidėjo 30.42% nuo bazinio lygio
Alamdari, Nasim ir Lobarinas, Edward ir Keh-tarnavaz, Nasser [ALK20]	Personalizuotos garso kompresijos nustatymas klausos aparatams, pagal gilaus SK metodus	Gilusis SK	Realūs duomenys	Gauti personalizuoti klausos aparatų nustatymai buvo efektyvesni už standartinius aparatų nustatymus

Tyrimuose dominuoja pasinaudojimas konvoliuciniais ir giliaisiais konvoliuciniais neuroniniais tinklais. Abu metodai yra tinkami klasifikuoti rodomą emociją, kadangi pasižymi aukštu tikslumo rezultatu. Bandant atpažinti emociją tarp ASS turinčių vaikų DCNN gali būti pranašesnis, dėl taikomų giliojo mokymosi metodų, tačiau reikia atsižvelgti į naudojamą duomenų rinkinį modelio apmokymui. Mažesnis duomenų rinkinys gali suprastinti modelio apmokymą ir neigiamai paveikti gaunamus rezultatus.

1.2.5. Duomenų rinkinių palyginimas

Tyrimui yra reikalinga turėti modelį, apmokytą veido mimikos duomenimis, kad jį pritaikyti PECS kortelių pasiūlymo sistamai. Siekiant užtikrinti tyrimo kokybę ir spartą, reikia įvertinti ir pasirinkti laisvai prieinamą iš anksto apmokytą modelį arba pasirinkti tinkamą duomenų rinkinį modelio apmokymui.

Išanksto apmokytų CNN modelių palyginimas (žr. 3 lentelę) ir veido emocijos nuotraukų rinkinių palyginimas (žr. 4 lentelę):

3 lentelė. *Apmokytų konvoliucinių neuroninių tinklų modelių palyginimai*

Modelis	Aprašymas	Apmokyti modeliai	Modelio naudoja- mos metrikos
Hugging Rain Man [JWX ⁺ 25]	Susideda iš veido emocijos duomenų iš vaikų turinčių ir neturinčių autizmo spektro sutrikimą Modelio apmokymui naudotos nuotraukos neprieinamos (viso naudota apie 130000 nuotraukų)	ResNet-50 (CNN) EmoFAN (CNN) ME-GraphAU (CNN) MAE-Face (CNN) FMAE (CNN)	Tikslumo rezultatas F1 vertinimas
HSEmotion [Sav22]	Susideda iš veido emocijos duomenų iš vaikų turinčių ir neturinčių autizmo spektro sutrikimą Modeliui apmokyti naudotos nuotraukos iš dviejų prieinamų duomenų rinkinių (VGGFace2 ir AffectNet) ir prieinamo vaizdo medžiagos duomenų rinkinio AFEW	EfficientNet (CNN)	Tikslumo rezultatas

Laisvai prieinamų, paruoštų naudojimui ir apmokytų, bent dalinai iš autizmo spektrą turinčių vaikų veido emocijų, konvoliucinių neuroninių tinklų modelių yra stokojama. Hugging Rain Man modeliai yra apmokyti dideliu kiekiu duomenų, tačiau nėra žinoma kokios nuotraukos buvo naudojamos modeliams apmokyti, tai gali sukelti sunkumų pateikiant naujas nuotraukas emocijos atpažinimui. Papildoma problema, kad modelis nustato ne pačią emociją, o atskirų veido raumenų judesius. Tokiu atveju reikia papildomai modeliuoti ryšį tarp veido raumenų ir emocijų. Sekantis nagrinėtas modelis, HSEmotion, nėra apmokytas ASS asmenų nuotraukomis, tačiau pateikia konkrečių emocijų įverčius.

4 lentelė. Veido emocijos duomenų rinkinių palyginimai

Duomenų rinkinys	Aprašymas	Nuotraukų kiekis ir apimamų emocijų kiekis	Apimamos emocijos
CK+	48x48 formato juodai baltos nuotraukos, skirtingos lyties asmenų nuo 18 iki 50 metų	920 nuotraukų 7 emocijos	Pyktis Šleikštulys Baimė Laimė Liūdesys Neutrali padėtis Panieka
RAF-DB	Skirtingos lyties ir įvairaus amžiaus asmenų nuotraukos	Virš 15000 nuotraukų 7 emocijos	Pyktis Šleikštulys Baimė Laimė Liūdesys Neutrali padėtis Nuostaba
FADC	Vaikų turinčių ir neturinčių autizmo spektro sutrikimą veido emocijų nuotraukos	7921 nuotraukų emocijos nėra sužymėtos	—

Vertinant prieinamus veido emocijos nuotraukų duomenų rinkinius, kurie gali būti panaudojami CNN modelio apmokymui nustatyti emociją, duomenų rinkinys FADC, susidedantis dalinai iš ASS turinčių vaikų yra deja netinkamas, nes nuotraukoms nėra priskirtos emocinės būsenos. Kad apmokyti modelį iš šių nuotraukų yra būtina joms priskirti emociją, tačiau tai šiuo atveju yra neįmanoma dėl ASS ypatybių ir neturint ryšio su vaikais. RAF-DB duomenų rinkinys yra platus, o nuotraukos yra sužymėtos pagal emocijas, tai leistų patikrinti veido atpažinimo modelio tikslumą arba tykslingai apmokyti modelį nustatyti veido emociją, tačiau jis neturi ASS turinčių vaikų nuotraukų.

Šio tyrimo atveju yra tikslingiausia naudoti HSEmotion CNN modelį ir vertinant rezultatus, jeigu jie pasižymėtų, kaip netikslūs, bandyti išmokyti CNN modelį RAF-DB duomenų rinkiniu. CK+ duomenų rinkinys tyrimui yra netinkamas, nes rinkinyje nuotraukos yra asmenų vyresnių amžiaus grupių.

1.3. Išvados

Išnagrinėjus autizmo spektro sutrikimą turinčių vaikų elgsenos modelius ir juos galinčius realizuoti skatinamojo mokymosi modelius, galime teigti, kad skatinamojo mokymosi algoritmai gali būti panaudoti, kad palengvinti autizmo spektro sutrikimą turinčių vaikų bendravimą, dėl savo savybės prisitaikyti prie aplinkos. Ši savybė išsprendžia problemą pasiūlyti tinkamas PECS korteles individualiai, pagal kiekvieno vaiko, turinčio autizmo spektro sutrikimą, grįžtamąjį ryšį į atvaizduojamas korteles. Kadangi tikslus grįžtamasis ryšys yra svarbus modelio apmokymo procesui, veido emocijos duomenų panaudojimas suteiktų galimybę modelį apmokyti tiksliai ir per trumpesnę laiką, dėl didelio kiekio duomenų, gaunamų realiu laiku.


Išnagrinėjus kitų autorių tyrimus, kuriuose bandoma atpažinti autizmo spektro sutrikimą turinčių asmenų veido emociją, galime pastebėti, kad dažniausiai yra naudojami konvoliuciniai arba gilieji konvoliuciniai neuroniniai tinklai. Jie pasižymi aukštu tikslumo rezultatu ir yra dažnai taikomi panašaus tipo problemoms spręsti. Tuo pačiu, ilgiamui galima stebėti vaiko emocinę būklę ir nustatyti ar siūloma PECS kortelių sistema jam yra tinkama.

2. Skatinamojo mokymosi modelio sudarymo metodologija, tyrimai ir rezultatai

Skyriuje yra tiriamas skatinamojo mokymosi algoritmas „CardFinder“, sukurtas autoriaus Augusto Mikulėno, kuris yra skirtas pasiūlyti PECS korteles [Mik22]. Tyrimui atlikti buvo panaudoti „CardFinder“ metodai, skirti agentui mokytis rasti teisingą kortelę 81 kortos kaladėje (toliau – aplinkoje), Augusto Mikulėno nustatyti efektyvūs mokymosi proceso hiperparametrai ir algoritme pritaikyti Q-mokymosi metodai. Algoritmo galutinio rezultato gerinimui „CardFinder“ buvo papildytas naujomis funkcijomis ir dalis esminių algoritmo veikimo procesų buvo modifikuoti. Naujasis algoritmas „CardFinder+ Sense“, sudarytas remiantis algoritmu „CardFinder“, paspartina, kaip greitai yra randama teisinga PECS kortelė, pagal naujai pritaikytus dvigubo Q-mokymosi metodus, integruotą veido duomenų panaudojamumą ir stabilizuojant skatinamojo mokymosi procesus. Tyrimo etapai yra pateikiami verslo procesų modeliavimo ir notacijos diagramose (angl. business process model and notation, toliau – BPMN).

2.1. Skatinamojo mokymosi modelio sudarymo metodologija

Tyrimo procesas yra išskaidytas į šešis esminius etapus (žr. 8 pav.). Pirmojo etapo metu yra analizuojamas Augusto Mikulėno algoritmas „CardFinder“ [Mik22], gilinamasi į jo veikimo principus, algoritmo hiperparametrus, paleidimą lokalioje aplinkoje ir užfiksuojami gaunami rezultatai.



8 pav. Skatinamojo mokymosi modelio sudarymo metodologija.

Antrojo etapu metu yra sudaromas pirminis „CardFinder+ Sense“ algoritmo variantas, paremtas „CardFinder“ metodais ir eksperimentiniu būdu yra bandoma stabilizuoti modelio gaunamus rezultatus, kiek įmanoma suvienodinti žingsnių skaičių, siekiant rasti teisingą kortelę, kas kartą mokinant skatinamojo mokymosi modelį iš naujo. Trečiojo etapo metu siekiama „CardFinder+ Sense“ algoritmo rezultatą pagerinti, sumažinant žingsnių skaičių, reikiamą, kad nustatyti teisingą kortelę. Ketvirtojo etapo metu į „CardFinder+ Sense“ integruojami veido emocijos duomenys, kad toliau bandyti gerinti gaunamus rezultatus. Penktojo etapu metu algoritmo modeliui bus pritaikoma galimybė mokytis keliuose aplinkose vienu metu, kad jo panaudojamumas atitiktų realaus panaudojimo atvejus. Paskutiniu etapu yra analizuojamas galutinis „CardFinder+ Sense“ algoritmo variantas ir tiriami gauti rezultatai.

2.1.1. Augusto Mikulėno „CardFinder“ algoritmo analizė

Analitinėje dalyje yra nustatyta, kad skatinamojo mokymosi algoritmai yra tinkami pasiūlyti PECS korteles. Kadangi kortelių kaladės gali būti skirtingų dydžių, galima jas skaityti varijuojančio

dydžio matricą, kuri turėtų duomenis ar kortelę yra būtent ta kurią naudotojas nori matyti ar ne. Su matricomis dirba sąlyginai žinomi „OpenAI“ algoritmai „FrozenLake“ ir „Taxi“, kurie simuliuoja žaidimą, kuriame veikėjas bando pereiti labirintą, pradėdamas nuo taško A ir įveikia jį pasiekdamas tašką B. Augusto Mikulėno sukurtas algoritmas „CardFinder“ pasižymi tuo, kad gali pasiūlyti teisingą kortelę per mažesnę kiekį epizodų lyginant su algoritmais „FrozenLake“ ir „Taxi“ [Mik22]. Toks rezultatas buvo pasiektas dėl algoritmo savybės rasti teisingą kortelę pagal jų turimus metaduomenis, kas pagreitina procesą, kai aplinka turi didelį galimų žingsnių skaičių (didelį žemėlapi). Kai algoritme yra naudojami metaduomenys, agentas gali netik vykdyti ėjimus pirmyn, atgal, į kairę, į dešinę, bet ir tam tikra prasme persiekti per korteles į konkrečias, pagal jų metaduomenis. Dėl šios savybės, kaip pavyzdžiui, kai aplinkoje yra 81 kortelė ir esant pačiam blogiausiam scenarijui, algoritmas gali rasti reikiamą kortelę per 4 žingsnius, kai be šios savybės jis užtruktų mažiausiai 16 žingsnių.

„CardFinder“ yra dalinai paremtas „FrozenLake“ algoritmo principais, jame agentas sąveikauja su atsitiktine aplinka ir bando surasti teisingą kortelę. Kiekviena kortelė savo metaduomenyse turi iš anksto apibrėžtus baudos ir apdovanojimo taškus, skirtus agentui nubausti arba apdovanoti už atliekamą žingsnį. Taip agentas bando rasti labiausia apdovanojantį kelią ir rasti teisingą kortelę.

Algoritmas yra paremtas Q-mokymusi ir gali būti konfigūruojamas hiperparametrais, kurie įtakoja modelio apmokymo procesus (žr. 5 lentelę).

5 lentelė. „CardFinder“ konfigūruojami hiperparametrai ir jų pradinės vertės

Parametras	Apibrėžimas	Pradinė reikšmė	Reikšmės diapazonas
learning_rate	Mokymosi dažnis (α) - nustato kaip smarkiai nauja apdovanojimo arba baudos reikšmė įtakoja buvusias Q-reikšmes.	0.9	0–1
gamma	Nuolaidos dydis (γ) - nustato ateities taškų svarbą lyginant su sekančio ėjimo taškų svarba (didesnė vertė lemia ilgalaikę strategiją).	0.9	0–1
epsilon	Tyrinėjimo tikimybė (ϵ) - tikimybė agentui pasirinkti atsitiktinį veiksmą.	1	0–1
max_epsilon	Maksimali tyrinėjimo tikimybės reikšmė - maksimali tikimybė pasirinkti atsitiktinį veiksmą.	1	0–1
min_epsilon	Minimali tyrinėjimo tikimybės reikšmė - minimali tikimybė pasirinkti atsitiktinį veiksmą.	0.001	0–1
decay_rate	Tyrinėjimo tikimybės mažinimo dydis - valdo kaip greitai mažėja tyrinėjimo tikimybė.	0.01	0–1
total_episodes	Maksimalus iteruojamų epizodų skaičius.	15	0– ∞

Q-mokymo pagalba agentas nusprendžia ar atlikti naują veiksmą ar remtis išmokta strategija. Kiekvieno agento žingsnio metu yra generuojamas atsitiktinis skaičius, kuris lemia ar veiksmas bus atsitiktinis. Baudos ir atlygio taškų sistema yra naudojama Q-reikšmių atnaujinimui, kurios skirtos agentui pasirinkti optimalų kelią. Jos yra atnaujinamos, kas kiekvieną agento žingsnį. Kai agentas

baigia epizodą, rasdamas tinkamą kortelę, tyrinėjimo tikimybė ϵ yra mažinama, nes jau yra sukaup-ta informacijos Q-reikšmių lentelėje. Kuo daugiau epizodų yra naudojama agentui apmokyti, tuo mažesnė tyrinėjimo tikimybė ϵ yra vėlesniuose epizoduose. „CardFinder“ paleidimui lokaliaje ap-linkoje yra reikalinga atlikti keletą smulkių modifikacijų, įsidięti Python versiją 3.9.13 ir tam tikras išorines bibliotekas (žr. 6 lentelę).

6 lentelė. „CardFinder“ algoritmo naudojamos trečios šalies bibliotekos

Biblioteka	Versija
gym	0.21.0
numpy	2.0.2
matplotlib	3.9.4
jupyterlab	4.4.9

Programiniame kode yra būtina pakeisti, kaip yra pasiekiamas išvesties langas: „`terminal_output = open(1, 'w')`“ keičiamas į „`terminal_output = sys.__stdout__`“. Taip pat būtina užregistruoti pasi-rinktą aplinką bibliotekos gym naudojimui, pridėdant programiniame kode duomenis: „`gym.envs.re-gistration.register(id='CardFinder-v1', entry_point='card_finder(v1):CardFinderEnv')`“.

„CardFinder“ algoritmo paleidimo metu, yra sugeneruojama atsitiktinė aplinka, kurioje va-dinamas agentas mokosi optimalios strategijos rasti teisingą kortelę, kuri iš anksto apibrėžiama ge-neruojamoje aplinkoje. Kad atliekamas tyrimas būtų sąžiningas ir teisingas, yra išsaugojami vienos atsitiktinės aplinkos duomenys, kurioje bus atliekami tyrimo eksperimentai (žr. 9 pav.). Aplinka susideda iš 81 kortelės, 9x9 matricoje. Kiekviena kortelė turi savo unikalų identifikacinį numerį, pradžios arba pabaigos žymėjimą arba būseną.


S N--N-NNT	[[18 30 42 24 10 6 5 41 22]
N--NNNNNT	[28 47 27 61 23 15 64 40 72]
NNNNNN--N	[12 8 4 14 2 1 67 36 26]
-NTNNNN-N	[7 58 76 37 0 9 68 16 11]
--N-NN-N-	[74 17 78 29 69 3 21 65 31]
NN-NNNN-N	[35 51 53 77 32 19 46 49 54]
-NNN-NN-N	[59 20 79 75 45 62 34 66 55]
N-NN---NN	[57 38 39 13 44 52 60 50 63]
N--NN-N-L	[48 33 25 73 71 56 43 80 70]]

9 pav. Algoritmo aplinkos pavyzdys, naudojamas eksperimentams atlikti (ekranvaizdžio kopija).

Kadangi algoritmas geba būti apmokomas su iš anksto apibrėžtomis kortelių būsenomis, tokio-mis kaip: teigiama T , neigiama N ir neutrali kortelė – (žr. 9 pav.), rezultatai bus analizuojami, kai modelis apmokomas be jokių iš anksto apibrėžtų duomenų ir kitu atveju, kai kortelių metaduomenys su savimi jau turės iš anksto numatytą būsenos vertę, kuri turi įtakos modelio apmokymo procesui.

Algoritmo principas yra toks, kad kiekvienam vaikui jis turėtų apsimokyti individualiai ir sugeneruoti Q-lentelę su duomenimis, kurie atitiktų vaiko panaudojamumo specifikas. Kad paprasčiau suprasti, kaip efektyviai „CardFinder“ sugeba apmokyti skatinamojo mokymosi modelį kas kartą jį mokinant iš naujo, buvo sudaryta funkcija iteruoti mokymosi procesą ir stebėti gaunamus rezultatus.

Nustatyti „CardFinder“ rezultatus, siekiant atpažinti teisingą kortelę, buvo renkami duomenys, kai mokymosi procesas yra iteruojamas 100 kartų ir modeliui apmokyti naudojama 15 epochų, kad pastebėti, kaip gerai modelį pavyksta išmokyti per itin trumpą laiką. Modelio efektyvumui įvertinti buvo fiksuojamas suminis rodiklis (vidutinis žingsnių skaičius) per visas apmokymo proceso epochas. Pirmojo stebėjimo metu buvo sudaryta diagrama, kuri parodo, kaip greitai modelis apmokytas be iš anksto priskiriamų būsenų kortelėms sugeba rasti teisingą kortelę (žr. 10 pav.). Optimalus modelio rezultatas – rasti teisingą kortelę per 5 žingsnius, tačiau 16% atvejų, apmokytas modelis identiškoje aplinkoje kortelę randa per didesnę žingsnių skaičių, tai indikuoja mokymosi proceso nestabilumą.



10 pav. „CardFinder“ apmokyto modelio rezultatai be metaduomenų kortelėse.

Antrojo stebėjimo metu epochų skaičius buvo padidintas iki 100, tuo atveju modelis sėkmingai sugebėjo rasti teisingą kortelę per 5 žingsnius visais atvejais. Yra pastebima, kad tam tikrais apmokyto modelio testavimo atvejais identiškoje aplinkoje, skatinamojo mokymosi algoritmas skirtingu greičiu randa tinkamą kortelę, tai gali būti problematiška, nes vienam naudotojui jis gali veikti efektyviau negu kitam.

„CardFinder“ algoritmas deramai negali būti pritaikomas autizmo spektro sutrikimą turinčių vaikų naudojimui, dėl sekančių priežasčių:


1. Kas kartą apmokant algoritmą yra pastebimas rezultatų nevientisumas, ~13% apmokymo atvejų, modelis kortelę randa lėčiau, negu optimalus algoritmo rezultatas. Tai žymi, kad bent 1 iš 10 vaikų jis gali veikti prasčiau negu numatyta.
2. Geriausias rezultatas pasiekiamas modelio yra 5 žingsniai, tai reiškia, kad algoritmas pirmiausia

parodys 4 neteisingas PECS korteles ir tik 5 kartu teisingą, tai gali pasireikšti kaip naudojimo atmetimo faktorius, jeigu vaikui per anksti pasirodytu, kad rodomos kortelės yra netinkamos.


3. Algoritmas sukurtas mokytis tik vienoje aplinkoje, tai reiškia, kad kas kartą mokinant modelį naujoje aplinkoje, buvusi išmokta informacija yra perrašoma nauja ir buvusi informacija dingsta. Atsižvelgiant į tai, kad modelis mokintusi kas kartą jį naudojant, jis turi turėti galimybę mokytis iš kelių aplinkų vienu metu, kad išmokti optimalią strategiją su buvusiais ir su naujais duomenimis.

2.1.2. Modelio rezultato stabilizavimo metodologija

Modelio apmokymo proceso stabilizavimui buvo sudaryta metodologija, kuri užtikrina sėkmingą atliekamų eksperimentų rezultatą (žr. 11 ir 12 pav.).



11 pav. Modelio rezultato stabilizavimo metodologija.




12 pav. Modelio testavimo ir analizės metodologija.

Modelio rezultato stabilizavimui yra pasitelkiama modifikuoti algoritmo hiperparametrus (žr. 12pav., procesas 2.1.) ir nustatyti jų rinkinį, kuris įgalintų kuo dažniau rasti teisingą kortelę per optimalų žingsnių skaičių. Testavimo ir analizės metu (žr. 12pav., procesas 2.2.) yra sekami gaunami rezultatai, kurie palyginami su „CardFinder“ rezultatais, gautais jo analizės metu. Jeigu gaunamas rezultatas, kaip dažnai randa kortelę per optimalų žingsnių skaičių, procentaliai nėra optimalesnis už „CardFinder“ rezultatus, hiperparametrai keičiami į kitą rinkinį ir procesas yra vykdomas iš naujo.

Testavimo ir analizės procesai (žr. 12 pav.) yra bendriniai ir bus naudojami ir kitų metodologijų metu.

2.1.3. Modelio rezultato gerinimo metodologija

Siekiant pagerinti žingsnių kiekį, norint pasiekti teisingą kortelę 81 kortelės aplinkoje, yra numatyta naudojantis 2 skirtingais eksperimentais (žr. 13 pav.). Prieš eksperimentų vykdymą, „Card-Finder+ Sense“ algoritmas yra papildomas funkcija pasirinkti, kaip keisti pradžios kortelės vietą mokymosi ir testavimo procesų metu (žr. 13 pav., procesas 3.1.). Sudaryti 3 skirtingi pradžios kortelės pasirinkimo metodai, kuriuos galima keisti algoritmo hiperparametro pagalba.




13 pav. Modelio rezultato gerinimo, nustatant pradžios kortelių vietas Q-mokymo ir dvigubo Q-mokymo metodams, metodologija.

Abu eksperimentai vykdomi paraleliai. Pirmojo eksperimento metu yra vykdomas testavimas ir analizė su standartiniais Q-mokymosi metodais, vykdant modelio mokymosi procesus su hiperparametrų rinkiniu gautu modelio rezultato stabilizavimo metu (žr. 12 pav., procesas 2.1.). Antrojo eksperimento metu yra vykdomas analogiškas procesas, prieš tai atnaujinus algoritmą su galimybe naudotis dvigubo Q-mokymosi metodais (žr. 13 pav., procesas 3.2.). Eksperimentai yra kartojami su visais pradžios pasirinkimo metodais ir yra tarpusavyje palyginami (žr. 13 pav., procesas 3.3.). Rezultatų palyginimo metu, jei modelio, apmokyto su dvigubo Q-mokymosi metodais, žingsnių skaičius randant teisingą kortelę testavimo metu nebuvo mažesnis už modelio, su standartiniais Q-mokymosi metodais, dvigubo Q-mokymosi lentelių sukeitimo dažnis keičiamas diapazone [0;1] (žr. 13 pav., procesas 3.4.). Tuomet modelis iš naujo apmokomas ir nauji rezultatai palyginami iš naujo. Jei mažesnis žingsnių skaičius nėra užfiksuojamas per 3 bandymus, skaitoma, kad dvigubo Q-mokymosi metodai šių eksperimentų metu įtakos nesudaro.

2.1.4. Veido emocijos duomenų integravimo metodologija

Atlikus eksperimentus, kad pagerinti algoritmo pateikiamus rezultatus, numatoma pritaikyti veido emocijos duomenis kortelėms ir įvertinti ar šie papildomi duomenis nesutrikdo algoritmui vykdyti funkcijos rasti tinkamą kortelę (žr. 14 pav.).

Eksperimentui atlikti yra sudaryti atsitiktiniai, netikri, emocijų duomenys, kurie priskiriami kortelių metaduomenims, pagal jų būsenas (žr. 9 pav.). „CardFinder+ Sense“ pritaikyta funkcija naudotis minėtais metaduomenimis modelio apmokymo metu, kad agentą bausti arba suteikti atlygio taškus papildomai pagal emocijos įvertčius (žr. 14 pav., procesas 4.1.), atitinkamai yra sudarytas naujas hiperparametras, nusakantis kaip smarkiai emocijos duomenys įtakoja agento atlygį.




14 pav. Veido emocijos duomenų pritaikymo algoritmui metodologija.

Testavimo metu, modeliui pateikiami visi pradžios nustatymo metodai, kad rezultatuose būtų galimybė atsižvelgti į jų naudą, kai modelis apmokomas kartu su emocijų duomenimis. Jei testavimo metu modelis nesugeba išspręsti visų testų, modifikuojamas emocijos duomenų įvertis ir testavimo procesas kartojamas iš naujo.

Minimas veido duomenų panaudojimas algoritme suteikia paprastai įgyvendinamą būdą, kaip pritaikyti konvoliucinius neuroninius tinklus „CardFinder+ Sense“ algoritmui. CNN išvedamą įtariamą veido emocijos nustatymo rezultatą yra galimybė priskirti prie kortelės metaduomenų, o algoritmas jau turėtų informaciją, kaip modifikuoti apdovanojimo ir baudos taškus pagal emociją. Tokiu metodu, algoritmui bus pritaikomas HSEmotion modelis emocijos atpažinimui iš RAF-DB duomenų rinkinio, pasirenkant atsitiktinę nuotrauką. Emocijos atpažinimo modelis pritaikomas nustatyti tris antrinktas emocijas: laimę, liūdesį ir neutralią padėtį, o iš RAF-DB duomenų rinkinio atrenkamos, analogiškų trijų emocijų, testavimui skirtos nuotraukos (2343 nuotraukos). Atpažystant laimę į rodomą kortelę, agento apdovanojimo dydis turi būti padidintas, kad skatinti rinktis korteles, kurios turėjo teigiamą emociją, o liūdesio atveju priešingai. Neutralios padeties emocijos agento apdovanojimo įverčio keisti neturi.

2.1.5. Kelių aplinkų pritaikymo metodologija

Siekiant pritaikyti „CardFinder+ Sense“ algoritmui galimybę mokytis keliose aplinkose vienu metu, algoritmui pritaikyta funkcija, kuri nusako metodą, kiek ir kokios aplinkos bus naudojamos modelio apmokymo ir testavimo procesams (žr. 15 pav., procesas 5.1.). Eksperimento metu naudojamas 2 metodas, kai modelis veikia 3 apibrėžtose aplinkose vienu metu, kad rezultatai būtų atkar-tojami. Paraleliai modelis mokinamas tiek su Q-mokymosi metodais, tiek su jau minėtais dvigubo Q-mokymosi metodais. Atveju, kai modelis negali sėkmingai išspręsti testų 3 aplinkose vienu metu, pritaikomas aplinkos keitimas kas kiekvieną mokymosi epochą (žr. 15 pav., procesas 5.1.1.).



15 pav. Kelių aplinkų pritaikymo metodologija.


2.2. Modelio tyrimai ir rezultatai

Remiantis modelio sudarymo metodologija, atliekami modelio eksperimentai įvertinant jį įta-kojančius parametrus, aplinką, scenarijus, siekiant rasti geriausią modelio variantą. Eksperimen-tų metu, pagal Augusto Mikulėno „CardFinder“ algoritmo Q-mokymosi metodus ir jame aprašyta PECS kortelių aplinkos struktūrą, buvo sudarytas algoritmas „CardFinder+ Sense“, siekiant pagerin-ti jo rezultatus, pašalinant nustatytus trūkumus pirmajame metodologijos punkte, ir pritaikyti, kad jis galėtų veikti keliuose aplinkose vienu metu. Viso tyrimo metu, „CardFinder+ Sense“ algoritmas buvo modifikuojamas ir papildomas naujomis funkcijomis, bei metodais.


2.2.1. Modelio rezultato stabilizavimo eksperimentai

Modelio stabilizavimo eksperimentai buvo vykdomi vienoje, iš anksto apibrėžtoje aplinkoje, kuri buvo naudota ir „CardFinder“ rezultatams nustatyti (žr. 8 pav., procesas 1.). Funkcija pamatyti modelio rezultatus testavimo etape, kai modelis yra apmokomas iš naujo nustatytą kiekį kartų, jau buvo sukurta algoritmo analizės metu. Ši duomenų stebėjimo funkcija buvo ir toliau pasitelkta naudoti eksperimento metu.

Eksperimentų metu buvo varijuojama įvairiais hiperparametrais minėtais algoritmo analizės metu ir stebima jų įtaka, kaip stabiliai modelis mokosi per daugelį apmokymo kartų. Modeliai buvo apmokomi aplinkoje, kuri neturi savyje neturi jokių metaduomenų apie kortelių būsenas, tik pradžios kortelės vietą ir teisingos kortelės vietą. Kad nekeisti algoritmų atsitiktiniu būdu, tikintis, kad rezultatas bus pagerintas, buvo sudaryti hiperparametrų šilumos žemėlapiai, kurie pavaizduoja jų įtaką žingsnių skaičiui (žr. 16 ir 17 pav.).



16 pav. Minimalios tyrinėjimo tikimybės ir tyrinėjimo tikimybės mažinimo dydžio šilumos žemėlapis pagal įtaką suminiam rodikliui.



17 pav. Mokymosi dažnio α ir nuolaidos dydžio γ šilumos žemėlapis pagal įtaką suminiam rodikliui.

„CardFinder+ Sense“ algoritmas buvo papildytas funkcija iteruoti per hiperparametrų nustatymus ir saugoti vidutinį žingsnių skaičių. Tokių būdų yra pastebėta, kad daugiausia įtakos turintys hiperparametrai yra mokymosi dažnis α ir nuolaidos dydis γ . Taip pat buvo gauta kokiame reikšmių diapazone yra geriausia išlaikyti tyrinėjimo tikimybės mažinimo ir minimalios tyrinėjimo tikimybės parametrus.

Pritaikius hiperparametrų vertes „CardFinder+ Sense“ algoritmui ir atlikus modelio testavimo procesą (žr. 12 pav.) pastebėta, kad apmokant modelį per 15 epochų pokytis yra reikšmingas, tik vienas apmokytas modelis iš 100 teisingą kortelę išmoko rasti per daugiau negu 5 žingsnius (žr. 18

pav.). Epochų skaičių padidinus iki 100, modelis stabiliai randa korteles per tą patį žingsnių skaičių visais atvejais, kai yra apmokomas iš naujo.



18 pav. „CardFinder+ Sense“ suminiai rodikliai, pritaikius efektyvų hiperparametrų rinkinį.

Tyrimo metu sėkmingai pavyko stabilizuoti apmokyto modelio rezultatus, kad būtų išvengtas nuokrypis modelį apmokinant identiškoje aplinkoje. Nustatytas parametrų rinkinys, įgalinantis apmokymo proceso stabilumą (žr. 7 lentelę). Mokymosi dažnis α ir nuolaidos dydis γ pasirinktas antras pagal mažiausią žingsnių skaičių iš šilumos žemėlapių (žr. 17 pav.), nes jis įgalina modelį apmokyti greičiau, lyginant su greičiu, kai modelis apmokomas $[0,1;0,2]$ mokymosi dažniu.

7 lentelė. Atrinktų pagal efektyvumą modeliui hiperparametrų vertės

Parametras	Reikšmė
learning_rate (α)	0,8
gamma (γ)	0,7
epsilon (ϵ)	1
max_epsilon	1
min_epsilon	0,1
decay_rate	0,001

2.2.2. Modelio rezultato gerinimo eksperimentai

„CardFinder+ Sense“ rezultatų gerinimo eksperimentams buvo pasitelkta naudoti stabilizavimo eksperimentų metu gautu hiperparametrų rinkiniu, kuris užtikrina gaunamų rezultatų stabilumą. Algoritmo naudojama aplinka yra apibrėžiama kaip matrica, tyrimo atveju 9×9 dydžio. Kiekvienas elementas atitinka vieną PECS kortelę 81 kortelės kaladėje. Algoritme yra apibrėžiama pradinė, starto kortelė, nuo kurios agentas pradeda savo veiksmų seką, kad pasiekti tinkamą kortelę (žr. 13 pav., 3.1. procesas). Jeigu agentas pradėtų veiksmus kortelėje, kuri yra gretima teisingai kortelei, tai hipotetiškai galėtų sumažinti reikiamų žingsnių skaičių pasiekiant teisingą kortelę. Norint patikrinti, ar yra nauda pradėti veiksmus atsitiktinėje arba iš anksto numatytoje pozicijoje, „CardFinder+ Sense“ buvo papildytas galimybe mokymosi metu keisti pradžios kortelės poziciją mokymosi ir testavimo

metu. Pradžios kortelės pozicija s yra keičiama į poziciją s_i , kur i yra vieta aplinkoje, jeigu ji yra pateikiama, kitu atveju s yra priskiriama atsitiktinė pozicija S iš aplinkos pozicijų aibės.

$$s = \begin{cases} s_i & , \text{ kai } i \neq \emptyset \\ s \sim S & , \text{ kai } i = \emptyset \end{cases} \quad (9)$$

Kad įvertinti naudą, kai pradžios kortelė yra keičiama apmokymo ir testavimo metu, buvo vykdomi 3 eksperimentai (žr. 13 pav.). Pirmojo eksperimento metu buvo keičiamos pradžios kortelės pozicijos į pozicijas aplinkos pradžioje ir viduryje su 50% tikimybe jas pasirinkti. Antrojo eksperimento metu papildomai įvesta paskutinės pozicijos padėtis pradžios kortelei, visoms pozicijoms buvo priskiriama atsitiktinė tikimybė. Trečiojo eksperimento metu kas kartą pradžios kortelei buvo priskiriama atsitiktinė pozicija iš visos kortelių matricos.

Eksperimentų rezultatai buvo renkami iteruojant mokymosi procesą 100 kartų po 15 epochų. Pirmojo eksperimento metu, vidutiniškai modelis randa kortelę per 4,5 žingsnio 100 iteracijų ir žemiausias pasiektas rezultatas 3 žingsniai. Antrojo eksperimento rezultatas kiek prastesnis, papildoma būseną agentui pradėti teisingos kortelės išieškojimą paskutinėje aplinkos būsenoje procesą prailgino. Labiausiai pasiteisino trečiasis eksperimentas, atsitiktinė pradžios kortelė agentui leidžia dažnai rasti kortelę greičiau, negu kitų eksperimentų metu, vidutiniškai per 4 žingsnius 100 iteracijų ir bendrai vertinant dažniausiai per 3 arba 4 žingsnius.

8 lentelė. „CardFinder+ Sense“ Q -mokymosi testavimo rezultatai, per 10000 testų

Eksperimentas	Epochų skaičius	Teisingai išspręsta
1 – startas pradžioje ir viduryje	15	100%
1 – startas pradžioje ir viduryje	100	100%
1 – startas pradžioje ir viduryje	1000	100%
2 – startas pradžioje, viduryje ir pabaigoje	15	66%
2 – startas pradžioje, viduryje ir pabaigoje	100	66,5%
2 – startas pradžioje, viduryje ir pabaigoje	1000	67,8%
3 – atsitiktinės vietos startas	15	97,4%
3 – atsitiktinės vietos startas	100	97,6%
3 – atsitiktinės vietos startas	1000	97,4%

Atsitiktinės arba iš anksto nustatytos pradžios kortelės keitimas apmokymo ir testavimo metu sukelia nestabilumą ir tam tikrais atvejais modeliui nepavyksta rasti teisingos kortelės (žr. 8 lentelę), kas kartą vykdant apmokymo procesą iš naujo, tačiau yra pasiektas žemesnis teisingos kortelės nustatymo rezultatas (žr. 19 pav.).



19 pav. Vidutinio žingsnių skaičiaus pasiskirstymas, pradžios kortelės keitimo eksperimentų metu.

Pirmo ir trečio eksperimento metu, modelis teisingą kortelę randa greičiau už „CardFinder“ toje pačioje aplinkoje. Pirmojo eksperimento modelis visais atvejais išsprendė visus testus, o trečiasis teisingai išsprendė daugumą, tačiau per vidutiniškai mažesnę žingsnių skaičių.

Siekiant dar labiau sumažinti žingsnių skaičių, „CardFinder+ Sense“ algoritmui pritaikyti dvigubo Q-mokymosi metodai (žr. 13 pav., procesas 3.2.). Kai agentas atsitiktinai pasirenka naudoti optimalų veiksmą, jis yra pasirenkamas iš abiejų Q-reikšmių lentelių imtinai:


$$a = \begin{cases} \arg \max_a [Q_A(s_t, a_t) + Q_B(s_t, a_t)] & \text{esant tikimybei } 1 - \epsilon \\ \text{atsitiktinis veiksmas} & \text{esant tikimybei } \epsilon \end{cases} \quad (10)$$

Apmokius modelį, testavimo metu Q_A ir Q_B lentelės yra sujungiamos į vieną Q-reikšmių lentelę ir agento veiksmai yra pasirenkami geriausią žinomą veiksmą atitinkamoje būsenoje:

$$a = \arg \max_a [Q_A(s_t, a_t) + Q_B(s_t, a_t)]. \quad (11)$$

Atlikus algoritmo pakeitimus, kad būtų naudojami dvigubo Q-mokymosi metodai modelio apmokymui ir testavimui, buvo pakartojami pradžios kortelės keitimo eksperimentai, kaip modeliui greitai pavyksta rasti teisingą kortelę (žr. 20 pav.).



Iš gaunamų rezultatų yra pastebima, kad atvejui, kai apmokyti modelį yra pasirenkama per 15 epochų, žingsnių skaičius tampa labai įvairus. Dvigubo Q-mokymosi atveju algoritmas turi spėti užpildyti dvi lenteles optimaliais duomenimis, kad modelis tinkamai veiktų, 15 epochų yra per mažas skaičius, kad tai pasiekti. Testavimo metu, apmokyti modeliai teisingai randa korteles tik dalį kartų (žr. 9 lentelę).



20 pav. Vidutinio žingsnių skaičiaus pasiskirstymas, pradžios kortelės keitimo eksperimentų metu, pritaikius dvigubą Q-mokymąsi.

9 lentelė. „CardFinder+ Sense“ dvigubo Q-mokymosi testavimo rezultatai, per 10000 testų

Eksperimentas	Epochų skaičius	Teisingai išspręsta
1 – startas pradžioje ir viduryje	15	39,5%
1 – startas pradžioje ir viduryje	100	100%
1 – startas pradžioje ir viduryje	1000	100%
2 – startas pradžioje, viduryje ir pabaigoje	15	20,8%
2 – startas pradžioje, viduryje ir pabaigoje	100	67,4%
2 – startas pradžioje, viduryje ir pabaigoje	1000	67,9%
3 – atsitiktinės vietos startas	15	46,3%
3 – atsitiktinės vietos startas	100	97,6%
3 – atsitiktinės vietos startas	1000	97,6%



21 pav. Dvigubo Q-mokymosi rezultatai dešinėje, lyginant su Q-mokymusi kairėje.

Dvigubo Q-mokymosi rezultatai tampa vienodi su rezultatais, kai naudojamas standartinis Q-mokymasis, kai epochų skaičius yra padidinamas iki 100, bet pagerėjimas nėra užfiksuojamas (žr. 21 pav.).

Modifikuojant, kaip dažnai yra apkeičiamas eiliškumas, į kurią dvigubo Q-mokymosi Q-reikšmių lentelę pildyti duomenis ir pritaikant skirtingus mokymosi dažnius α , gaunami rezultatai ženkliai nesikeičia nuo buvusių eksperimentų rezultatų ir mažesnis žingsnių skaičius nėra pastebimas.

2.2.3. Veido emocijos duomenų pritaikymas algoritmo naudojimui

Pritaikyti ir išanalizuoti, ar veido emocijos duomenys gali padėti pagreitinti teisingos kortelės radimą, pirmiausia apibrėžiami veido emocijos duomenys (žr. 14 pav., procesas 4.1.). Eksperimentams buvo laikoma, kad skatinamojo mokymosi algoritmas „CardFinder+ Sense“ jau gauna emocijų duomenis apie rodomas PECS korteles, kad vykdytų mokymosi procesą.

Emocijų duomenys buvo atsitiktinai sugeneruoti matricos pavidalu, tokiu būdu kiekviena kortelė su savimi turi istorinius emocijos duomenis į atitinkamą kortelę savo metaduomenyse (žr. 22 pav.). Duomenys sugeneruoti aibėje $[-1;1]$, su mintimi, kad veido emocijų duomenys į rodomas korteles bus nuolatos kaupiami ir naujinami.

	Emocijų įverčiai kortelėms									
S N--N-NNT	[	0.	-0.42	0.	0.	-0.15	0.	-0.73	-0.08	0.45]
N--NNNNNT	[	-0.61	0.	0.	-0.34	-0.88	-0.12	-0.55	-0.29	0.12]
NNNNNN--N	[	-0.19	-0.47	-0.66	-0.03	-0.71	-0.52	0.	0.	-0.38]
-NTNNNN-N	[	0.	-0.81	0.59	-0.22	-0.44	-0.67	-0.09	0.	-0.11]
--N-NN-N-	[	0.	0.	-0.53	0.	-0.27	-0.82	0.	-0.14	0.]
NN-NNNN-N	[	-0.33	-0.77	0.	-0.05	-0.58	-0.21	-0.49	0.	-0.64]
-NNN-NN-N	[	0.	-0.18	-0.85	-0.39	0.	-0.7	-0.26	0.	-0.51]
N-NN---NN	[	-0.07	0.	-0.41	-0.9	0.	0.	0.	-0.37	-0.62]
N--NN-N-L	[	-0.25	0.	0.	-0.76	-0.13	0.	-0.04	0.	1.]]

22 pav. Testavimams atlikti sugeneruoti atsitiktiniai emocijų įverčiai kortelėms (ekranvaizdžio kopija).

Modelio apmokymo metu, kiekvieno agento žingsnyje yra apskaičiuojami atlygio taškai, pagal kuriuos yra išmokstama optimali strategija. Pritaikius veido emocijos duomenis į kortelių metaduomenis yra sudaryta papildoma funkcija, kuri prie apskaičiuoto atlygio prideda taškus iš pasirinktos kortelės metaduomenų. „CardFinder+ Sense“ algoritmo aplinkose yra naudojamos 3 matricos. Pirmoji nurodo kortelės numerį, tyrimo atveju nuo 0 iki 80. Antroji matrica savyje laiko duomenis ar kortelė teisinga, teigiama, neigiama ar neutrali. Trečioji nusako emocijos vertę konkrečioje kortelėje. Agento atlygiui apskaičiuoti, galima varijuoti antrosios matricos kortelių būsenos įverčiais (žr. 14 pav., procesas 4.3.). Pavyzdžiui, agentui pradėjus veiksmus pradžios kortelėje S , pozicijoje $[0, 0]$ ir žengus žingsnį į poziciją $[4, 2]$ (žr. 24 pav.), atlygis yra apskaičiuojamas tokiu būdu:

$$A = a(b) + E(k) v$$

$$a(b) = \begin{cases} A_L, & b = \text{„Teisinga kortelė“} \\ A_N, & b = \text{„Neigiama kortelė“} \\ A_T, & b = \text{„Teigiama kortelė“} \\ A_x, & \text{kitais atvejais} \end{cases} \quad (12)$$

Atlygis A yra sumuojamas pagal $a(b)$ konkrečios kortelės atlygį ir tos kortelės k emocijos įvertį E , padaugintą iš konstantos v . Konstanta v algoritme apibrėžiama kaip hiperparametras, kuris valdo kaip smarkiai emocijos duomenys įtakoja apdovanojimo rezultatą.

Įvertinti veido emocijos duomenų įtaką modelio apmokymo procesui, buvo atliekami tyrimai aprašyti 3 eksperimentai, kai pradžios kortelė nustatoma skirtingais būdais ir keičiamas epochų skaičius (žr. 10 lentelę).

10 lentelė. „CardFinder+ Sense“ testavimo rezultatai, kai kortelės turi emocijos įverčius, per 10000 testų

Eksperimentas	Epochų skaičius	Teisingai išspręsta
1 – startas pradžioje ir viduryje	15	1%
1 – startas pradžioje ir viduryje	100	0%
1 – startas pradžioje ir viduryje	1000	0%
2 – startas pradžioje, viduryje ir pabaigoje	15	39,6%
2 – startas pradžioje, viduryje ir pabaigoje	100	66,6%
2 – startas pradžioje, viduryje ir pabaigoje	1000	66,9%
3 – atsitiktinės vietos startas	15	21,6%
3 – atsitiktinės vietos startas	100	19,4%
3 – atsitiktinės vietos startas	1000	18,4%

Pritaikius agento atlygio skaičiavimą su atsižvelgimu į emocijų metaduomenis, pastebima, kad modelis nesugeba rasti rasti teisingos kortelės testavimo metu arba ją randa tik dalį atvejų kartų (iki ~67% kartų). Toks rezultatas yra netinkamas algoritmo naudojimui, nes nėra modelis nėra tinkamai apmokomas.


Papildomai yra bandyta keisti konstantą v (žr. 11 lentelę), kad patikrinti kaip emocijų duomenys įtakoja teisingai išspręstų testų kiekį.

Mažesnė emocijos duomenų įtaka visų eksperimentų metu ženkliai pagerino rezultatą, kaip dažnai modelis sėkmingai atlieka testavimo scenarijų. Tuo pačiu, visų eksperimentų metu, žingsnių skaičius, kad pasirinkti teisingą kortelę neviršijo 5 žingsnių.

11 lentelė. „CardFinder+ Sense“ išsprendžiamų testų procentas, kas 100 epochų, keičiant konstantą v , per 10000 testų

Eksperimentas	Įtaka n	Teisingai išspręsta
1 – startas pradžioje ir viduryje	1	0%
1 – startas pradžioje ir viduryje	0,5	50%
1 – startas pradžioje ir viduryje	0,1	100%
2 – startas pradžioje, viduryje ir pabaigoje	1	66,6%
2 – startas pradžioje, viduryje ir pabaigoje	0,5	100%
2 – startas pradžioje, viduryje ir pabaigoje	0,1	100%
3 – atsitiktinės vietos startas	1	19,4%
3 – atsitiktinės vietos startas	0,5	50,3%
3 – atsitiktinės vietos startas	0,1	94,8%

Kadangi algoritmas sėkmingai nustato teisingą kortelę kartu naudojantis ir iš anksto apibrėžtais veido emocijų duomenimis, jam buvo pritaikyta HSEmotion biblioteka, kad nustatyti emociją iš nuotraukos, o ne naudoti atsitiktinę vertę (14 pav., procesas 4.4.). Eksperimentui atlikti, buvo sudarytas atskiras metodas, kuris pasirenką atsitiktinę nuotrauką iš RAF-DB duomenų rinkinio, kurią apdoroja HSEmotion modelis, kuris tuomet nustato kokią emociją atpažystą ir kaip užtikrintai. Iš duomenų rinkinio buvo atrinktos trys pagrindinės emocijos – liūdesys, neutrali padėtis ir laimė, kad paprasčiau įsivertinti modelio veikimą. Sudaryti įverčiai kiekvienai iš emocinių padėčių, kurie įtakoja agento apdovanojimo arba baudos taškus (žr. 23 pav.). Teigiamos emocijos siejamos su teigiama reikšme, neigiamos atvirkščiai (žr. 24 pav.). Šie emocijų įverčiai, taškų apskaičiavimo metu, yra dauginami su buvusio eksperimento metu sudaryta konstanta v .



23 pav. Veido emocijos įverčio pritaikymo principas agento apdovanojimui.

EMOTION_SCORES = {	[Emotion] test_2694_aligned.jpg → Happiness	confidence: 0.82	score: +0.818
"Happiness": 1.0,	[Emotion] test_0945_aligned.jpg → Neutral	confidence: 0.70	score: +0.000
"Neutral": 0.0,	[Emotion] test_1687_aligned.jpg → Sadness	confidence: 0.87	score: -0.434
"Sadness": -0.5	[Emotion] test_3013_aligned.jpg → Happiness	confidence: 0.80	score: +0.796
}	[Emotion] test_0180_aligned.jpg → Happiness	confidence: 0.90	score: +0.896

24 pav. Liūdesio, neutralios ir laimės emocijų įverčiai ir rezultatai testavimo metu (ekranvaizdžio kopija).

Įgalinant algoritmui „CardFinder+ Sense“ naudoti veido emocijos metaduomenims yra gautas žemesnis žingsnių skaičius, lyginant su „CardFinder“ ir praeitais tyrime gautais rezultatais.

Kai duomenų įtaka yra pakankamai žema, rezultatai išlieka patenkinami, o testavimo metu dviems eksperimentams yra pasiekiamas 100% teisingas modelio veikimas. Modelis gali veikti su išanksto apibrėžtais emocijų duomenų rinkiniais arba vykdyti emocijos nustatymą iš nuotraukų realiu laiku.

2.2.4. Mokymosi ir testavimo keliose aplinkose pritaikymas

Kadangi modelis turi būti apmokytas veikti įvairiose, iš anksto neapibrėžtose, aplinkose, algoritmo apmokymo ir testavimo scenarijus buvo papildytas naujomis funkcijomis:

- Modelio apmokymo proceso vykdymas keliose aplinkose.
- Testavimo scenarijų iteravimas per kelias aplinkas.

Validžių rezultatų užtikrinui, atsitiktiniu būdu buvo atrinktos 3 aplinkos, kuriuose bus vykdomi skatinamojo mokymosi modelio apmokymo ir testavimo procesai (žr. 15 pav., procesas 5.1.). Visose aplinkose pradžios taškas ir teisinga kortelė yra atitinkamai žemėlapių pradžioje ir pabaigoje, tačiau kiekviena kortelė turi savo atskirą identifikacinį numerį, kuris yra atsitiktinai sugeneruojamas kiekvienai aplinkai individualiai. Dėl to, nors ir žemėlapyje kortelės pavaizduotos toje pačioje pozicijoje, algoritmo veikimo metu jos yra atsitiktinėse vietose (žr. 25 pav.).

1 aplinka	2 aplinka	3 aplinka	3 aplinkos identifikaciniai numeriai
S N - NNNNNN	S - N - - NTNN	S N - N - NN - N	[[66 21 27 28 45 53 37 7 41]
N - NNN - - - N	- N - TNNN - T	- N - NN - NN -	[3 56 31 10 42 12 8 34 5]
- TNN - N - N -	NNNN - N - - N	- NNNNNNNN	[71 77 39 62 38 48 30 25 67]
- NNN - NNNN	- NNNNNNNN	- N - NN - - NN	[73 58 6 74 76 40 44 52 11]
- - - - NNNNN	TN - NNN - - N	NNNNN - N - N	[64 70 32 54 0 57 20 46 63]
N - - NNNNN -	- N - NNTNN -	NNNNNNNNN	[13 55 15 78 60 51 49 33 16]
NNN - NNNN -	- N - N - N - NN	- N - NNNN - N	[4 79 2 68 23 29 75 47 59]
TN - - - N - - N	NNNNNNNNN	TNNNN - NNN	[24 36 14 43 65 22 9 35 18]
NN - NN - N - L	N - TN - - N - L	- NN - NTNNL	[19 1 61 69 50 72 80 26 17]]


25 pav. Trijų aplinkų žemėlapiai (ekranvaizdžio kopija).

Visos trys aplinkos naudoja tuos pačius hiperparametrus, apdovanojimo ir baudos taškų sistemą ir agentas turi tuos pačius galimus veiksmus. Dėl šios priežasties Q-reikšmių lentelė naudojama viena, visoms aplinkoms.

„CardFinder+ Sense“ algoritmas buvo papildytas galimybe naudotis 3 atskirais masyvais, kurie tarpusavyje turi sąryšį pagal masyvų identifikacinį skaičių. Pirmas masyvas savyje talpina aplinkas ir jų kortelių identifikacinius numerius. Antrasis masyvas savyje talpina aplinkų kortelių būsenas. Trečiasis – aplinkų kortelių veido emocijos įverčius.

Pirminio bandymo metu pritaikant skirtingas aplinkas modelio apmokymo procesui, yra pastebima, kad agentas pamiršta visą sukaupią informaciją apie praėjusias aplinkas, kai jose yra mokomasi

sekvenciškai. Toks agento katastrofiškas užmirštamumas buvo išspręstas modelį apmokant skirtingose aplinkose kiekvieno epizodo metu (žr. 26 pav.), o ne pereinant prie naujos aplinkos po paskutinio epizodo. Apmokyti modeliai sėkmingai randa teisingas korteles per nedaugiau kaip 6 žingsnius skirtingose aplinkose vienu metu.



26 pav. Modelio apmokymo rezultatai apmokymo (kairėje) ir testavimo (dešinėje) metu, trijose aplinkose vienu metu.

Visos trys aplinkos turi teisingą kortelę skirtingose atsitiktinėse vietose. Eksperimentinio tyrimo metu, buvo vykdomi modelio apmokymo bandymai, kad įvertinti, kaip gerai modelis sugeba išmokyti veikti dirbti trijose aplinkose vienu metu, taikant standartinius Q-mokymosi metodus (žr. 12 lentelę).

12 lentelė. „CardFinder+ Sense“ eksperimentų rezultatai 3 aplinkose, per 100 testų, naudojant Q-mokymosi metodus

	1 aplinka		2 aplinka		3 aplinka	
	% teisingai išspręsta	žingsnių vid.	% teisingai išspręsta	žingsnių vid.	% teisingai išspręsta	žingsnių vid.
1 eksp. 300 epochų	68,18	6,75	88,89	3	65	4,94
2 eksp. 300 epochų	75,3	2,95	100	2,17	83,40	2,37
3 eksp. 300 epochų	59,55	4,91	62,31	3,31	71,33	4
1 eksp. 3000 epochų	85	6,05	92,86	3	96,15	4,58
2 eksp. 3000 epochų	96,80	3,37	97,42	1,99	96,38	3,01
3 eksp. 3000 epochų	81,27	5,44	85,62	3,86	94,45	4,13

Iš gaunamų rezultatų pastebima, kad algoritmas sėkmingai geba apsimokyti ir veikti trijose skirtingose aplinkose. Geriausi rezultatai pasireiškė 2 eksperimento metu, kai pradžios kortelė buvo atsitiktinai priskiriama kaladės pradžiai, viduriui arba pabaigai. Didesnis aplinkų kiekis apsunkina modelio testavimą, modelis dažniau nesugeba rasti teisingos kortelės (t.y. neišsprendžia testo). Kai epochų skaičius didinamas, modelis spėja išmokyti optimalesnę strategiją ir neišsprendžiamumo kiekis mažėja.

Kad pabandyti sumažinti kaip dažnai modelis neišsprendžia testo, algoritmui buvo pritaiky-

tas jau bandytas dvigubas Q-mokymasis (žr. 15 pav., procesas 3.2.), kad įvertinti, ar jo metodų panaudojimas, pagerina rezultatus lyginant su standartiniu Q-mokymusi (žr. 13 lentelę).

13 lentelė. „CardFinder+ Sense“ eksperimentų rezultatai 3 aplinkose naudojant dvigubo Q-mokymosi metodus, per 100 testų

	1 aplinka		2 aplinka		3 aplinka	
	% teisingai išspręsta	žingsnių vid.	% teisingai išspręsta	žingsnių vid.	% teisingai išspręsta	žingsnių vid.
1 eksp. 300 epochų	60,42	4,34	65,66	4,22	65,24	5,39
2 eksp. 300 epochų	100	3,57	82,82	1,89	81,11	3,07
3 eksp. 300 epochų	72,25	5,54	79,6	4,09	77,62	3,83
1 eksp. 3000 epochų	57,14	3,90	72,73	3,20	91,67	5,33
2 eksp. 3000 epochų	80,73	2,94	85	3,12	100	3,29
3 eksp. 3000 epochų	81,09	5,57	92,40	4,28	87,89	4,44

Kaip ir buvusių eksperimentų metu, dvigubo Q-mokymosi pritaikymas nesuteikė reikšmingų rezultatų. Tiek mažesniame epochų kiekyje, tiek didesniame, modelio rezultatai buvo prastesni už standartinio Q-mokymosi modelį.

Modeliai, kurie pasiekė geriausius rezultatus, mokymosi ir testavimo procesą vykdė su standartiniais Q-mokymosi metodais, kai pradžios kortelė buvo nustatoma aplinkų pradžioje, viduryje ir pabaigoje pagal ~33% tikimybę. Tokiu būdu, per 3.000 epochų apmokyti modeliai sėkmingai rado teisingas korteles testavimų metu visose aplinkose tarp ~96% kartų, vidutiniškai per 3 žingsnius.

2.3. Modelio analizė

Tyrimo ir eksperimentų metu sudarytas „CardFinder+ Sense“ algoritmas, gebantis išmokyti pasiūlyti PECS korteles, kurios galėtų būti tinkamos, kaip pasirinkimai bendravimui vaikams, turintiems autizmo spektro sutrikimą. Algoritmas yra paremtas skatinamojo mokymosi metodais, konkrečiai Q-mokymosi metodais.

Modelis turi savybę mokytis keliose aplinkose, kad išmokyti optimalią strategiją veikti nepriklausomai nuo kortelių išdėstymo aplinkoje. „CardFinder+ Sense“ gali veikti su veido emocijų duomenimis kortelių metaduomenyse arba neturint sukauptų duomenų. Modelio apmokymo ir testavimo procesai gali būti vykdomi 4 režimais, pasirinktinai:

1. Režimas nustatantis pradžios kortelę atsitiktinėje vietoje.
2. Režimas nustatantis pradžios kortelę kaladės pradžioje arba per vidurį, su 50% tikimybe.
3. Režimas nustatantis pradžios kortelę kaladės pradžioje, per vidurį arba pabaigoje, su ~33% tikimybe.
4. Režimas nustatantis pradžios kortelę kaladės pradžioje.


„CardFinder+ Sense“ geba veikti su visais išvardintais režimais, mažame epochų kiekyje ir didesniame (žr. 14 lentelę).

14 lentelė. Modelio rezultatai ieškant kortelės vienoje konkrečioje aplinkoje

Modelis apmokytas per 15 epochų								
	1 režimas		2 režimas		3 režimas		4 režimas	
	Vid. žing. sk.	Išspr. %	Vid. žing. sk.	Išspr. %	Vid. žing. sk.	Išspr. %	Vid. žing. sk.	Išspr. %
Be emoc. duom.	3,34	~95	4	100	2,67	100	5	100
Su emoc. duom.	3,16	~95	4	100	2,69	100	5	100


Modelis apmokytas per 100 epochų								
Be emoc. duom.	3,16	~95	4	100	2,67	100	5	100
Su emoc. duom.	3,13	~95	4	100	2,67	100	5	100

Modelis gali būti apmokomas visiškai atsitiktinai sugeneruotose aplinkose, su randomizuotomis ar nustatomis iš nuotraukos veido emocijų duomenimis kortelių metaduomenyse arba be duomenų. Modelio efektyvumui įvertinti, jis buvo apmokytas pirmuoju režimu, per 3.000 epochų, kas kiekvieną epochą buvo sugeneruojama nauja atsitiktinė aplinka. Apmokytam modeliui tuomet buvo atlikta 1.000 testavimo atvejų. Kiekvieno testo metu, aplinkos buvo generuojamos atsitiktinės, visiškai nesusijusios su aplinkomis naudotomis modelio apmokymo metu. Pirmuoju režimu, modelis teisingai išsprendė 92% visų testų, dažniausiai per 7 žingsnius (žr. 27 pav.), atsižvelgiant į tai, kad testavimo metu aplinkos galėjo būti modeliui dar nematytos.



27 pav. „CardFinder+ Sense“ testavimo rezultatai, be veido emocijos duomenų, atsitiktinėse aplinkose.

Apmokant modelį pirmuoju režimu atsitiktinėse aplinkose ir nustačius, kad kiekvienai aplinkai būtų sugeneruojami atsitiktiniai veido emocijos duomenys kortelėms, vidutinis žingsnių skaičius tampa mažesnis. Modelis teisingai išsprendžia 94,3% testų, dažniausiai per 7 žingsnius (žr. 28 pav.).



28 pav. „CardFinder+ Sense“ testavimo rezultatai atsitiktinėse aplinkose su atsitiktiniais veido emocijų duomenimis.

Iš gaunamų rezultatų pastebima, kad algoritmas geba veikti tiek jau matytose aplinkose tiek nematytose, tačiau sekančiu atveju jam reikia pakankamai apsimokyti skirtingose aplinkose, kad galėtų jose rasti teisingą kortelę. Veido emocijų duomenys kortelėms didžiausią įtaką suteikia, kai aplinkos yra atsitiktinės arba 1 režimo naudojimo atveju.

2.4. Modelio validavimas

Norint atlikti validaciją su tikrais duomenimis reikalingas bioetikos leidimas. Dėl šios priežasties modelis validuojamas sukuriant tris sintetinius scenarijus:

1. Scenarijus, kai vaikui yra tinkamos bent trys kortelės.
2. Scenarijus, kai vaikui yra tinkama tik viena kortelė.
3. Scenarijus, kai vaikui buvo tinkama konkreti kortelė prieš tai, bet paskutiniu metu, tinkama kortelė yra visai kita.

Modeliui validuoti yra tikrinami visi pradžios kortelės nustatymo režimai ir atvejai, kai modeliui yra pateikiami arba nėra pateikiami veido emocijų duomenys (žr. 15 lentelę). Validavimui atlikti, modeliai apmokomi per 100 epochų. Pirmo ir antro scenarijaus validavimui yra keičiamos kortelių aplinkos, kad atitiktų scenarijų. Trečiajam scenarijui, teisinga kortelė yra pakeičiama į kitą, likus 20 epochų iki apmokymo pabaigos.

Modelis sėkmingai randa teisingas korteles, nepriklausomai nuo jų kiekio aplinkoje ir geba prisitaikyti prie besikeičiančių duomenų. Pritaikant algoritmą naudojimui yra svarbu nenutraukti Q-verčių atnaujinimo, kad išlaikyti savybę prisitaikyti prie pokyčių.

15 lentelė. Modelio rezultatai pagal validavimo scenarijus

1 scenarijus								
	1 režimas		2 režimas		3 režimas		4 režimas	
	Vid. žing. sk.	Išspr. %	Vid. žing. sk.	Išspr. %	Vid. žing. sk.	Išspr. %	Vid. žing. sk.	Išspr. %
Be emoc. duom.	1,78	100	3	100	2,67	100	4	100
Su emoc. duom.	1,78	100	3	100	2,67	100	4	100
2 scenarijus								
Be emoc. duom.	3,16	~95	4	100	2,68	100	5	100
Su emoc. duom.	3,16	~95	4	100	2,67	100	5	100
3 scenarijus								
Be emoc. duom.	2,84	~89	2,5	100	2	~34	2	100
Su emoc. duom.	2,64	~88	2,5	100	2	~33	2	100

2.5. Tyrimo apibendrinimas

Tyrimo metu buvo analizuojamas „CardFinder“ algoritmas, kurio tikslas apmokyti skatinamuoju mokymusi paremtą modelį, skirtą rasti tinkamą PECS kortelę, kurio pagrindu sukurtas „CardFinder+ Sense“ algoritmas, siekiant pagerinti modelio rezultatus ir jo panaudojamumą autizmo spektro sutrikimą turintiems vaikams. Buvo atliktos modifikacijos, kuriomis bandyta sumažinti žingsnių skaičių, per kurį modeliui pavyksta rasti tinkamą kortelę.

Tyrimo metu buvo rasti algoritmo hiperparametrai, kurie labiausiai įtakoja algoritmo mokymosi stabilumą, kuris įgalino kuo dažniau pateikti pastovius rezultatus, siekiant rasti teisingą kortelę. Sekančiu etapu, algoritmui buvo pritaikyta funkcija, pasirinkti pradžios kortelės vietą mokymosi ir testavimo procesams. Ši funkcija leido „CardFinder+ Sense“ pagerinti „CardFinder“ rezultatus, per kiek žingsnių randama teisinga kortelė.

Eksperimentų metu bandyta pritaikyti dvigubo Q-mokymosi metodus ir pastebėta, kad algo-

ritmui tinkamai veikti naudojant šiuos metodus, reikia vykdyti mokymosi procesą ilgesnį laiką, per daugiau epochų.

Algoritmui „CardFinder+ Sense“ įgalinta naudotis veido emocijos duomenimis, priskiriant juos kortelių metaduomenims. Tyrimų metu, buvo sudaryti atsitiktiniai emocijų duomenys, kad patikrinti jų naudą. Sudaryta galimybė nuskaityti veido emociją iš nuotraukos, kad pritaikyti papildomą įvertį agento apdovanojimo procesui.

Siekiant užtikrinti pritaikomumą realioms panaudojamumo situacijoms, algoritmas buvo papildytas funkcijomis, leidžiančiomis veikti keliose aplinkose vienu metu. Pastebėta, kad modeliui mokantis aplinkose pasekliui, agentas pamiršta visą sukaupią informaciją apie praėjusias aplinkas, dėl to buvo atsižvelgta, kada agentui turėtų būti pakeičiama aplinka po kiekvieno mokymosi ciklo, kad informacija būtų neužmiršta.

Rezultatai ir išvados

Atlikus tyrimo eksperimentus, gauti šie rezultatai:

1. Išanalizavus skatinamojo mokymosi algoritmo hiperparametrų įtaką ir pritaikius jų rinkinį modelio apmokymo procesams, nustatyta, jog rezultatas tampa stabilesnis, kad skirtingų modelio apmokymų metu rasti kortelė per optimalų modelio žingsnių skaičių. Mokinant modelį per 15 epochų, modelis kortelę randa lėčiau, negu optimalu tik 1% kartų vietoje ~13% kartų.
2. Nustatyta, kad pradžios kortelės priskyrimas į skirtingas pozicijas mokymosi ir veikimo procesams įgalina skatinamojo mokymosi modeliui rasti teisingą kortelę per mažesnį žingsnių skaičių, mažiausiai 1 žingsniu greičiau.
3. Atlikus eksperimentus su dvigubo Q-mokymosi metodais nustatyta, kad jo pritaikymas nebuvo naudingas, modeliui mokinantis per 15 epochų modelis teisingos kortelės neranda arba randa iki 66% kartų. Didesniame epochų kiekyje rezultatai nesiskiria nuo modelio rezultatų su standartiniais Q-mokymosi metodais.
4. Įvertinta, kad dideliame kiekyje atsitiktinių aplinkų, veido emocijų duomenys padeda rasti teisingą kortelę ~11% greičiau, lyginant su modeliu, apmokytu be veido emocijos duomenų, o pavienės aplinkos atvejais ~5,4%, kai pradžios kortelės pozicija yra priskiriama į atsitiktines pozicijas.
5. Nustatyta, kad algoritmui pritaikius metodus, mokytis keliose skirtingose aplinkose vienu metu, įgalino modeliui ieškoti teisingos kortelės tarp skirtingų aplinkų, nepriklausomai, ar jis buvo apmokytas tose aplinkose.

Atlikus tyrimą, nustatytos išvados:

1. Išanalizavus autizmo spektro sutrikimą turinčių vaikų elgsenos modelius ir skatinamojo mokymosi modelius, nustatyta, kad Q-mokymosi ir dvigubo Q-mokymosi modeliams nereikia paruoštų išankstinių duomenų, todėl jie yra tinkami projektuoti modelį bendravimui PECS kortelėmis, pagal autizmo spektro sutrikimą turinčių vaikų bendravimo elgseną. Kadangi autizmo spektro sutrikimą turinčių vaikų elgsena ir poreikiai yra skirtingi, pradžios kortelės vietos keitimas leidžia modeliui prisitaikyti prie individualių panaudojamumo atvejų ir rasti teisingą kortelę per mažesnį žingsnių skaičių.
2. Ištyrus „CardFinder“ modelį nustatyta, kad jo naudojimosi metu, jis veikia nestabiliai toje pačioje aplinkoje, nėra sudarytas veikti keliose aplinkose vienu metu ir jo kortelės radimo žingsnių skaičius gali paveikti algoritmo panaudojamumą.
3. Ištyrus „CardFinder+ Sense“ modelį, nustatyta, kad emocijų integravimas sumažina žingsnių kiekį iki 11%, kai modelis veikia režimu, nustatančiu agento pradinę poziciją į atsitiktinę vietą. Gauta išvada leidžia patvirtinti išsiskeltą darbo hipotezę.

Literatūra ir šaltiniai

- [AAA⁺23] J. Achiam, S. Adler, S. Agarwal, L. Ahmad ir kiti. „Gpt-4 technical report“. Iš: *arXiv preprint arXiv:2303.08774* (2023).
- [AY21] P. Ali, A. Younas. „Understanding and interpreting regression analysis“. Iš: *Evidence-Based Nursing* 24.4 (2021), puslapiai 116–118.
- [Ald23] C. Aldred. *Paediatric autism communication therapy improved long-term child outcomes*. <https://www.openaccessgovernment.org/wp-content/uploads/2023/03/openaccessgovernment.org-Paediatric-autism-communication-therapy-improved-long-term-child-outcomes.pdf>. 84 KB, žiūrėta 2024-12-08. 2023.
- [ALK20] N. Alamdari, E. Lobarinas, N. Kehtarnavaz. „Personalization of hearing aid compression by human-in-the-loop deep reinforcement learning“. Iš: *IEEE access* 8 (2020), puslapiai 203503–203515.
- [AMA⁺19] S. Ali, F. Mehmood, Y. Ayaz, M. J. Khan, H. Sadia, R. Nawaz. *Comparing the Effectiveness of Different Reinforcement Stimuli in a Robotic Therapy for Children With ASD*. <https://doi.org/10.1109/ACCESS.2020.2965204>. 9,1 MB, žiūrėta 2024-12-09. 2019.
- [AMS⁺21] V. Ardulov, V. R. Martinez, K. Somandepalli, S. Zheng, E. Salzman, C. Lord, Narayanan. „Robust diagnostic classification via Q-learning“. Iš: *Scientific reports* 11.1 (2021).
- [Ari20] T. Ariwijaya. *PECS vs. iPad I ntervention for Students with Autism Spectrum Disorders: A Literature Review*. <https://doi.org/10.21776/ub.ijds.2020.007.02.09>. 554 KB, žiūrėta 2024-12-09. 2020.
- [ASR⁺22] I. A. Ahmed, E. M. Senan, T. H. Rassem, M. A. Ali, H. S. A. Shatnawi, S. M. Alwazer, M. Alshahrani. „Eye tracking-based diagnosis and early detection of autism spectrum disorder using machine learning and deep learning techniques“. Iš: *Electronics* 11.4 (2022), puslapis 530.
- [BCS⁺18a] A. Brignell, K. V. Chenausky, H. Song, J. Zhu, C. Suo, A. T. Morgan. „Communication interventions for autism spectrum disorder in minimally verbal children“. Iš: *Cochrane Database of Systematic Reviews* 11 (2018).
- [BCS⁺18b] A. Brignell, K. V. Chenausky, H. Song, J. Zhu, C. Suo, A. T. Morgan. „Communication interventions for autism spectrum disorder in minimally verbal children“. Iš: *Cochrane Database of Systematic Reviews* 11 (2018).
- [BD08] A. G. Barto, T. G. Dietterich. *Reinforcement Learning and its Relationship to Supervised Learning*. <https://web.engr.oregonstate.edu/~tgd/publications/Barto-Dietterich-03.pdf>. 83,7 KB, žiūrėta 2024-12-09. 2008.

- [BML⁺14] H. Boonen, J. Maljaars, G. Lambrechts, I. Zink, K. Van Leeuwen, I. Noens. „Behavior problems among school-aged children with autism spectrum disorder: Associations with children’s communication difficulties and parenting behaviors“. Iš: *Research in Autism Spectrum Disorders* 8.6 (2014), puslapiai 716–725.
- [Bol11] S. Bolte. *Brief Report: The Social Responsiveness Scale for Adults (SRS-A): Initial Results in a German Cohort*. https://pmc.ncbi.nlm.nih.gov/articles/PMC3425739/pdf/10803_2011_Article_1424.pdf. 171 KB, žiūrėta 2025-04-21. 2011.
- [BVG⁺22] P. D. Barua, J. Vicnesh, R. Gururajan, S. L. Oh, E. Palmer, M. M. Azizan, N. A. Kadri, U. R. Acharya. *Artificial Intelligence Enabled Personalised Assistive Tools to Enhance Education of Children with Neurodevelopmental Disorders—A Review*. <https://www.mdpi.com/1660-4601/19/3/1192>. 4.1 MB, žiūrėta 2024-12-08. 2022.
- [CBC23] P. Cipresso, F. Borghesi, A. Chirico. „Affects affect affects: A Markov chain“. Iš: *Frontiers in Psychology* 14 (2023), puslapis 1162655.
- [CD92] J. „Christopher, P. Dayan. „Q-learning““. Iš: *Machine learning* 8 (1992), „279–292“.
- [DKA⁺20] S. Dargan, M. Kumar, M. R. Ayyagari, G. Kumar. „A survey of deep learning and its applications: a new paradigm to machine learning“. Iš: *Archives of computational methods in engineering* 27 (2020), puslapiai 1071–1092.
- [Ef124] V. Efimov. *Reinforcement Learning, Part 1: Introduction and Main Concepts*. 2024. URL: <https://medium.com/data-science/reinforcement-learning-introduction-and-main-concepts-48ea997c850c> (žiūrėta 2025-05-26).
- [EYA⁺22] B. R. G. Elshoky, E. M. Younis, A. A. Ali, O. A. S. Ibrahim. „Comparing automated and non-automated machine learning for autism spectrum disorders classification using facial images“. Iš: *Etri Journal* 44.4 (2022), puslapiai 613–623.
- [FN25] E. Farsari, C. Nitsiou. „The implementation of an interactive educational intervention program using the Kinems learning games platform to improve gross motor skills in children with ASD“. Iš: *Preschool and Primary Education* 13.1 (2025), puslapiai 29–49.
- [FTS⁺23] M. S. Farooq, R. Tehseen, M. Sabir, Z. Atal. „Detection of autism spectrum disorder (ASD) in children and adults using machine learning“. Iš: *scientific reports* 13.1 (2023), puslapis 9605.
- [GO19] S. Greydanus, C. Olah. „The Paths Perspective on Value Learning“. Iš: *Distill* (2019). <https://distill.pub/2019/paths-perspective-on-value-learning>. <https://doi.org/10.23915/distill.00020>.
- [Goo25] Google Trends. *Trends*. 2025. URL: <https://trends.google.com/trends/explore?date=today%205-y&q=autism&hl=en> (žiūrėta 2025-05-24).
- [Haq19] M. I. Haque. *A facial expression recognition application development using deep convolutional neural network for children with autism spectrum disorder to help identify human emotions*. 2019.

- [HMA23] H. Hughes, R. Moreno, P. Ashwood. „Innate immune dysfunction and neuroinflammation in autism spectrum disorder (ASD)“. Iš: *Brain, behavior, and immunity* 108 (2023), puslapiai 245–254.
- [HMM20] A. Hassouneh, A. M. Mutawa, M. Murugappan. „Development of a real-time emotion recognition system using facial expressions and EEG based on machine learning and deep neural network methods“. Iš: *Informatics in Medicine Unlocked* 20 (2020).
- [Ye20] A. Ye. *11 Essential Neural Network Architectures, Visualized And Explained*. 2020. URL: <https://medium.com/analytics-vidhya/11-essential-neural-network-architectures-visualized-explained-7fc7da3486d8> (žiūrėta 2025-05-26).
- [IPR⁺21] A. Ibrahimagic, N. Patkovic, B. Radic, S. Hadzic. „Communication and language skills of autistic spectrum disorders in children and their parents’ emotions“. Iš: *Materia socio-medica* 33.4 (2021), puslapis 250.
- [JWX⁺25] Y. Ji, S. Wang, R. Xu, J. Chen, Y. Quan, X. Jiang, Z. Deng, J. Liu. „Hugging Rain Man: A Novel Facial Action Units Dataset for Analyzing Atypical Facial Expressions in Children with Autism Spectrum Disorder“. Iš: *IEEE Transactions on Affective Computing* (2025), puslapiai 1–17. <https://doi.org/10.1109/TAFFC.2025.3558914>.
- [KAA⁺22] A. Khattak, M. Z. Asghar, M. Ali, U. Batool. „An efficient deep learning technique for facial emotion recognition“. Iš: *Multimedia Tools and Applications* 81 (2022), puslapiai 1649–1683.
- [KFP⁺23] A. Khabbaz, M. Fateh, A. Pouyan, M. Rezvani. „Designing a Serious Game for Children with Autism using Reinforcement Learning and Fuzzy Logic“. Iš: *Journal of AI and Data Mining* 11.3 (2023), puslapiai 375–390.
- [KH20] K. Ke, M. Huang. *Quality prediction for injection molding by using a multilayer perceptron neural network*. *Polymers (Basel)* 12 (8). 2020.
- [Kha22] A. Khan. „Facial emotion recognition using conventional machine learning and deep learning methods: current achievements, analysis and remaining challenges“. Iš: *Information* 13 (2022).
- [KJA⁺20] Y. Kortli, M. Jridi, A. Al Falou, M. Atri. „Face recognition systems: A survey“. Iš: *Sensors* 20.2 (2020), puslapis 342.
- [KKB⁺22] M. Kohli, A. K. Kar, A. Bangalore, P. Ap. „Machine learning-based ABA treatment recommendation and personalization for autism spectrum disorder: an exploratory study“. Iš: *Brain Informatics* 9.1 (2022), puslapis 16.
- [KLM96] L. P. Kaelbling, M. L. Littman, A. W. Moore. „Reinforcement learning: A survey“. Iš: *Journal of artificial intelligence research* 4 (1996), puslapiai 237–285.
- [Kun18] H. Kung-Hsiang. *Introduction to Various Reinforcement Learning Algorithms. Part I (Q-Learning, SARSA, DQN, DDPG)*. 2018. URL: <https://medium.com/data-science/introduction-to-various-reinforcement-learning-algorithms-i-q-learning-sarsa-dqn-ddpg-72a5e0cb6287> (žiūrėta 2025-05-24).

- [KZH20] D. Kumar, Z. Zhang, K. Huang. „Multi angle optimal pattern-based deep learning for automatic facial expression recognition–ScienceDirect“. Iš: *Pattern Recognition Letters* 139 (2020), puslapiai 157–165.
- [LEC⁺13] A. Lerna, D. Esposito, M. Conson, A. Massagli. *Long-term effects of PECS on social–communicative skills of children with autism spectrum disorders: a follow-up study*. <https://doi.org/10.1111/1460-6984.12079>. 138 KB, žiūrėta 2024-12-09. 2013.
- [LIT17] LITALICO. *Card Talk*. 2017. URL: <https://app.litalico.com/cardtalk/index.html> (žiūrėta 2025-06-12).
- [LLA⁺24] Y. Lyu, D. Liu, P. An, X. Tong, H. Zhang, K. Katsuragawa, J. Zhao. „EMooly: Supporting Autistic Children in Collaborative Social-Emotional Learning with Caregiver Participation through Interactive AI-infused and AR Activities“. Iš: *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies* 8.4 (2024), puslapiai 1–36.
- [LLX⁺19] M. Li, X. Li, L. Xie, J. Liu, F. Wang, Z. Wang. *Assisted therapeutic system based on reinforcement learning for children with autism*. <https://doi.org/10.1080/24699322.2019.1649072>. 2,2 MB, žiūrėta 2024-12-09. 2019.
- [Mah⁺20] B. Mahesh ir kiti. „Machine learning algorithms–a review“. Iš: *International Journal of Science and Research (IJSR)*. [Internet] 9.1 (2020), puslapiai 381–386.
- [MDM⁺22] J. T. Megerian, S. Dey, R. D. Melmed, D. L. Coury ir kiti. „Evaluation of an artificial intelligence-based medical device for diagnosis of autism spectrum disorder“. Iš: *NPJ digital medicine* 5.1 (2022), puslapis 57.
- [MFG⁺20] S. Milani, Z. Fan, S. Gulati, T. Nguyen, F. Fang, A. Yadav. „Intelligent tutoring strategies for students with autism spectrum disorder: A reinforcement learning approach“. Iš: *The 2020 CMU Symposium on Artificial Intelligence and Social Good*. 2020.
- [MH20] W. Mellouk, W. Handouzi. „Facial emotion recognition using deep learning: review and insights“. Iš: *Procedia Computer Science* 175 (2020), puslapiai 689–694.
- [Mik22] A. Mikulėnas. „Mašininiu mokymusi grindžiamas naudotojo sąsajos kūrimas specialiųjų poreikių turintiems naudotojams“. Magistro darbas. Vilniaus Gedimino Technikos Universitetas, 2022.
- [Mil20] S. Milani. „Intelligent tutoring strategies for students with autism spectrum disorder: A reinforcement learning approach“. Iš: *The 2020 CMU Symposium on Artificial Intelligence and Social Good*. 2020.
- [Nas17] V. Nasteski. „An overview of the supervised machine learning methods“. Iš: *Horizons*. b 4.51-62 (2017), puslapis 56.
- [NRC20] M. Naeem, S. T. H. Rizvi, A. Coronato. „A gentle introduction to reinforcement learning and its application in different fields“. Iš: *IEEE access* 8 (2020), puslapiai 209320–209344.

- [OOO⁺23] C. Okoye, C. M. Obialo-Ibeawuchi, O. A. Obajeun, S. Sarwar ir kiti. „Early diagnosis of autism spectrum disorder: a review and analysis of the risks and benefits“. Iš: *Cureus* 15.8 (2023).
- [Pre25] Presvika. *Presvika*. 2025. URL: <https://www.presvika.lt/bendraukime-paveiksleliais> (žiūrėta 2025-05-24).
- [PV20] E. Puiutta, E. M. Veith. „Explainable reinforcement learning: A survey“. Iš: *International cross-domain conference for machine learning and knowledge extraction*. Springer. 2020, puslapiai 77–95.
- [PWB⁺17] D. A. Pitaloka, A. Wulandari, T. Basaruddin, D. Y. Liliana. „Enhancing CNN with preprocessing stage in automatic emotion recognition“. Iš: *Procedia computer science* 116 (2017), puslapiai 523–529.
- [RGB⁺24] S. Rubio-Martín, M. T. García-Ordás, M. Bayón-Gutiérrez, N. Prieto-Fernández, J. A. Benítez-Andrades. „Enhancing ASD detection accuracy: a combined approach of machine learning and deep learning models with natural language processing“. Iš: *Health Information Science and Systems* 12.1 (2024), puslapis 20.
- [RMB20] K. S. Rush, B. P. Mortenson, S. E. Birch. *The Inadvertent Effects of PECS on Vocal Responding of Children with Autism Spectrum Disorder*. <https://doi.org/10.1007/s41252-020-00168-5>. 684 KB, žiūrėta 2024-12-09. 2020.
- [RSG12] R. Rathore, P. Singh, R. Goudar. „Personalized Model of an Interactive System for Improving the Pronunciation Skills in Autistic Children“. Iš: *International Journal of Information and Education Technology* 2.5 (2012), puslapis 503.
- [SA23] K. Sharifani, M. Amini. „Machine learning and deep learning: A review of methods and applications“. Iš: *World Information Technology and Engineering Journal* 10.07 (2023), puslapiai 3897–3904.
- [Sar22] I. H. Sarker. „AI-based modeling: Techniques, applications and research issues towards automation, intelligent and smart systems“. Iš: *SN Comput. Sci.* 3.2 (2022), puslapis 158.
- [Sav22] A. V. Savchenko. „Hsemotion: High-speed emotion recognition library“. Iš: *Software Impacts* 14 (2022), puslapis 100433.
- [SBS⁺21] P. d. A. Santos, D. Bordini, M. Scattolin, G. R. d. C. Asevedo, S. C. Caetano, C. S. Paula, J. Perissinoto, A. C. Tamanaha. „The Impact of the Implementation of the Picture Exchange Communication System–PECS on Understanding Instructions in Children with Autism Spectrum Disorders“. Iš: *CoDAS*. Tomas 33. SciELO Brasil. 2021, e20200041.
- [SFB14] M. Semrud-Clikeman, J. G. Fine, J. Bledsoe. „Comparison among children with children with autism spectrum disorder, nonverbal learning disorder and typically developing children on measures of executive functioning“. Iš: *Journal of autism and developmental disorders* 44 (2014), puslapiai 331–342.

- [SG22] C. K. Syriopoulou-Delli, E. Gkiolnta. „Review of assistive technology in the training of children with autism spectrum disorders“. Iš: *International Journal of Developmental Disabilities* 68.2 (2022), puslapiai 73–85.
- [SKS24] H. A. Salman, A. Kalakech, A. Steiti. „Random forest algorithm overview“. Iš: *Babylonian Journal of Machine Learning* 2024 (2024), puslapiai 69–79.
- [SM23] P. Singhi, P. Malhi. „Early diagnosis of autism spectrum disorder: what the pediatricians should know“. Iš: *Indian Journal of Pediatrics* 90.4 (2023), puslapiai 364–368.
- [SMB23] S. K. Sahu, A. Mokhade, N. D. Bokde. „An overview of machine learning, deep learning, and reinforcement learning-based techniques in quantitative finance: recent progress and challenges“. Iš: *Applied Sciences* 13.3 (2023), puslapis 1956.
- [SMW⁺23] D. C. E. Saputra, Y. Maulana, T. A. Win, R. Phann, W. Caesarendra. „Implementation of machine learning and deep learning models based on structural MRI for identification autism spectrum disorder“. Iš: *Jurnal Ilmiah Teknik Elektro Komputer dan Informatika (JITEKI)* 9.2 (2023), puslapiai 307–318.
- [SPM⁺23] F. M. Shiri, T. Perumal, N. Mustapha, R. Mohamed. „A comprehensive overview and comparative analysis on deep learning models: CNN, RNN, LSTM, GRU“. Iš: *arXiv preprint arXiv:2305.17473* (2023).
- [Spo20] Spoken Inc. *Spoken*. 2020. URL: <https://spokenaac.com/> (žiūrėta 2025-06-12).
- [SPS⁺23] V. Silva, A. P. Pereira, F. Soares, C. P. Leao, A. Jurdi, J. S. Esteves, J. Hertzberg. *Social Stories for Promoting Social Communication with Children with Autism Spectrum Disorder Using a Humanoid Robot: Step-by-Step Study*. <https://link.springer.com/content/pdf/10.1007/s10758-023-09681-7.pdf>. 1.450 KB, žiūrėta 2024-12-08. 2023.
- [SR17] S. A. Sankardas, J. Rajanahally. *iPad: efficacy of electronic devices to help children with autism spectrum disorder to communicate in the classroom*. <https://doi.org/10.1111/1467-9604.12160>. 875 KB, žiūrėta 2024-12-08. 2017.
- [Sri19] N. Srinivas. „Face recognition algorithm bias: Performance differences on images of children and adults“. Iš: *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops*. 2019.
- [SSH⁺21] A. K. Sauer, J. Stanton, S. Hans, A. Grabrucker. „Autism spectrum disorders: etiology and pathology“. Iš: *Exon Publications* (2021), puslapiai 1–15.
- [ST20] S. R. Shahamiri, F. Thabtah. „Autism AI: a new autism screening system based on artificial intelligence“. Iš: *Cognitive Computation* 12.4 (2020), puslapiai 766–777.
- [Tal23] F. M. Talaat. „Real-time facial emotion recognition system among children with autism based on deep learning and IoT“. Iš: *Neural Computing and Applications* 35.17 (2023), puslapiai 12717–12728.

- [TAM⁺24] F. M. Talaat, Z. H. Ali, R. R. Mostafa, N. El-Rashidy. „Real-time facial emotion recognition model based on kernel autoencoder and convolutional neural network for autism children“. Iš: *Soft Computing* 28.9 (2024), puslapiai 6695–6708.
- [VBG⁺22] E. Vallefucio, C. Bravaccio, G. Gison, L. Pecchia, A. Pepino. „Personalized training via serious game to improve daily living skills in pediatric patients with autism spectrum disorder“. Iš: *IEEE Journal of Biomedical and Health Informatics* 26.7 (2022), puslapiai 3312–3322.
- [Ver24] F. Verstraete. *Mastering Proximal Policy Optimization (PPO) in Reinforcement Learning with Code*. 2024. URL: <https://medium.com/@felix.verstraete/mastering-proximal-policy-optimization-ppo-in-reinforcement-learning-230bbdb7e5e7> (žiūrėta 2025-05-28).
- [VSC⁺22] I. Vogindroukas, M. Stankova, E.-N. Chelas, A. Proedrou. „Language and speech characteristics in autism“. Iš: *Neuropsychiatric disease and treatment* (2022), puslapiai 2367–2377.
- [Wor23] World Health Organization. *Autism*. 2023. URL: <https://www.who.int/news-room/fact-sheets/detail/autism-spectrum-disorders> (žiūrėta 2024-12-08).
- [XL25] B. Xia, S. Liu. „Research on the interface design of an interactive system for concentration training of autistic children based on reinforcement learning“. Iš: *J. COMBIN. MATH. COMBIN. COMPUT* 127 (2025), puslapiai 4275–4293.
- [ZMS14] H. M. Zakari, M. Ma, D. Simmons. „A review of serious games for children with autism spectrum disorders (ASD)“. Iš: *Serious Games Development and Applications: 5th International Conference, SGDA 2014, Berlin, Germany, October 9–10, 2014. Proceedings* 5. Springer. 2014, puslapiai 93–106.
- [ZMW⁺20] L. Zahara, P. Musa, E. P. Wibowo, I. Karim, S. B. Musa. „The facial emotion recognition (FER-2013) dataset for prediction system of micro-expressions face using the convolutional neural network (CNN) algorithm based Raspberry Pi“. Iš: *2020 Fifth international conference on informatics and computing (ICIC)*. IEEE. 2020, puslapiai 1–9.

Terminų ir santrumpų žodynas

Terminai:

Komunikacija - alternatyvioji ir augmentinė komunikacija

Santrumpos:

- ASS - autizmo spektro sutrikimas
- AVAZ - papildytos ir alternatyvios komunikacijos programinė įranga AVAZ
- BPMN - verslo procesų modeliavimas ir notacija (angl. business process model and notation)
- CNN - konvoliucinis neuroninis tinklas (angl. convolutional neural network)
- DCNN - gilusis konvoliucinis neuroninis tinklas (angl. deep convolutional neural network)
- DI - dirbtinis intelektas
- DNT - dirbtinis neuroninis tinklas (angl. artificial neural network)
- MM - mašininis mokymasis (angl. machine learning)
- SK - skatinamasis mokymasis (angl. reinforcement learning)
- SRS - socialinio reagavimo skalė (angl. social responsiveness scale)
- PECS - paveikslėlių apsikeitimo komunikacijos sistema (angl. picture exchange communication system)
- PPO - proksimalinis strategijos optimizavimas (angl. PPO)

Priedas 1. Darbo temos pristatymo pažymėjimas „Lietuvos magistrantų informatikos ir IT tyrimai“ VII-ojoje konferencijoje

Pažymėjimas

Andrius Lukas Maslovas

Vilniaus universitetas Matematikos ir informatikos fakultetas

dalyvavo VII-oje konferencijoje

Lietuvos magistrantų informatikos ir IT tyrimai

vykusioje 2026 m. gegužės 6 dieną

ir skaitė pranešimą

Sustiprinto mokymosi modelio jautrumo parametrų ir
stabilumo tyrimas: PECS kortelių atvejis

Programinis komitetas:

Prof. Gintautas Dzemyda

Prof. Olga Kurasova

Prof. Julius Žilinskas

Vilnius, 2026-05-06

