

VILNIAUS UNIVERSITETAS

DARIUS DRUNGILAS

**AFEKTO ATPAŽINIMO IR ADAPTYVAUS PASLAUGŲ
VALDYMO METODŲ INTEGRAVIMAS UŽDAROS APLINKOS
MIKROKLIMATO VALDYMO SISTEMOJE**

Daktaro disertacija

Technologijos mokslai

Informatikos inžinerija (07T)

Vilnius, 2014

Disertacija rengta 2009-2013 metais Vilniaus universiteto Matematikos ir informatikos institute.

Mokslinis vadovas

Prof. dr. Dalė Dzemydienė (Vilniaus universitetas, technologijos mokslai, informatikos inžinerija – 07T)

Padėka

Nuoširdžiai dėkoju mokslinei vadovei prof. dr. Dalei Dzemydienei už vertingas mokslines konsultacijas, nuoseklų vadovavimą, pagalbą ir kantrybę rengiant šią disertaciją.

Dėkoju prof. habil. dr. Antanui Andriui Bielskiui už idėjas, patarimus, pasiūlymus ir bendradarbiavimą kuriant bei skelbiant šiame darbe pateiktus rezultatus.

Ačiū disertacijos recenzentams prof. habil. dr. Adolfui Laimučiiui Telksniui ir prof. habil. dr. Kaziui Kazlauskui už vertingus patarimus bei kritines pastabas.

Dėkoju Matematikos ir informatikos instituto Programų sistemų inžinerijos skyriaus darbuotojams bei kolegoms už naudingus patarimus ir draugišką pagalbą.

Dėkoju Klaipėdos universiteto Informatikos ir Informatikos inžinerijos katedrų kolektyvui už palaikymą ir visokeriopą pagalbą rengiant šį darbą.

Nuoširdžiai dėkoju savo artimiesiems ir draugams už jų paramą, moralinį palaikymą, kantrybę bei supratingumą.

Taip pat dėkoju visiems, kurie tiesiogiai ar netiesiogiai prisidėjo prie šio darbo.

Darius Drungilas

Reziumė

Kuriant paslaugų adaptavimo prie besikeičiančios aplinkos ar vartotojų poreikių sistemas, atsiranda dirbtinio intelekto bei žmogaus ir kompiuterio sąveikos metodų integracijos problema. Jai spęsti vis dar trūksta metodų, kurie tiksliau leistų įvertinti žmogaus būsenas bei tiesiogiai jas susieti su paslaugų kokybės gerinimo proceso automatizavimu, leidžiančiu betarpiškai adaptuoti teikiamas paslaugas dinaminio pobūdžio dalykinėse srityse. Todėl šio disertacinio darbo tikslas – modifikuoti esamus ir pasiūlyti naujus afekto atpažinimo ir adaptyvaus valdymo metodus, leidžiančius išvystyti uždaros aplinkos mikroklimato valdymo sistemą, realizuojant dinaminę paslaugų teikimą pagal žmogaus afektinių būsenų įverčius.

Darbe pasiūlytas fiziologinių žmogaus parametrų klasterizavimo ir klasifikavimo metodų apjungimas, leidžiantis padidinti afektinės būsenos atpažinimo tikslumą. Pateiktas aplinkos mikroklimato parametrų valdymo sistemos modelis, kaip vienas naujausių afekto atpažinimo metodų pritaikymas, kuriant adaptyvias, prie žmogaus poreikių prisitaikančias paslaugas. Skirtingai negu kituose moksliniuose tyrimuose, pasiūlytas modelis leidžia afekto atpažinimą naudoti kaip automatinio valdymo sistemos grįžtamąjį ryšį, adaptavimo principą realizuojant skatinamojo mokymosi metodais. Eksperimentiniai rezultatai parodė, jog naudojant aktorius-kritikus skatinamojo mokymosi modelį bei afekto įvertinimo funkciją, galima pasiekti aplinkos mikroklimato valdymo sistemos stabilią būseną.

Abstract

When developing modern artificial intelligence based systems, it is important for them to be useful and able to adapt to the dynamic environment. Particular attention is paid to the development of smart services, improvement of their quality, monitoring behaviour of their users and integration of adaptive components. Therefore, the aim of this dissertation work is to modify the existing methods and propose new ones of affect recognition and adaptive control in order to develop a control system of the closed environment microclimate, implementing dynamic provision of services, based on the estimated affect state of humans.

The dissertation work proposes the method designed to remove labelling error of the training sample that allows increasing the accuracy of classification, while solving a wide range of challenges when the algorithms of supervised learning are used. The integrated adaptive control method has been proposed for microclimate control system of closed environment. It is an improved method of microclimate control system, when a person participates in a system as a sensor of ambient comfort and the evaluation of affect enables the estimation of suitability of environmental parameters for that person. The results of experimental simulation has shown that using a reinforcement learning and the function of affect evaluation, it is possible to achieve the optimal light, temperature, and air quality parameters in accordance with the estimates of the affect of a human.

Sąvokų, santrumpų ir žymėjimų sąrašas

Sąvokos

Adaptyvumas (angl. *adaptiveness*) – požymis, nusakantis gebėjimą prisitaikyti (adaptuotis). Valdymo sistemose adaptyvumas išreiškia sistemos savybę prisitaikyti prie kintančių sąlygų, stengiantis minimizuoti siektinos ir esamos būsenos skirtumą (Martin ir kt., 2008).

Adaptyvus (angl. *adaptive*) – savybė, nusakanti biologinės būtybės arba kompiuterinės sistemos gebėjimą prisitaikyti.

Afektas (angl. *affect*) – stipri ir pakankamai trumpa emocinė reakcija, dažniausiai kylanti, kai staiga pakinta subjektui svarbios gyvenimo aplinkybės.

Afektinė kompiuterija (angl. *affective computing*) – dirbtinio intelekto šaka, nagrinėjanti žmogaus emocinių būsenų kompiuterinį atpažinimą, interpretavimą bei imitavimą.

Agentas (angl. *agent*) – autonominė esybė, atliekanti tam tikrą rolę. Dirbtinio intelekto sistemose agentas yra programinis komponentas, kuris gali jausti aplinką jutiklių pagalba ir veikti toje aplinkoje vykdyklių pagalba (Russell ir Norvig, 2009).

Aktorius (angl. *actor*) – esybė, kuri atlieka veiksmus. Mašininio mokymo srityje aktorius veiksmai gali būti grindžiami skatinamojo mokymosi strategijos struktūra, kuri per būsenų vertinimą atlieka (atvaizduoja) rolei priskiriamus veiksmus (Sutton ir Barto, 2012).

Aplinkos komfortas (angl. *ambient comfort*) – charakteristika, nusakanti tam tikrus aplinkos parametrus, į kuriuos reaguodamas žmogus (ar dirbtinis agentas) gali išreikšti pasitenkinimą jį supančia aplinka. Automatinio patalpų mikroklimato valdymo sistemose aplinkos komfortas reglamentuojamas ISO

standartais, pritaikytas aplinkos apšvietimo, oro temperatūros bei CO₂ kiekio ore parametrų valdymui (ASHRAE, 1999; ASHRAE, 2005; CIBSE, 1994).

Kritikas (angl. *critic*) – tai tam tikro subjekto veiklą stebintis ir kritikuojantis veikėjas. Mašininio mokymo srityje kritikas kaip dirbtinis agentas gali būti išreiškiamas skatinamojo mokymosi struktūra, kuri būseną atvaizduoja į aktorius veiksmų veiksmingumo skaitinę vertę (Sutton ir Barto, 2012).

Mikroklimatas – dirbtinai sudarytas klimatas uždaroje patalpoje, siekiant apsaugoti nuo nepalankių išorės poveikių.

Mokymasis iš patirties – tai mokymosi būdas, kai naudojami patirties ir praktikoje įgytų žinių taikymo metodai. Dirbtinio intelekto ir mašininio mokymo sistemose mokymasis iš patirties išreiškia agento gebėjimą atlikti užduotį, kai veiksmingumo matas, atliekant užduotį, didėja kartu su patirtimi (Russell ir Norvig, 2009).

Paskata (angl. *reward*) – stimulus, naudojamas tam tikrų veiksmų sustiprinimui ar susilpninimui. Mašininio mokymo sistemose paskatą galima apibrėžti kaip agento atliekamų veiksmų veiksmingumo įvertį, kurią agentas gauna sąveikaudamas su aplinka (Sutton ir Barto, 2012).

Patirtis (angl. *experience*) – tai žmogaus arba dirbtinio agento sukauptos žinios ir gebėjimai jas taikyti. Dirbtinio intelekto srityje patirtis išreiškia žinias apie aplinką, kurias agentas įgyja veikdamas toje aplinkoje (Russell ir Norvig, 2009).

Skatinamasis mokymas (angl. *reinforcement learning*) – mokymosi būdas, kuris mašininio mokymosi sistemose išreiškiamas kaip metodas, leidžiantis agentui mokytis nežinomoje aplinkoje iš patirties, kurią agentas gauna jutiklių pagalba, tyrinėdamas nežinomą aplinką, siekiant gauti didžiausią suminę paskatą (Sutton ir Barto, 2012).

Strategija (angl. *policy*) – tai ilgalaikio veikimo veiksmų planas. Skatinamojo mokymo srityje strategija išreiškia agento sprendimų priėmimo funkciją tikslui pasiekti, atvaizduojanti būsenų aibę į veiksmų aibę (Sutton ir Barto, 2012).

Susijaudinimas (angl. *arrousal*) – emocinė savybė, kurios dydis nusako žmogaus psichologinės reakcijos į aplinkos stimulą sužadavimo laipsnį (Dolcos ir kt., 2004).

Valentingumas (angl. *valence*) – žmogaus emocinį pasitenkinimą nusakanti savybė, kurios dydis nusako teigiamą arba neigiamą žmogaus psichologinę reakciją į aplinkos stimulą (Dolcos ir kt., 2004).

Veiksmingumo matas (angl. *performance measure*) – dydis, nusakantis atliekamų veiksmų efektyvumą. Dirbtinio intelekto sistemose ši charakteristika leidžia įvertinti agento atliekamų veiksmų naudą ar priartėjimą prie tikslo (Russell ir Norvig, 2009).

Vertės funkcija (angl. *value function*) – skatinamojo mokymosi sistemose išreiškia suminę paskatos vertę, kurią agentas gali surinkti atlikdamas prognozuojamus veiksmus (Sutton ir Barto, 2012).

Santrumpos

ACAR – Aplinkos komforto afekto paskata (angl. *Ambient Comfort Affect Reward*);

DI – Dirbtinis intelektas;

ECG – Elektrokardiograma;

FIS – Neraiškioji išvedimo sistema (angl. *Fuzzy Inference System*);

GSR – Odos galvaninė reakcija (angl. *Galvanic Skin Response*);

HCI – Žmogaus ir kompiuterio sąveika (angl. *Human Computer Interaction*);

HF – Aukštas dažnis (angl. *High Frequency*);

HRV – Širdies ritmo variabilumas (angl. *Heart Rate Variability*);

kNN – k-artimiausių kaimynų metodas (angl. *k-Nearest Neighbours*);

LF – Žemas dažnis (angl. *Low Frequency*);

MDP – Markovo sprendimų procesas (angl. *Markov Decision Process*);

MLP – Daugiasluoksnis perceptronas (angl. *Multilayer Perceptron*);

PMV – Nuspėjamas vidutinis balsas (angl. *predicted mean vote*);

PPD – Nepatenkintų žmonių procentinė išraiška (angl. *Percentage of People Dissatisfied*);

RBF – Radialinė bazinė funkcija (angl. *Radial Basis Function*);

SOM – Susitvarkantys žemėlapiai (angl. *Self Organizing Maps*), neuroninių tinklų tipas;

SVM – Atraminių vektorių klasifikatorius (angl. *Support Vector Machines*);

TD – Laikinieji skirtumai (angl. *Temporal Difference*).

Žymėjimai

A – Galimų veiksmų aibė;

c^t – Eksperto nusakyta klasė;

e_t – Tinkamumo kelias skatinamajame mokyme;

$h(x)$ – Hipotezė, kad x bus priskirtas į atitinkamą klasę;

L – Aplinkos apšvietimo dydis išreikštas procentais;

L' – Žmogaus terminis krūvis;

M – Metabolizmo laipsnis žmogaus kūne;

N – Imties dydis;

O – Uždaros aplinkos oro kokybės matas atvirkščiai proporcingas CO₂ kiekiui ore;

p – Būsenų perėjimų tikimybė;

R – Paskatos funkcija;

S – Būsenų aibė;

T – Aplinkos temperatūros kiekybinis įvertis °C;

U – Universumas

v – Radialinių bazinių funkcijų neuroninio tinklo akatoriaus dalies svoriai;

V – Vertės funkcija skatinamajame mokyme;

w – Radialinių bazinių funkcijų neuroninio tinklo kritiko dalies svoriai;

α – Mokymosi greitis skatinamajame mokyme;

γ – Diskonto faktorius skatinamajame mokyme (angl. *discount factor*);

δ – Laikinių skirtumų paklaida skatinamajame mokyme;

- ΔL – Aplinkos apšvietimo pokytis išreikštas procentais per laiko vienetą;
- ΔO – Aplinkos oro kokybės pokytis išreikštas procentais per laiko vienetą;
- ΔT – Aplinkos temperatūros pokyčio kiekybinis įvertis išreikštas °C per laiko vienetą;
- θ – Adaptyvios funkcijos parametrų aibė;
- λ – Nykimo faktorius skatinamajame mokyme (angl. *decay factor*);
- μ – Lingvistinio kintamojo priklausomybės funkcija;
- π – Skatinamojo mokymo strategija;
- σ – Radialinių bazinių funkcijų pločiai;
- ϕ – Radialinių bazinių funkcijų išvesties reikšmė.

Paveikslėlių sąrašas

1 pav. Emocinių būsenų pozicijos susijaudinimo – valentingumo erdvėje (pagal Russell, 1980).	30
2 pav. GSR jutiklio principinė schema	32
3 pav. Afekto atpažinimo tikslumas, naudojant skirtingus atpažinimo parametrų apdorojimo metodus	41
4 pav. Klasikinė apsimokančios valdymo sistemos schema.....	48
5 pav. Klasikinis skatinamojo mokymosi modelis (Sutton ir Barto, 2012).....	49
6 pav. Skatinamojo mokymo aktorius - kritiko architektūra (pagal Sutton ir Barto, 2012)	55
7 pav. Aktoriaus ir kritiko įgyvendinimas, naudojant RBF neuroninį tinklą ...	57
8 pav. Afekto atpažinimo metodais grindžiamų sistemų pagrindiniai konstrukciniai komponentai.....	62
9 pav. Daugiamodalinio auditorijos emocinės būsenos atpažinimo sistemos pavyzdys (pagal Vildjiounaite ir kt., 2009)	63
10 pav. Agentinėmis sistemomis grindžiamos daugiamodalinės afekto atpažinimo sistemos pavyzdys (pagal Gonzalez-Sanchez ir kt., 2011).....	64
11 pav. Išskirstyta afekto vertinimo ir sprendimų priėmimo agentinė sistema (Dzemydienė ir kt., 2010).....	65
12 pav. Aplinkos mikroklimato valdymo sistema naudojanti afekto vertinimą kaip grįžtamąjį ryšį	68
13 pav. PMV ir PPD dydžių tarpusavio priklausomybė (Fanger, 1982).....	70
14 pav. ACAR koeficiento neraiškioji išvedimo sistema.....	72
15 pav. Neraiškiosios logikos ACAR priklausomumo funkcijos.....	73
16 pav. Skatinamuoju mokymu grindžiamas uždaros aplinkos mikroklimato valdymo sistemos modelis.....	74

17 pav. Išvystyta aplinkos mikroklimato adaptyvaus valdymo, pagal žmogaus afekto vertinimą, sistemos architektūra	76
18 pav. Tipinė GSR kreivė, su ją charakterizuojančiais fiziologiniais parametrais.....	80
19 pav. GSR signalo filtravimas naudojant branduolinį glodinimą. a) nefiltruoti duomenys, b) filtruoti duomenys	83
20 pav. ECG signalo filtravimas naudojant branduolinį glodinimą. a) nefiltruoti duomenys, b) filtruoti duomenys	83
21 pav. Širdies ritmo variabilumo spektrinė analizė, naudojant AR metodą ...	84
22 pav. a) emocinių būsenų erdvė pagal (Russell, 1980), b) emocinių būsenų fiksavimo įrankis.....	85
23 pav. GSR duomenys su pažymėtais stimulais. a) nefiltruoti duomenys, b) filtruoti duomenys.....	85
24 pav. Fiziologinių parametrų klasterizavimas naudojant SOM	86
25 pav. SOM mokymo proceso įvertinimas	87
26 pav. Fiziologinių parametrų klasterizavimas, naudojant SOM pagal kiekvieną požymį: a) uždelstumą (Lat.), b) pakilimo laiką (RT), c) amplitudę (A), d) hrt	88
27 pav. Daugiasluoksnio perceptrono topologija afekto atpažinimui	89
28 pav. Daugiasluoksnio perceptrono mokymosi progresas atskirais atvejais.	90
29 pav. Neraiškioji susijaudinimo ir valentingumo išvedimo sistema	91
30 pav. Afekto neraiškiosios išvedimo sistemos įvesties lingvistinių kintamųjų funkcijos: a) temperatūros, b) apšvietimo, c) oro kokybės.....	91
31 pav. Susijaudinimo ir valentingumo neraiškiosios išvedimo sistemos išvesties lingvistinių kintamųjų funkcijos: a) susijaudinimo (Arousal), b) valentingumo (Valence).....	91
32 pav. Afekto neraiškiosios išvedimo sistemos taisyklių bazė	92
33 pav. Afekto atvaizdavimo funkcijos: a) susijaudinimo priklausomybė nuo apšvietimo ir temperatūros, b) susijaudinimo priklausomybė nuo oro kokybės ir temperatūros, c) susijaudinimo priklausomybė nuo oro kokybės ir	

apšvietimo, d) valentingumo priklausomybė nuo oro kokybės ir apšvietimo, e) valentingumo priklausomybė nuo oro kokybės ir temperatūros, f) valentingumo priklausomybė nuo apšvietimo ir temperatūros.....	93
34 pav. Afekto išvedimo sistemos taisyklių aktyvacija, kai vertinamas žemas aplinkos komforto laipsnis.....	94
35 pav. Afekto išvedimo sistemos taisyklių aktyvacija, kai vertinamas aukštas aplinkos komforto laipsnis.....	94
36 pav. Neraiškioji ACAR indekso išvedimo sistema	95
37 pav. ACAR indekso neraiškiosios išvedimo sistemos taisyklių bazė	96
38 pav. ACAR indekso atvaizdavimo funkcija nuo susijaudinimo ir valentingumo	96
39 pav. ACAR indekso išvedimo sistemos taisyklių aktyvacija, kai vertinamas neigiamas valentingumas ir neigiamas susijaudinimas	97
40 pav. ACAR indekso išvedimo sistemos taisyklių aktyvacija, kai vertinamas nulinis susijaudinimas (angl. arousal) ir aukštas teigiamas valentingumas (angl. valence).....	97
41 pav. Aplinkos mikroklimato reguliavimo algoritmo pseudokodas	99
42 pav. Laikinių skirtumų (TDerror) dinamika naudojant atitinkamus reguliatoriaus parametrus: a) $\gamma=0.8$, $\lambda=0.5$, $\alpha=0.2$; b) $\gamma=0.8$, $\lambda=0.5$, $\alpha=0.01$; c) $\gamma=0.9$, $\lambda=0.9$, $\alpha=0.02$	100
43 pav. Uždaros aplinkos charakteristikų dinamika naudojant atitinkamus reguliatoriaus parametrus: a) $\gamma=0.95$, $\lambda=0.9$, $\alpha=0.5$; b) $\gamma=0.8$, $\lambda=0.5$, $\alpha=0.2$..	101

Lentelių sąrašas

1 lentelė. <i>k</i> artimiausių kaimynų klasifikavimo metodo savybės	37
2 lentelė. Sprendimų medžių kaip klasifikavimo metodo taikymo savybės.....	38
3 lentelė. Susitvarkančių žemėlapių taikymo savybės.....	39
4 lentelė. Afekto atpažinimo metodų galimybių palyginimas	42
5 lentelė. Šiluminio komforto vertinimo skalė (pagal ASHRAE, 2005).....	69

Turinys

Padėka	3
Reziუმė	4
Abstract	5
Sąvokų, santrumpų ir žymėjimų sąrašas.....	6
Paveikslėlių sąrašas.....	11
Lentelių sąrašas.....	14
ĮVADAS	18
Temos aktualumas.....	18
Problemos formulavimas	20
Tyrimo objektas	21
Darbo tikslas.....	21
Darbo uždaviniai	21
Ginamieji disertacijos teiginiai	22
Tyrimo metodika.....	22
Gauti rezultatai	23
Mokslinis darbo naujumas	24
Praktinė darbo reikšmė.....	25
Darbo rezultatų aprobavimas	26
Disertacijos struktūra	27
1. AFEKTO ATPAŽINIMO METODAI IR JŲ TAIKYMO GALIMYBĖS KOMPIUTERINĖSE SISTEMOSE	29
1.1. Afekto samprata	29
1.2. Afekto atpažinimo kriterijai	31
1.3. Afekto atpažinimo metodai ir jų galimybės.....	33
1.3.1. Atraminių vektorių klasifikatorius (mašina)	35
1.3.2. Fišerio tiesinio diskriminanto analizė.....	35
1.3.3. <i>k</i> artimiausių kaimynų metodas	36
1.3.4. Sprendimų medžių taikymas	37
1.3.5. Daugiasluoksnio perceptrono taikymo galimybės	38

1.3.6. Susitvarkančių žemėlapių (SOM) taikymas fiziologinių būsenų klasterizavimui	39
1.4. Afekto atpažinimo požymių analizės metodai.....	39
1.4.1. Požymių derinių eksperimentinio tyrimo metodai	40
1.4.2. Principinių komponentų analizė	40
1.4.3. SOM korekcijos taikomi principai	40
1.5. Afekto vertinimo kompiuterinių metodų apibendrinimas	41
1.6. Pirmojo skyriaus išvados	44
2. METODAI, TAIKOMI ADAPTYVAUS VALDYMO SISTEMOMS KURTI	45
2.1. Adaptyvaus valdymo sistemos samprata	45
2.2. Apsimokančios valdymo sistemos.....	47
2.3. Mašininio mokymosi metodų taikymas valdymo sistemose	48
2.4.1. Skatinamojo mokymosi modelis	49
2.4.2. Markovo sprendimų procesas.....	51
2.4.3. Optimalumo įvertinimo modelis	52
2.4.4. Dinaminio programavimo principų taikymas	52
2.4.5. Laikinių skirtumų mokymasis	53
2.4.6. Aktoriaus – kritiko metodas	54
2.4.7. Vertės funkcijos aproksimavimas	55
2.4. Antrojo skyriaus išvados.....	58
3. AFEKTO ATPAŽINIMAS UŽDAROS APLINKOS MIKROKLIMATO VALDYMO SISTEMOJE.....	59
3.1. Afekto atpažinimu grindžiamų sistemų apžvalga.....	59
3.2. Uždaros aplinkos mikroklimato valdymo sprendimų pavyzdžiai	65
3.3. Afekto atpažinimo ir adaptyvaus valdymo metodų integravimas	67
3.4. Adaptyvios mikroklimato valdymo sistemos grįžtamojo ryšio realizavimas.....	70
3.5. Skatinamojo mokymosi taikymas uždaros aplinkos mikroklimato reguliavimui	73

3.6. Trečiojo skyriaus išvados.....	77
4. UŽDAROS APLINKOS MIKROKLIMATO VALDYMO SISTEMOS EKPERIMENTINIAI TYRIMAI	78
4.1. Eksperimentinio tyrimo metodika	78
4.2. Afekto vertinimo duomenų aprašymas	79
4.3. Afekto vertinimo tyrimas.....	81
4.3.1. GSR tyrimas	84
4.3.2. „Mokytojo triukšmo“ šalinimas panaudojant SOM	86
4.3.3. Fiziologinių parametų klasifikavimas	88
4.4. Paskatos funkcija išreikšto afekto vertinimo tyrimas	90
4.4.1. ACAR funkcijos tyrimas	95
4.5. Adaptyvios uždaros aplinkos mikroklimato valdymo sistemos tyrimas	97
4.6. Ketvirtojo skyriaus išvados.....	101
Bendrosios išvados	103
Literatūros sąrašas.....	105
Autoriaus publikacijų disertacijos tema sąrašas	113

Temos aktualumas

Kuriant šiuolaikines dirbtinio intelekto (DI) sistemas svarbu, kad jos būtų naudingos ir gebėtų prisitaikyti dinaminėje aplinkoje. Ypač didelis dėmesys skiriamas išmaniųjų paslaugų kūrimui, jų kokybės didinimui, stebint vartotojų įpročius ir įvedant adaptyvumo komponentus. Svarbu, kad šios sistemos įgalintų daugelį paslaugų valdyti automatiškai ir adaptuotis prie konkrečių vartotojo poreikių. Viena iš tokių sistemų kūrimo sričių – paslaugų personalizavimas. Šiose sistemose taip pat aktualu mažinti resursų sąnaudas, paslaugas atlikti tiesioginės kreipties režimu, reikiamu laiku, siekiant didesnės teikiamų paslaugų kokybės ir rizikos sumažinimo. DI sistemose, siekiant kuo adekvačiau įvertinti realybę ir gebėti valdyti paslaugas teikiančius procesus, siūlomos įvairios disciplinas (biomediciną, psichologiją, kompiuterių inžineriją ir kt.) siejančios kompiuterinės technologijos.

Technologijos, skirtos atpažinti, interpretuoti, imituoti žmogaus emocines būsenas, 1995 metais buvo apjungtos į vieną iš dirbtinio intelekto šakų – afektinę kompiuteriją. Cituojant afektinės kompiuterijos pradininkę R. W. Picard, kuri teigia, „... kad kompiuteriai būtų tikrai protingi ir natūraliai su mumis bendrautų, mes turime suteikti kompiuteriams gebėjimą atpažinti, suprasti ir netgi išreikšti emocijas“ (Picard, 1995), suvokiama, jog emocijų atpažinimas tampa svarbia dirbtinio intelekto sistemų kūrimo dalimi. Taikomosios sritys, kuriose aktualūs afekto atpažinimo metodai, apima išmaniojo būsto valdymo sistemas, daiktų interneto technologijomis grindžiamas nuotolinio valdymo paslaugų sistemas.

Nagrinėjamos adaptyvių sistemų kūrimo galimybės, kurios pagal tam tikras užduotas statines parametrų reikšmes geba keisti supančios aplinkos parametrus (Marreiros ir kt., 2007a; Marreiros ir kt., 2007b; Masatoshi ir kt.,

2010). Šių sistemų valdymas grindžiamas metodais, siekiant mažinti energijos sąnaudas ir kuriant žmogaus veiklai tinkamą aplinką.

Intelektualios aplinkos kūrimo srityje vykdoma nemažai projektų, siekiant pasiūlyti architektūrinius elektroninių prietaisų apjungimo į bendrą visumą sprendimus (IoT-A, 2013). Tarpinės programinės įrangos kūrimas įvairialypių fizinių įrenginių apjungimui, siekiant sukurti patogias įrenginių valdymo paslaugas (HYDRA, 2010). Įterptinių sistemų apjungimas ir intelektualizuotų paslaugų teikimas projekte taikomas užtikrinant efektyvesnę paslaugų vartotojiškumą (Smarcos, 2012).

Vykdam mokslinius tyrimus afekto atpažinimo srityje buvo pasiūlyta keletas sprendimų sukurti adaptyvias paslaugas teikiančias sistemas (Bielskis ir kt., 2009; Drungilas ir kt., 2010; Dzemydienė ir kt., 2010). Šios sistemos leidžia parinkti socialinės e. rūpybos paslaugas kaip asmenį asistuojančių įrenginių valdymo scenarijus, vertinant žmogaus emocines būsenas. Tolimesnis, intelektualias paslaugas teikiančių adaptyvių sistemų vystymas reikalauja tiesioginio žmogaus supančios aplinkos valdymo ir afekto atpažinimo metodų integravimo. Vienas plačiausiai nagrinėjamų šios probleminės srities atvejų – tai uždaros aplinkos komforto valdymo sistemos, gebančios keisti tam tikrus aplinkos parametrus, į kuriuos reaguodamas žmogus (ar dirbtinis agentas) gali išreikšti pasitenkinimą jį supančia aplinka.

Automatinio patalpų mikroklimato valdymo sistemose aplinkos komfortas dažniausiai reglamentuojamas ISO standartais, pritaikytais aplinkos apšvietimo, oro temperatūros bei CO₂ kiekio ore parametrų valdymui (ASHRAE, 1999; ASHRAE, 2005; CIBSE, 1994). Nuo aplinkos komforto lygio priklauso darbo vietos ergonominiai rodikliai, kurie veikia žmogaus sveikatą, darbo produktyvumą, emocijas, motyvaciją ir kt. (Masatoshi ir kt., 2010). Komforto parametrų reguliavimo uždaviniai ypač aktualūs ir plačiai nagrinėjami kuriant išmaniojo būsto sistemas. Tačiau komforto reguliavimo sistemos nėra pakankamai automatizuotos, jos dažnai nėra patogios vartotojui (Eiben ir kt., 2010), todėl atsiranda poreikis modifikuoti esamus ir pasiūlyti

naujus afekto atpažinimo bei adaptyvaus valdymo metodus, leidžiančius išvystyti uždaros aplinkos mikroklimato valdymo sistemą, realizuojant dinaminį paslaugų teikimą pagal žmogaus afektinių būsenų įverčius.

Problemos formulavimas

Daiktų interneto, išmaniųjų technologijų, kontekstą suvokiančių sistemų vystymasis yra grindžiamas naujausiais pasiekimais mašininio mokymo bei adaptyvių sprendimo priėmimo metodų taikymų srityje. Ypač didelis dėmesys skiriamas tokių intelektualių technologijų taikymams, kuriuose paslaugos teikiamos, siekiant minimizuoti kaštus, energijos sąnaudas, individualiai pasiūlyti vartotojui labiausiai tinkamas paslaugas ar komforto sąlygas. Kuriant paslaugų adaptavimo prie besikeičiančios aplinkos ir vartotojų poreikių sistemas, atsiranda dirbtinio intelekto bei žmogaus ir kompiuterio sąveikos metodų integracijos problema. Šiai problemai spęsti vis dar trūksta metodų, kurie tiksliau leistų įvertinti žmogaus fiziologines būsenas ir tiesiogiai jas susieti su paslaugų kokybės gerinimo proceso automatizavimu, leisiančiu betarpiškai adaptuoti teikiamas paslaugas dinaminio pobūdžio dalykinėse srityse. Paslaugų kokybės įvertinimas reikalauja išspęsti kriterijų parinkimo, sprendimo priėmimo sistemų taikymo uždavinius, integruojant robotizuotas, sensorines, žinių valdymo bei automatizuotų procesų valdymo sistemas.

Adaptyviose valdymo sistemose afekto atpažinimo metodai grindžiami gebėjimais vertinti žmogaus reakciją į aplinkos pokyčius, analizuojant fiziologinius parametrus (Cowie ir kt., 2001; Rani, 2003, Mandryk, 2005). Dalis tokio pobūdžio mokslinių tyrimų nagrinėja afekto atpažinimo metodų efektyvumą įvairaus sudėtingumo dalykinėse srityse (Lisetti ir kt. 2003; Villon ir Lisetti, 2006). Naudojant jau sukurtus afekto atpažinimo metodus, nagrinėjamas aplinkos veiksnių įtakos žmogui vertinimas, pasitelkiant biologinį grįžtamąjį ryšį (Rani, 2003, Mandryk, 2005, Kaklauskas ir kt., 2010; Kaklauskas ir kt., 2011). Ypač didelis dėmesys afekto atpažinimo metodų taikymui skiriamas kuriant išmanaus būsto sistemas, diegiant adaptyvaus

uždaru patalpų mikroklimato valdymo sistemas. Tačiau siūlomų sistemų automatinis reguliavimas dažniausiai vykdomas pagal iš anksto užduotus parametrus, neatsižvelgiant į toje aplinkoje esančio žmogaus afektinės būsenos pokyčius ir jų dinamiką. Šiuo metu egzistuojančių metodų nepakanka, norint realiu laiku adaptuoti paslaugas, kurios valdo žmogų supančią aplinką, naudojant jo afekto vertinimą, todėl adaptyvias paslaugas teikiančių sistemų kūrimo pagrindiniu uždaviniu tampa afekto atpažinimo ir adaptyvaus valdymo metodų integracija.

Tyrimo objektas

Afekto atpažinimo ir adaptyvaus paslaugų valdymo metodai, kurie leidžia išvystyti integruotą adaptyvių paslaugų valdymą uždaros aplinkos mikroklimato reguliavimo sistemoje.

Darbo tikslas

Disertacinio darbo tikslas – modifikuoti esamus ir pasiūlyti naujus afekto atpažinimo bei adaptyvaus paslaugų valdymo metodus, leidžiančius išvystyti uždaros aplinkos mikroklimato valdymo sistemą, realizuojant dinaminę paslaugų teikimą pagal žmogaus afektinių būsenų įverčius.

Darbo uždaviniai

Darbo tikslui pasiekti keliami šie uždaviniai:

1. Atlikti kompiuterinių afekto atpažinimo metodų palyginamąją analizę, kuri nustatytų jų taikymo galimybes, konstruojant adaptyvių paslaugų valdymo sistemas;
2. Išanalizuoti adaptyvaus valdymo ir afekto atpažinimo metodų integracijos galimybes tikslingam uždaros aplinkos mikroklimato valdymo sistemos išvystymui;

3. Sukurti afekto atpažinimo ir adaptyvaus valdymo metodus integruojančios sistemos modelį, realizuojantį adaptyvią uždaros aplinkos mikroklimato valdymo sistemą;
4. Eksperimentiškai įvertinti sukurtos uždaros aplinkos mikroklimato valdymo sistemos prototipą skirtingomis afekto įvertinimo sąlygomis.

Ginamieji disertacijos teiginiai

1. Adaptyvioms, prie vartotojų poreikių prisitaikančioms sistemoms kurti tikslinga taikyti kompiuterinius afekto atpažinimo metodus, vertinant jų galimybes, kuo tiksliau įvertinti žmogaus reakcijas į aplinkos pokyčius.
2. Tikslinga integruoti afekto atpažinimo ir adaptyvaus valdymo metodus, siekiant išvystyti adaptyvią, prie vartotojų poreikių prisitaikančių paslaugų valdymo sistemą.
3. Žmogaus afekto vertinimo metodų integracija su skatinamojo mokymosi metodais užtikrina efektyvų adaptyvių paslaugų uždaros aplinkos mikroklimato valdymo sistemoje išvystymą.
4. Sukurta aplinkos mikroklimato adaptyvaus valdymo sistema leidžia pasiekti optimalius apšvietimo, temperatūros ir oro kokybės parametrus pagal toje aplinkoje esančio žmogaus afekto vertinimą.

Tyrimo metodika

Informatikos inžinerijos moksle afekto atpažinimo metodų kūrimas ir jų taikymas yra pakankamai nauja sritis, tad norint įvertinti šiuo metu taikomų afekto atpažinimo metodų ir su jais susietų mokslinių pasiekimų svarbą, darbe buvo taikyti informacijos paieškos, sisteminimo, analizės, lyginamosios analizės ir apibendrinimo metodai. Analizuojant naujausią mokslinę literatūrą iš mokslinių duomenų bazių, konkretizuojamas tyrimo kontekstas, įvertinant darbe keliamos problemos išspręstumo lygį ir išskiriant esmines afekto atpažinimo metodų ir jų taikymo problemas. Siekiant integruoti afekto

atpažinimo ir automatinio uždaros aplinkos mikroklimato reguliavimo metodus, pasiūlant adaptyvaus valdymo sistemos išvystymą pagal vartotojų poreikius, darbe nagrinėjami afekto atpažinimo, skaitmeninio valdymo bei mašininio mokymo metodai.

Siekiant sukurti aplinkos mikroklimato adaptyvaus valdymo mechanizmą, taikomas tyrimo konstravimu metodas, apimantis teorinių afekto atpažinimo, mašininio mokymo, adaptyvaus valdymo metodų nagrinėjimą bei pritaikymą, pasiūlant naujus modelius, metodus bei eksperimentinės sistemos sukūrimą. Siekiant atlikti sukurtos sistemos prototipo validaciją ir verifikaciją bei eksperimentiškai įvertinti sistemos elgseną, buvo sukurtas ir panaudotas prototipinis fiziologinių signalų matavimo techninės įrangos maketas. Remiantis išmatuotais žmogaus odos galvaninės reakcijos, elektrokardiogramos, odos temperatūros duomenimis bei ekspertiniu vertinimu, naudojant skirtingus aplinkos būsenos scenarijus buvo sudarytas aplinkos mikroklimato adaptyvios valdymo sistemos imitacinis modelis. Eksperimento rezultatams palyginti taikytas statistinis tyrimų rezultatų vertinimas.

Gauti rezultatai

Pasiūlytas fiziologinių žmogaus parametrų klasterizavimo ir klasifikavimo metodų apjungimas leido padidinti afektinės būsenos atpažinimo tikslumą. Vertinant klasifikavimo tikslumą, išskirti dirbtinio intelekto metodai, kurie labiausiai tinka afekto atpažinimui. Patvirtinta, jog adaptyvioms, prie vartotojų poreikių prisitaikančioms sistemoms kurti tikslinga taikyti kompiuterinius afekto atpažinimo metodus, nustatant jų galimybes, kuo tiksliau įvertinti žmogaus reakcijas į aplinkos mikroklimato pokyčius.

Pasiūlytas kiekybinio afekto įvertinimo principas, leidžiantis sukurti uždaros automatinės aplinkos komforto valdymo sistemos grįžtamąjį ryšį ir jį pritaikyti, pasiūlant aplinkos mikroklimato parametrų valdymo sistemos modelį, grindžiamą žmogaus afekto įvertinimu. Parodyta, jog tikslinga

integruoti afekto atpažinimo ir adaptyvaus valdymo metodus, siekiant išvystyti adaptyvią, prie vartotojų poreikių prisitaikančių paslaugų valdymo sistemą.

Siekiant kiekybiškai įvertinti afektą, naudojant fiziologinių parametru reikšmes, buvo sukurtas ir išbandytas sistemos prototipo modelis, gebantis nuskaityti fiziologinius signalus, kaupiti diskretizuotų signalų skaitmeninius duomenis, iš jų išskirti fiziologinius parametrus bei juos interpretuoti. Parodyta, jog žmogaus afekto vertinimo metodų, susietų su fiziologinių parametru įverčiais ir grįžtamojo ryšio panaudojimu integracija su skatinamojo mokymosi metodais užtikrina adaptyvių paslaugų uždaros aplinkos mikroklimato valdymo sistemoje išvystymą.

Remiantis afekto vertinimo principais buvo sudaryta ekspertinė afekto įverčio funkcija, kuri leidžia realizuoti adaptyvios sistemos grįžtamojo ryšio grandinę.

Eksperimentiniai imitacinio modeliavimo rezultatai parodė, jog naudojant aktoriaus-kritiko skatinamojo mokymosi modelį bei afekto pokyčių įvertinimo funkciją, galima pasiekti optimalius apšvietimo, temperatūros ir oro kokybės parametrus pagal toje aplinkoje esančio žmogaus afekto vertinimą.

Mokslinis darbo naujumas

Rengiant disertaciją buvo gauti šie informatikos inžinerijos mokslui nauji rezultatai:

- Pasiūlytas integruotas adaptyvių paslaugų valdymo metodas uždaros aplinkos mikroklimato reguliavimo sistemoje. Tai patobulintas uždaros aplinkos mikroklimato valdymo metodas, kai žmogus dalyvauja sistemoje kaip aplinkos komforto jutiklis, kurio afekto įvertis leidžia nustatyti aplinkos mikroklimato tinkamumą tam žmogui. Tai vienas naujausių afekto atpažinimo metodų pritaikymas, kuriant adaptyvias, prie žmogaus poreikių prisitaikančias paslaugas;

- Taikant aktoriaus-kritiko skatinamojo mašininio mokymo metodą, kuris geba išgauti trūkstamas žinias apie sistemą jos veikimo metu, sukurta adaptyvi uždaros aplinkos mikroklimato reguliavimo sistema. Skirtingai negu šiuo metu siūlomos mikroklimato reguliavimo sistemos, pasiūlytas metodas, priklausomai nuo konteksto, leidžia adaptuoti vartotojui teikiamas paslaugas dinaminio pobūdžio dalykinėse srityse;
- Sukurtas afekto vertinimo sistemos prototipas ir eksperimentiškai įvertintas pasiūlytos aplinkos mikroklimato parametrų adaptavimo sistemos imitacinis modelis;
- Pasiūlytas fiziologinių žmogaus parametrų klasterizavimo, naudojant SOM, ir klasifikavimo, naudojant MLP, metodų apjungimas. Šis sprendimas leidžia panaikinti mokymo imties sužymėjimo klaidas ir taip padidinti klasifikavimo tikslumą, sprendžiant įvairaus pobūdžio klasifikavimo uždavinius, kai apsimokančiose sistemose yra taikomi prižiūrimo mokymosi algoritmai.

Praktinė darbo reikšmė

Pasiūlytas uždaros aplinkos mikroklimato valdymo sistemos modelis, realizuojantis dinaminį paslaugų teikimą pagal žmogaus afektinių būsenų įverčius. Šis modelis, apimantis žmogaus fiziologinių signalų nuskaitymą, parametrų analizę, afekto įvertinimą bei adaptyvaus valdymo principus, gali būti praktiškai pritaikomas ir kitose dalykinėse srityse, kuriose paslaugų kokybės valdymas būtų grindžiamas žmogaus afekto įvertinimo metodais. Uždaros aplinkos mikroklimato atpažinimo ir vertinimo kontekstinės žinios bei jų valdymo mechanizmai, panaudoti sukuriant jų taikymo metodiką, galėtų pasitarnauti intelektualių, išmaniųjų paslaugų teikimo sistemų kūrimui, taip didinant siūlomų paslaugų ar produktų konkurencingumą. Taikant šį modelį, sudaromos galimybės gerinti kontekstinių paslaugų kokybę, pritaikant jas prie

individualių vartotojo poreikių, kai paslaugų vertinimo kriterijus nustatomas pagal objektyvų vartotojo afekto įvertį.

Darbe taip pat pasiūlytas mokymo imties sužymėjimo klaidų naikinimo metodas, leidžiantis padidinti klasifikavimo tikslumą, sprendžiant įvairaus pobūdžio uždavinius, kai apsimokančiose sistemose yra taikomi prižiūravimo mokymosi algoritmai.

Darbe pasiūlyti afekto atpažinimo metodai bei adaptyvaus valdymo principai buvo panaudoti, kuriant neįgalius asmenis asistuojančios aplinkos paslaugų valdymo metodus, robotizuotas adaptyvaus valdymo sistemas (Bielskis ir kt., 2008; Bielskis ir kt., 2009; Bielskis ir kt., 2010; Dzemydienė ir kt., 2011) bei žmogui draugiškos ir energiją tausojančios išmaniosios aplinkos koncepciją (Drungilas ir kt., 2010; Bielskis ir kt., 2012; Bielskis ir kt., 2013).

Darbo rezultatų aprobavimas

Moksliniai rezultatai publikuoti 13 mokslinių darbų, iš kurių: 5 straipsniai ISI Web of Science duomenų bazėje referuojamuose ir turinčiuose citavimo indeksą leidiniuose, 1 straipsnis kituose ISI Web of Science duomenų bazėje referuojamuose leidiniuose, 2 straipsniai Lietuvos recenzuojamuose moksliniuose periodiniuose leidiniuose, 5 straipsniai tarptautinių mokslinių konferencijų pranešimų medžiagoje.

Dalyvaujant konferencijose tyrimų rezultatai buvo pristatyti ir aptarti 2 nacionalinėse ir 4 tarptautinėse konferencijose Lietuvoje bei užsienyje:

1. 7-oji mokslinė konferencija Technologijos mokslo darbai Vakarų Lietuvoje, 2010 m. gegužės 14 d., Klaipėda;
2. The 14th International Conference Electronics'2010, May 18-20, 2010, Kaunas;
3. The 10th International Conference on Artificial Intelligence and Soft Computing (ICAISC) 2010 June 13-17, 2010, Zakopane, Poland.

4. The 10th International Conference Reliability and Statistics in Transportation and Communication (RelStat'10), October 20-23, 2010, Riga, Latvia.
5. 15-oji Respublikinė konferencija Kompiuterininkų dienos (Klaipėda, 2011); rugsėjo 22-24, 2011.
6. The 16th International Conference Electronics'2010, June 18-20, 2012, Palanga.

Disertacijos struktūra

Disertaciją sudaro įvadas, 4 skyriai ir bendrosios išvados. Disertacijos apimtis – 118 puslapių, 43 paveikslai ir 5 lentelės.

Įvade aprašomas mokslinio tyrimo aktualumas, analizuojama jo reikšmė, pateikiamas šiuolaikinių mokslinių tyrimų kontekstas, pateikiama problemos formuluotė, nagrinėjamos problemos aktualumas, formuluojamas tikslas ir uždaviniai, apibrėžiamos tyrimo hipotezės, aprašoma tyrimo metodika. Pateikiami pagrindiniai mokslinio darbo rezultatai bei disertacijos gautų rezultatų praktinė vertė ir naujumas, disertacijos rezultatų publikavimo rodikliai ir aprobavimas.

1 skyriuje nagrinėjami kompiuteriniai afekto atpažinimo metodai ir apžvelgiamos jų taikymo galimybės, konstruojant adaptyvias sistemas. Pateikiama pasaulio mokslininkų dažniausiai naudojamų afekto atpažinimo metodų analitinė apžvalga. Šiame skyriuje parodyta, jog kompiuteriniai afekto atpažinimo metodai pakankamai tiksliai įvertina žmogaus reakciją į aplinkos pokyčius ir leidžia sukurti uždaros aplinkos mikroklimato adaptyvaus valdymo pagal žmogaus afekto vertinimą konstrukcijas.

2 skyriuje nagrinėjamos mašininio mokymosi metodų taikymo ir panaudojimo galimybės, kuriant adaptyvias valdymo sistemas. Aprašomi svarbiausi šių sistemų kūrimui taikomi metodai, kuriant adaptyvaus valdymo sistemos modelį, taikomą aplinkos mikroklimato valdymui. Atskleidžiami

klasikinių valdymo sistemų ir šiuolaikinių mašininio mokymu grindžiamų valdymo sistemų realizavimo principai.

3 skyriuje formuluojami ir aptariami pagrindiniai teoriniai problemos sprendimo metodai. Pateikiamas uždaros aplinkos mikroklimato adaptyvios valdymo sistemos modelis, kuris leidžia reguliuoti aplinkos mikroklimato parametrus pagal afekto vertinimą. Pateikiami uždaros aplinkos valdymo metodų integracijos su afekto atpažinimo metodais realizacijos principai. Remiantis ankstesniuose skyriuose atlikta analize, šiame skyriuje parodoma, jog žmogaus afekto vertinimo metodų, susietų su fiziologinių parametru įverčiais ir grįžtamojo ryšio panaudojimu, integracija su skatinamojo mokymosi metodais užtikrina efektyvų adaptyvių paslaugų uždaros aplinkos mikroklimato valdymo sistemoje išvystymą.

4 skyrius skirtas sistemos eksperimentinių rezultatų aprašymui, kuriame pateikiami empiriniai pasiūlyto modelio atskiro atvejo analizės tyrimai, taip pat eksperimentiniai tyrimai, siekiant eksperimentiškai patvirtinti pasiūlyto modelio veikimą. Eksperimentiniai imitacinio modeliavimo rezultatai parodė, jog naudojant aktorius-kritiko skatinamojo mokymosi modelį bei afekto pokyčių įvertinimo funkciją, galima pasiekti optimalius apšvietimo, temperatūros ir oro kokybės parametrus pagal toje aplinkoje esančio žmogaus afekto vertinimą.

Bendrosiose išvadose pateikiami darbo rezultatai, išvados ir rekomendacijos.

1. AFEKTO ATPAŽINIMO METODAI IR JŲ TAIKYMO GALIMYBĖS KOMPIUTERINĖSE SISTEMOSE

Šiame skyriuje apžvelgiamos esminės intelektualių sistemų kūrimo problemos, taikant afekto atpažinimo metodus. Analizuojamos afekto atpažinimo metodų taikymo galimybės, įvertinant kompiuterių mokslo pasiekimus šioje srityje. Atliekant kompiuterinių afekto atpažinimo metodų palyginamąją analizę nustatomos jų taikymo galimybės, konstruojant adaptyvias valdymo sistemas. Konkretizuojant tyrimo problematiką, skyriuje nagrinėjami klausimai:

- Kokie metodai leidžia kiekybiškai įvertinti afektą?
- Nuo ko priklauso atskirų kompiuterinių afekto vertinimo metodų tikslumas ir ar jis tenkina afekto atpažinimo grindžiamų sistemų reikalavimus?

1.1. Afekto samprata

Afektas yra stipri ir pakankamai trumpa emocinė reakcija, dažniausiai kylanti, kai staiga pakinta subjektui svarbios gyvenimo aplinkybės. Ši sąvoka apibūdina emociją, nuotaiką bei požiūrį. Emocija arba emocinis atsakas yra tiesioginis afekto atvaizdas, vertinant subjektui svarbų įvykį (stimulą) (Ekman, 1994).

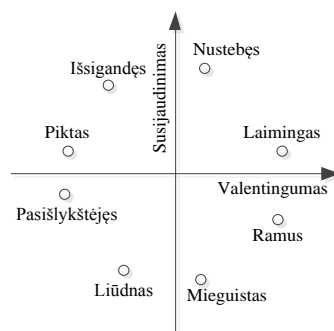
Nuotaika susiformuoja iš kelių emocinių būsenų, susidariusių dėl skirtingų apriorinių įvykių. Suprantama, jog nuotaika keičiasi rečiau negu emocinė būsena, tačiau afektinėje kompiuterijoje ši sąvoka vartojama kaip pagalbinė charakteristika, kada teigiama nuotaika kompensuoja neigiamas emocijas ir atvirkščiai. Požiūris yra labiau susietas su subjektyviu vertinimu, kuris atspindi žmogaus emocinį potyrį apie kiekvieną daiktą ar gyvą

organizmą. Požiūrį formuoja emocinės būsenos ir nuotaikos kaita, susieta su konkrečiu objektu (Gockley ir kt., 2006).

Afekto, kaip emocinės būsenos, atvaizdavimas tam tikra skale grindžiamas dviem nusistovėjusiais modeliais:

1. Pagrindinių emocinių būsenų atvaizdavimas nominaliąja matavimų skale. Naudojant šį metodą vadovaujamosi principu, jog egzistuoja tam tikras skaičius emocinių būsenų (pvz., piktas, laimingas, liūdnas, išsigandęs, pasišlykštėjęs, nustebęs), kuriose gali būti žmogus (Oatley ir Johnson-Laird, 1987; Ekman, 1992). Bet kuri kita būsena traktuojama kaip tam tikros pagrindinės būsenos poaibis;
2. Dviejų arba trijų dimensijų modelis, kuris leidžia bet kurią emocinę būseną atvaizduoti trijų dimensijų intervaline skale (Russell, 1980). Atitinkamos dimensijos išreiškia valentingumo (angl. *valence*) lygmenį, susijaudinimo (angl. *arousal*) lygmenį bei dominavimo lygmenį (angl. *dominance*). Pavyzdžiui, pyktis ir išgąstis turi neigiamą valentingumą ir aukštą susijaudinimą, tačiau pykčio dominavimas yra stiprus, o išgąščio – silpnas.

Russell pasiūlytas supaprastintas emocinių būsenų atvaizdavimo modelis grindžiamas požiūriu į emocijas kaip į tam tikrą susijaudinimo ir valentingumo laipsnį. Tokiu būdu, bet kurią emocinę būseną galima atvaizduoti dvimatėje erdvėje susijaudinimo ir valentingumo atžvilgiu (1 pav.).



1 pav. Emocinių būsenų pozicijos susijaudinimo – valentingumo erdvėje (pagal Russell, 1980).

Afektu atpažinimą galime traktuoti kaip fiziologinių parametrų transformavimą į žmogaus emocinę būseną nusakančias nominalines klases arba, naudojant dviejų dimensijų modelį, transformuojant į kiekvienos dimensijos intervaline skale nusakytą dydį.


1.2. Afektu atpažinimo kriterijai

Afektu atpažinimas gana plačiai taikomas žmogaus ir kompiuterio sąveikoje (HCI – angl. *Human Computer Interaction*), siekiant didinti kompiuterinių sistemų vartotojiškumą bei pritaikyti prie specifinių poreikių. Afektui atpažinti ir įvertinti taikomi įvairūs metodai, pasitelkiant sensorines sistemas, duomenų tyrybos, žinių vaizdavimo metodus ir kitus dirbtinio intelekto principus, leidžiančius nuskaityti, analizuoti bei interpretuoti žmogaus fiziologinius parametrus. Viena grupė metodų, taikomų afektui atpažinti, grindžiama veido išraiškos arba balso atpažinimo principais (Cowie ir kt. 2001). Nemažai galima rasti mokslinių darbų, kurie analizuoja fiziologinius parametrus (širdies ritmas, žmogaus odos galvaninė reakcija) (Kim ir kt. 2004; Canento ir kt., 2011; Fletcher ir kt., 2010), elektroencefalogramos bei kiti duomenys.

Žmogaus reakcijai į aplinką, t.y. afektui įvertinti, galima naudoti trijų žmogaus fiziologinių signalų duomenis, tokius kaip odos galvaninės reakcijos (GSR), elektrokardiogramos (ECG) ir temperatūros parametrus (Wang, 2006; Fleureau ir kt., 2012; Dzemydienė ir kt., 2010, Drungilas ir kt., 2010; Bielskis ir kt., 2009).

Odos galvaninės reakcijos (GSR) matavimas pakankamai paprastas, lengvai realizuojamas. Nesudėtinga GSR jutiklio principinė schema pavaizduota 2 pav. Šis informatyvus fiziologinis signalas dažnai naudojamas įvairiuose žmogaus fiziologiniuose ir psichologiniuose tyrimuose. GSR signalą sukuria autonominės nervų sistemos reakcija, kuri kontroliuoja odos prakaitavimo liaukų aktyvumą. Prakaitavimo liaukų funkcija yra kontroliuojama galvos smegenų ir šis valdymas vyksta per simpatinę nervų

sistemą. GSR dažnai naudojama kaip vienas pagrindinių fiziologinių signalų afektui vertinti, kadangi odos laidumas labai jautriai reaguoja į emocinius sujaudinimus (angl. *arousal*) ir pakankamai informatyviai perteikia žmogaus reakciją į aplinkos pokyčius (Wang, 2006; Fleureau ir kt., 2012).



2 pav. GSR jutiklio principinė schema

Panašiai kaip ir GSR, elektrokardiogramos (ECG) stebėjimo rezultatai leidžia įvertinti, kaip jaudinantis žmogaus širdies ritmas didėja, atsipalaiduojant – mažėja. Širdies veikla atspindi daug esminių psichologinių ir fiziologinių būsenų, kadangi yra stipriai susieta su simpatine bei parasimpatine nervų sistema (Markienė, 2000). Dėl šių dviejų nervų sistemų įtakos atsiranda širdies ritmo variabilumas (angl. *Heart Rate Variability – HRV*), kitaip tariant, periodiniai širdies ritmo pasikeitimai. Svarbiausia yra tai, jog HRV svyruoja tam tikrų dažnių ribose, priklausomai nuo žmogaus emocinės būsenos. Tyrimuose su HRV dažniausiai yra naudojami du dažnių intervalai – aukšto (HF) (0,15-0,4 Hz) ir žemo (LF) (0,04-0,15 Hz) dažnio – ir iš jų išvestiniai dydžiai. Aukšto dažnio HRV pasireiškia dėl parasimpatinės nervų sistemos, esant ramybės, atsipalaidavimo būsenoje. Analogiškai, žemo dažnio HRV pokyčius sukuria simpatinė nervų sistema, esant įtemptai būsenai (Perry, 2007; Rani, 2003). Be šių dviejų dažnių spektrų dar egzistuoja labai žemas (0,0033 – 0,04 Hz) ir ypač žemas (mažiau negu 0,0033 Hz). Tačiau iki šiol nėra visiškai iširta, kokius organizme vykstančius procesus charakterizuoja šie spektrai.

Afektui vertinti taip pat dažnai naudojami ir odos temperatūros matavimai, kurie keičiasi dėl kraujotakos sistemos pokyčių: kraujagyslių pasipriešinimo ar arterinio kraujospūdžio pasikeitimų, kuriuos reguliuoja autonominė nervų sistema. Tyrimais yra įrodyta, jog odos temperatūra skirtingose kūno vietose kinta diferentiškai, priklausomai nuo emocinės reakcijos į stimulą (Perry, 2007). Pavyzdžiui, odos temperatūra smilkinių srityje didėja esant neigiamam afektui (patiriant neigiamas emocijas) ir mažėja esant teigiamam afektui (teigiamoms emocijoms). Pirštų temperatūros, priešingai negu smilkinių srityje, didėjimas susijęs su teigiamomis emocijomis, mažėjimas – su neigiamomis.

1.3. Afekto atpažinimo metodai ir jų galimybės

Didžioji dalis metodų, taikomų fiziologiniams parametrams transformuoti į afektą nusakančias emocinės būsenos klases, priskiriama mašininio mokymo bei atvaizdų atpažinimo (angl. *pattern recognition*) sričiai. Šioje srityje dažniausiai naudojami metodai – tai k artimiausių kaimynų klasifikatorius, funkcinė diskriminantinė analizė, dirbtiniai neuroniniai tinklai, atraminių vektorių mašinos, įvairūs regresinės analizės metodai ir kt. (Chanel ir kt., 2009; Mandryk, 2005).

Svarbiausias uždavinys, naudojant šiuos metodus, yra pasiekti kuo didesnę koreliaciją tarp gautos interpretacijos ir tikrosios žmogaus reakcijos į aplinkos pokyčius vertinimo, t.y. kaip galima tiksliau atlikti emocinės būsenos priskyrimą tam tikrai klasei.

Kaip buvo minėta aukščiau, fiziologinių parametru transformavimas į tarpusavyje nepalyginamas aibes atliekamas naudojant klasifikavimo metodus, kurie mašininio mokymo kontekste gali būti vertinami dviem pagrindiniais aspektais:

- gali būti duota stebėjimų aibė ir siekiama nustatyti egzistuojančias klases. Šis metodas dar vadinamas klasterizacija arba neprižiūrimu klasifikavimu;

- gali būti duota stebėjimų aibė su įvardintomis klasėmis ir siekiama nustatyti taisykles, kurios leis priskirti kiekvieną objektą atitinkamai klasei, t.y. prižiūrimas klasifikavimas (toliau vadinsime klasifikavimu).

Bet kokių atveju, kiekviena klasė yra analizuojama pagal tam tikrą rinkinį kiekybinių kintamųjų, įvardijamų požymiais ar parametrais. Požymiai gali būti kategoriniai, ordinariniai, sveikieji, realieji skaičiai, priklausomai nuo sprendžiamo klasifikavimo uždavinio dalykinės srities. Tačiau klasę nurodantis atributas būtinai turi būti diskretus.

Klasifikavimo metodai taip pat gali būti įvairūs, t.y. sprendimų medžiai, taisyklėmis grindžiamas klasifikavimas, atraminių vektorių mašinos, dirbtiniai neuroniniai tinklai ir šių metodų integracija. Naudojant šiuos metodus, būtinas apmokymo algoritmas, kuris priderina modelį taip, kad atitinkamas požymių rinkinys kuo tiksliau atvaizduotų atitinkamą klasę. Tokiu būdu, mokymo algoritmas, naudojant mokymo imtį, kurioje kiekvienas požymių rinkinys turi nurodytą klasės atributą, sudaro klasifikavimo modelį. Modelio tikrinimui naudojama nauja duomenų imtis, kurioje požymių rinkiniui nėra nurodytas klasės atributas.

Klasifikavimo tikslumą nusako testavimo imtyje teisingai klasei priskirtų stebėjimų skaičius. Bendru atveju, klasifikavimo tikslumas gali būti įvertintas pagal šią formulę:

$$A(h | X) = \frac{\sum_{t=1}^N h(x^t) = c^t}{N} \cdot 100\% \quad (1)$$

Kur $h(x)$ hipotezė, kad x bus priskirtas į atitinkamą klasę, c^t – eksperto nusakyta klasė, N – klasifikuojamų įrašų imties dydis. $h(x^t) = c^t$ lygus 1, kai x^t priskiriamas c^t klasei ir lygus 0 priešingu atveju.

Toliau aptariami afektui vertinti dažniausiai naudojami klasifikavimo metodai.

1.3.1. Atraminių vektorių klasifikatorius (mašina)

Atraminių vektorių klasifikatorius (SVM – angl. *support vector machines*), vienas iš, palyginus, neseniai atsiradusių statistinių požymių klasifikavimo metodų, davusių labai gerų rezultatų vaizdų apdorojimo, ypač veido atpažinimo, srityje. Eksperimentai rodo, kad šie klasifikatoriai veikia ne prasčiau už kitus, be to, reikalauja mažiau mokymo duomenų (Maaoui, 2008). Pagrindinė atraminių vektorių klasifikatoriaus idėja yra dviejų skirtingų klasių mokymo duomenų projektavimas į aukštesnės dimensijos erdvę, pavadintą požymių erdve, ir hiperplokštumos, atskiriančios šias dvi klases, sukūrimas šioje erdvėje. Hiperplokštuma konstruojama maksimizuojant atstumą tarp dviejų artimiausių mokymo duomenų, priklausančių dviem skirtingoms klasėms. SVM reikalauja, kad mokymo ar atpažinimo pavyzdžiai būtų atstovaujami fiksuoto ilgio vektoriais. SVM yra binarinis klasifikatorius, kuris daro sprendimus pagal tiesinę sprendimo ribą arba hiperplokštumą, optimaliai atskiriančią dvi klases (Takahashi, 2004; Rani ir kt., 2006; Kamarauskas, 2009).

1.3.2. Fišerio tiesinio diskriminanto analizė

Fišerio tiesinis diskriminantas dažnai naudojamas, kad būtų galima sumažinti aukštą dimensiškumą turinčius vektorius x iki mažesnį dimensiškumą turinčių vektorių y , kad klasės būtų lengviau atskiriamos (Duda ir Hart, 1973). Fišerio diskriminantas atlieka atstovaujančios matricos w paiešką tokiu būdu, kad originalios dimensijos galėtų būti atidėtos joje remiantis

$$y = w^t x \quad (2)$$

transformacija taip, kad y vektoriaus dimensijos būtų maksimaliai atsiskyrusios ir klasių persidengimas būtų kuo mažesnis. Svorijų matrica w yra linijinė funkcija, kurios kriterijaus funkcijos

$$J(w) = \frac{w^t S_B w}{w^t S_W w} \quad (3)$$

reikšmė yra didžiausia (Maaoui, 2008). Pateiktos lygybės S_B ir S_W parametrai atvaizduoja išsibarstymą tarp klasių ir klasių viduje. Maksimali kriterijaus reikšmė nustatoma tada, kai atstumas tarp klasių vidurkių yra maksimalus ir dispersija kiekvienos klasės viduje yra kuo mažesnė.

1.3.3. k artimiausių kaimynų metodas

Skirtingai nuo kitų klasifikavimo algoritmų, k artimiausių kaimynų metodas arba tiesiog kNN (angl. *k-Nearest Neighbours*) mokymo imties nenaudoja modelio sukūrimui. Priešingai – mokymo imtis ir yra pats modelis (Duda ir Hart, 1973). Naujojo elemento klasės nustatymas gali būti vykdomas dviem būdais:

- globaliu metodu – kai atsižvelgiama į visus mokymo imtyje esančius objektus;
- lokaliu metodu – kai vertinamas tik ribotas skaičius artimiausių kaimynų.

Naujojo elemento klasės nustatymas remiasi atstumo iki kaimynų vertinimu, kad artimiausiai esantys kaimynai turėtų didesni poveikį klasei nustatyti. Atstumas tarp elemento a ir jo kaimyno b paprastai apskaičiuojamas pagal Euklido atstumo formulę:

$$d(a,b) = d(b,a) = \sqrt{(a_1 - b_1)^2 + (a_2 - b_2)^2 + \dots + (a_n - b_n)^2} = \sqrt{\sum_{i=1}^n (a_i - b_i)^2}, \quad (4)$$

kur a_i ir b_i – vektorių dimensijos. Priskiriama ta klasė, kurios atstovų tarp artimiausių kaimynų yra daugiausia:

$$\hat{f}(x_q) \leftarrow \arg \max \sum_{i=1}^k \delta(v, f(x_i)) \quad (5)$$

Alternatyviai galima taikyti svorinį atstumo vertinimą, kai mažesniu atstumu esantys kaimynai turi didesnę įvertį nei labiau nutolę. Dažniausiai

svorinis atstumas apibrėžiamas formule: $w_i = \frac{1}{d(x_a, x_b)^2}$. Globalusis kaimynų vertinimo metodas dažniausiai naudoja būtent svorinį atstumo vertinimą,

kadangi kitaip visada būtų nustatoma klasė, kurios atstovų yra daugiausia tarp visų mokymo imties vektorių.

kNN skaičiavimo algoritmas vienodai atsižvelgia į visas dimensijas, todėl prieš jį taikant reikia atskirti mažą reikšmingumą klasei nustatyti turinčias dimensijas. 1 lentelėje pateiktos stipriosios ir silpnosios k artimiausių kaimynų metodo savybės.

1 lentelė. k artimiausių kaimynų klasifikavimo metodo savybės

Privalumai	Trūkumai
Paprastai įgyvendinamas.	Kaskart nustatant klasę reikia atlikti daug skaičiavimų, kad būtų galima nustatyti atstumą iki kiekvieno mokymo imties elemento.
Efektyviai klasifikuoja, kai tiriamos klasės nėra visiškai atskiriamos.	
Mokymo imties praplėtimas nereikalauja klasifikavimo modelio perskaičiavimo.	Jautres nesvarbiems, triukšmą sukeliantiems atributams.
Mažai derinamų parametrų (atstumo svorio skaičiavimas ir kaimynų skaičius).	Nėra efektyvus, kai mokymo imties klasių egzempliorių skaičius ženkliai skiriasi.

1.3.4. Sprendimų medžių taikymas

Sprendimo medžiu siekiama padalinti uždavinį į smulkesnius uždavinius su mažesne dimensijų gausa. Tolimesnių šakų uždaviniai turi mažiau kriterijų, tarp kurių galima rinktis. Dalijimas šakomis vyksta tol, kol bus galima vienareikšmiškai nustatyti klasę, arba pasiektas minimalus dalinamų elementų kiekis ir dauguma jų priklauso konkrečiai klasei.

Konstruojant sprendimo medį, sprendžiami šie klausimai:

- koks požymis turi būti naudojamas kiekviename išsišakojimo mazge?
- kada nusprendžiama, kad esamas mazgas yra kraštutinis, t.y. tampa lapu?
- kokią sąlygą priskirti požymio patikrai?

Požymio atranka kiekvieno mazgo sąlygai sudaryti remiasi informacijos naudingumo matu:

$$Gain(D, D_L, D_R) = H(D) - H(D_L, D_R), \quad (6)$$

kur $H(D)$ atitinka pilnąją pasirinkto požymio entropiją, o $H(D_L)$ ir $H(D_R)$ yra to požymio pagal pasirinktą taisyklę atskirtų dalinių imčių entropijų suma (Duda ir Hart, 1973). Kitaip tariant, naudingumo matas apibrėžia, kiek sumažės entropija padalinus narinėjamą mazgą atitinkančią imtį. 2 lentelėje pateiktos sprendimo medžių savybės.

2 lentelė. Sprendimų medžių kaip klasifikavimo metodo taikymo savybės

Privalumai	Trūkumai
Aiški tiek sudarymo koncepcija, tiek gauto rezultato interpretacija.	Aukštas detalizavimas per daug prisiderina prie mokymo imties ir praranda objektyvumą, klasifikuojant naujus egzempliorius, tačiau tai būdinga ir kitiems metodams.
Ištreniruotas medis lengvai pritaikomas naujų elementų klasifikavimui.	

1.3.5. Daugiasluoksnio perceptrono taikymo galimybės

Daugiasluoksnis perceptronas (MLP – angl. *Multilayer Perceptron*) sudarytas iš atskirų neuronų, surikiuotų į sluoksnius. Įėjimo signalai x_1, x_2, \dots, x_p patenka į paslėptąjo sluoksnio neuronus. Paslėptųjų sluoksnių gali būti keli, ir čia žemesnio sluoksnio signalai keliauja į aukštesnį, kol galų gale pasiekia išėjimo sluoksnį. Nuolat daugelį kartų sumuojami, netiesiškai transformuojami signalai gali suformuluoti sudėtingas sąvokas, reikalingas tolesniam sprendimų priėmimui pagal informaciją, esančią MLP įėjimuose (Raudys, 2008).

Į perceptrono įėjimą paduodamas n -matis vektorius $X = (x_1, x_2, \dots, x_n)$, o visuose paslėptąjo sluoksnio neuronuose suskaičiuojamos svorinės sumos:

$$s_v = \sum_{i=1}^n x_i w_{iv} + w_{0v} \quad v=1, 2, \dots, h, \quad (7)$$

kurios paduodamos į atitinkamas aktyvacijos funkcijas ir kurių išėjimai $f(s_v)$ tampa MLP išėjimo sluoksnio neuronų įėjimais.

Kad MLP galėtų atlikti konkrečią užduotį, pagal mokymo algoritmą randami svoriai. Mokymo algoritmas, remdamasis pavyzdžiais (mokymo duomenimis), kaip sistema turėtų veikti, adaptuoja MLP svorius.

Yra sukurta daug mokymo algoritmų, tačiau populiariausias praktikoje naudojamas atgalinio sklaidimo algoritmas. Šis prižiūrimojo mokymo algoritmas yra gradientinis optimizavimo metodas, pritaikytas minimizuoti

nuostolių funkciją, kuri tiesiogiai susijusi su perceptrono daromų klaidų skaičiumi.

1.3.6. Susitvarkančių žemėlapių (SOM) taikymas fiziologinių būsenų klasterizavimui

Fiziologinių būsenų klasterizavimui taikomi susitvarkantys žemėlapiai SOM (angl. *Self-Organising Maps*) apibrėžia dvimatį netiesinį manifoldą, kaip įprastinį diskrečių taškų masyvą. Tokio tipo žemėlapių sudarymo algoritmai (SOM) iš dalies primena k-vidurkių algoritmą, tačiau skirtingai nei k-vidurkių algoritmuose pastarasis neoptimizuoja jokios vertės funkcijos. Dėl to yra pakankamai sunku parinkti modelio parametrus ir įvertinti jų konvergavimą. Taip pat nėra jokios garantijos, kad žemėlapis susitvarkys, nes šio proceso sėkmė priklauso nuo atitinkamų parametrų reikšmių parinkimo kiekvienam konkrečiam duomenų rinkiniui.

3 lentelėje pateiktos stipriosios ir silpnosios fiziologinių būsenų klasterizavimui taikomų susitvarkančių žemėlapių SOM savybės.

3 lentelė. Susitvarkančių žemėlapių taikymo savybės

Privalumai	Trūkumai
Gali aiškiai pavaizduoti požymių reikšmingumo rožę klasės nustatymui.	Kaskart mokinant SOM gaunamas vis skirtingas žemėlapis.
Vaizdžiai surikioja klases dvimatyje erdvėje, taip leisdamas įvertinti jų išsibarstymą.	Kaip ir DNT, yra pakankamai ilgai mokinamas.

1.4. Afekto atpažinimo požymių analizės metodai

Algoritmo sudėtingumas iš esmės priklauso nuo nagrinėjamų požymių kiekio ir jų svarbos. Kuo daugiau požymių nagrinėjama, tuo statistine prasme duomenų analizės algoritmas bus sudėtingesnis. Tad kyla klausimas, kaip sumažinti požymių kiekį, neprarandant vertingos informacijos. Šis uždavinys yra gana sunkiai sprendžiamas. Ypač, kai reikia įrodyti, jog duomenų analizės metu gautos išvados yra patikimos (Raudys, 2008).

Požymių atranka remiasi tam tikru kriterijumi, kuris nustato vieno požymio reikšmingumą kitam.

1.4.1. Požymių derinių eksperimentinio tyrimo metodai

Šio tipo metodai grindžiami vartotojų aprašytomis įvertinimo funkcijomis. Įvertinimo funkcija gali būti, pavyzdžiui, bet kuris klasifikavimo metodas. Tai yra itin patogu, norint parinkti geriausią imtį konkrečioms klasifikavimo metodams. Tačiau priklausomai nuo pasirinktos įvertinimo funkcijos sudėtingumo, tokio pobūdžio geriausių požymių derinių paieška gali užtrukti. Kad nereikėtų tikrinti visus įmanomus derinius, siūlomi keli paieškos algoritmai.

1.4.2. Principinių komponentų analizė

Principinių komponentų analizės paskirtis — sumažinti erdvės dimensiškumą, atliekant požymių kovariacinę analizę. Pradiniai požymiai pertvarkomi į naująją koordinačių sistemą, atsižvelgiant į duomenų dispersiją. Esminis principinių komponentų analizės privalumas yra tas, kad naujieji požymiai, vadinami principiniais komponentais, yra dekoreliuojami, t.y. atliekant transformaciją šalinama galima požymių tarpusavio priklausomybė. Kita principinių komponentų analizės taikymo sritis yra atrasti nežinomą tendenciją duomenų rinkinyje.

1.4.3. SOM korekcijos taikomi principai

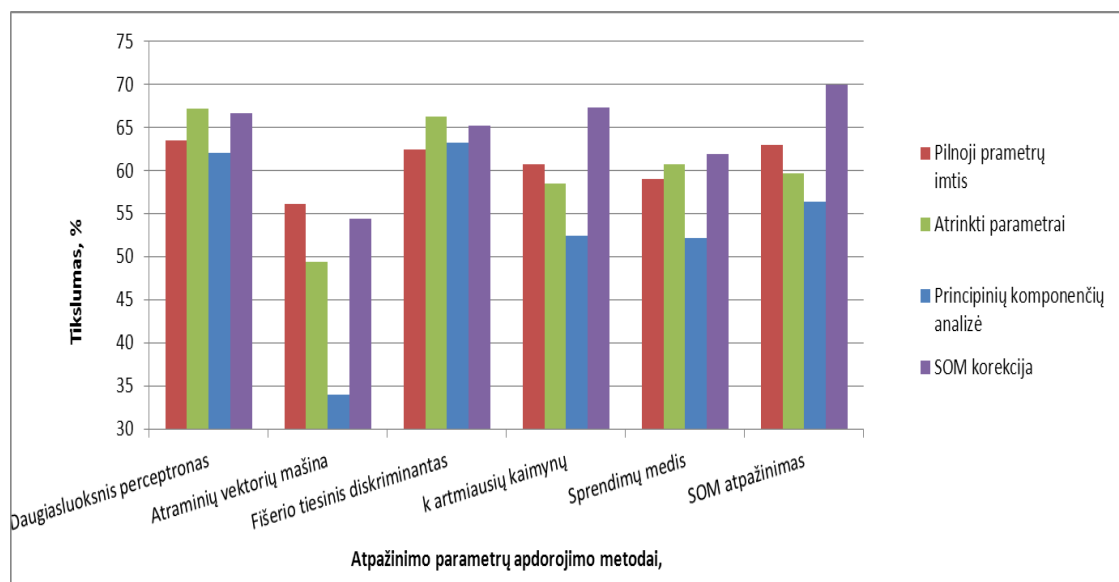
Formuojant dirbtinio neuroninio tinklo mokymo aibę, neišvengiamai susiduriama su „mokytojo triukšmu“. Šis reiškinys atsiranda dėl sužymėjimo klaidų – kai mokymo egzemplioriui priskiriama klaidinga klasė (Alpaydin, 2004). Konkrečiai šiuo atveju, kartais būna sunku atpažinti realią emocinę būseną dėl jų persidengiamumo. Šiai problemai spręsti naudojamas SOM, kuris iš naujo sudarydamas duomenų imties klasterius pašalina sužymėjimo klaidas (Drungilas ir kt., 2010).

1.5. Afekto vertinimo kompiuterinių metodų apibendrinimas

Apibendrinti afekto atpažinimui taikomų metodų analizės rezultatai pateikti 3 pav. Analizuojant parinktų parametų apdorojimo metodų ir klasifikavimo algoritmų:

- daugiasluoksnio perceptrono,
- atraminių vektorių mašinos,
- Fišerio tiesinio diskriminanto,
- k artimiausių kaimynų,
- Sprendimų medžių,
- SOM atpažinimo,

įtaką atpažinimo tikslumui, galima pastebėti, jog daugiasluoksnis perceptronas bei Fišerio tiesinis diskriminantas yra mažiausiai jautrūs parametų korekcijai, todėl galima manyti, jog šie algoritmai labiausiai atsparūs triukšmams. 3 pav. pateiktame grafike matoma, jog SOM korekcija beveik visais atvejais (išskyrus atraminių vektorių mašinos metodą) ženkliai padidina klasifikavimo tikslumą. Taipogi pastebima, kad atraminių vektorių mašinos algoritmas šiuo atveju ypač jautrus bet kokiai požymių korekcijai.



3 pav. Afekto atpažinimo tikslumas, naudojant skirtingus atpažinimo parametų apdorojimo metodus

Afekto atpažinimo rezultatai priklauso nuo pasirinktų fiziologinių signalų bei duomenų klasifikavimo ir analizės metodų. 4 lentelėje pateikiami įvairių mokslininkų tyrimų rezultatai atsižvelgiant į tai, kokie fiziologiniai signalai, duomenų analizės metodai buvo naudojami.

4 lentelė. Afekto atpažinimo metodų galimybių palyginimas

Autoriai	Naudojami fiziologiniai signalai	Taikyti atpažinimo, duomenų analizės metodai	Gauti tyrimų rezultatai
Kim, 2004	GSR, EMG, kvėpavimas, ECG	Tiesinė diskriminantinė analizė	Išskiriant keturias emocines būsenas (laimingas, piktas, atsipalaidavęs, liūdnas) pasiektas tikslumas 84%. Klasifikuojant į pozityvias ir negatyvias emocijas tikslumas nepasikeičia. Dar kitu atveju išskiriant aukštą ir žemą susijaudinimą pasiekiamas 94% tikslumas.
	Temperatūra, GSR, širdies ritmas	Atraminų vektorių klasifikatorius	Klasifikuojamos 3 emocinės būsenos: liūdnas, piktas, įsitemęs. Pasiektas tikslumas 78%. Kitu atveju pridėjus dar vieną emocinę būseną (nustebęs), tikslumas sumažėja iki 62%.
Lisetti ir Nasoz, 2004	GSR, širdies ritmas, temperatūra	Neuroniniai tinklai	Išskiriamos 6 emocinės būsenos: liūdnas, linksmas, išsigandęs, piktas, nusivylęs, nustebęs. Geriausias klasterizavimo tikslumas pasiektas 84%.
Rainville ir kt., 2006	ECG, kvėpavimas, GSR, EMG	Diskriminantinė analizė, sprendimų medis	Diskriminuojamos 4 emocinės būsenos: piktas, išsigandęs, laimingas, liūdnas. Pasiektas 49% tikslumas.
Wagner ir kt., 2005	EMG, ECG, GSR, kvėpavimas	tiesinė diskriminantinė analizė, KNN, daugiasluoksnis perceptronas	Klasterizuojamos 4 emocinės būsenos: piktas, liūdnas, linksmas, patenkintas. Pasiektas tikslumas – 92%.
Haag ir kt., 2004	EMG, GSR, temperatūra, kraujospūdis, ECG, kvėpavimas	Neuroninis tinklas	Nagrinėjant susijaudinimo laipsnį pasiektas tikslumas 97%, valentingumą – 90%.
Sinha ir Parsons,	ECG, GSR, temperatūra,	Tiesinė diskriminantinė	Nagrinėjamos 3 emocinės būsenos: baimė, pyktis, neutrali. Pasiektas

Autoriai	Naudojami fiziologiniai signalai	Taikyti atpažinimo, duomenų analizės metodai	Gauti tyrimų rezultatai
1996	kraujospūdis, EMG	analizė	tikslumas – 67%.
Takahashi, 2004	EEG, kraujospūdis, GSR	Atraminių vektorių klasifikatorius	Klasifikuojamos 5 emocijų būsenos: džiaugsmas, pyktis, liūdesys, baimė, atsipalaidavimas. Pasiektas tikslumas – 42%.
Chanel ir kt., 2006	EEG, GSR, kraujospūdis, kvėpavimas, temperatūra	Bajeso klasifikatorius	Nagrinėjant 2 susijaudinimo lygmenis (aukštą, žemą) pasiektas tikslumas 72%. Klasifikuojant į 3 (aukštas, vidutinis, žemas) – 58%.
Leon ir kt., 2007	HR, GSR, kraujospūdis	Autoasociatyvinis neuroninis tinklas	Klasifikuojamos 3 būsenos: neutrali, negatyvi, pozityvi. Pasiektas tikslumas – 71%.
Sakata ir kt., 2007	EEG	Tiesinė diskriminantinė analizė	Nagrinėjamos 6 emocijų būsenos. Pasiektas tikslumas – 29%.
Rani ir kt., 2006	ECG, GSR, EMG, temperatūra, kraujospūdis, širdies garsas	KNN	Klasifikuojamos 5 emocijų būsenos: susidomėjimas, nerimas, nuobodulys, nusivylimas, pyktis. Pasiektas tikslumas – 79%.
		Regresijos medis	Klasifikuojamos 5 emocijų būsenos: susidomėjimas, nerimas, nuobodulys, nusivylimas, pyktis. Pasiektas tikslumas – 83%.
		Bajeso klasifikatorius	Klasifikuojamos 5 emocijų būsenos: susidomėjimas, nerimas, nuobodulys, nusivylimas, pyktis. Pasiektas tikslumas – 78%.
		Atraminių vektorių klasifikatorius	Klasifikuojamos 5 emocijų būsenos: susidomėjimas, nerimas, nuobodulys, nusivylimas, pyktis. Pasiektas tikslumas – 86%.
Mandryk, 2005	GSR, EMG HR	Neraiškioji logika	Nagrinėjamas susijaudinimo laipsnis ir valentingumas, pagal kuriuos klasifikuojamos 5 emocijų būsenos: džiaugsmas, abejingumas, nuobodulys, nusivylimas, nuostaba. Pasiektas tikslumas iki 95 %.

Klasifikavimo tikslumas akivaizdžiai priklauso nuo nagrinėjamų fiziologinių signalų skaičiaus, uždavinio sudėtingumo ir pasirinkto analizės

metodo. Pastebima, jog padidinus klasių skaičių vienetu, klasifikavimo tikslumas sumažėja daugiau kaip 10%.

Atsižvelgiant į fiziologinių signalų kiekį ir gautus rezultatus, tikslinga būtų pasirinkti dirbtinius neuroninius tinklus arba neraiškiają logiką kaip afekto atpažinimo metodą. Šiuo metodu atliekami tyrimai rodo, jog jo sprendžiamo uždavinio tikslumas yra gana aukštas tiek su mažesniu fiziologinių signalų skaičiumi, tiek klasifikuojant į didesnę klasių skaičių.

1.6. Pirmojo skyriaus išvados

Afekto atpažinimo metodais grindžiamų sistemų kūrimas orientuotas į dvi taikomas sritis: emocinės būsenos imitavimas robotizuotose sistemose, siekiant gerinti žmogaus ir kompiuterio sąveiką; kompiuterinis žmogaus emocinės būsenos atpažinimas, siekiant analizuoti teikiamų paslaugų kokybę arba naudojant įvairias sprendimų paramos sistemas pateikti vartotojui rekomendacijas ar patarimus.

Didžioji dalis afekto vertinimo metodų priskiriama mašininio mokymo bei atvaizdų atpažinimo sričiai. Konkretaus metodo parinkimas priklauso nuo neapdorotų duomenų patikimumo bei reikiamo rezultato tikslumo. Neretai yra derinama keletas metodų, siekiant gauti kuo tikslesnę rezultatą.

Naudojant fiziologinių parametrų analizės metodus, principinių komponentų panaudojimas parodė atraminių vektorių mašinos klasifikavimo metodo jautrumą mokymo vektorius dimensiškumo mažinimui.

Afekto vertinimas priklauso nuo įvairių parametrų apdorojimo metodų tikslumo. Pastebėta, jog Fišerio tiesinis diskriminantas ir daugiasluoksnis perceptronas labiausiai atsparūs požymių pasikeitimams.

Remiantis atlikta analize galima teigti, jog kompiuteriniai afekto atpažinimo metodai pakankamai tiksliai leidžia įvertinti žmogaus reakciją į aplinkos pokyčius, todėl kaip tam tikros konstrukcijos gali būti naudojamos kuriant e. paslaugų (pavyzdžiui, aplinkos mikroklimato adaptavimo) adaptavimo pagal vartotojų poreikius mechanizmą.

2. METODAI, TAIKOMI ADAPTYVAUS VALDYMO SISTEMOMS KURTI

Valdymo sistemą galima projektuoti dviem būdais: remiantis tik turimomis žiniomis apie valdomą objektą arba sukuriant reguliatorių, kuris geba išgauti trūkstamą informaciją veikimo metu (Fu, 1986). Pastarasis metodas dažniausiai taikomas intelektualiose valdymo sistemose, prie klasikinės valdymo teorijos prijungiant mašininio mokymo metodus. Šiame skyriuje nagrinėjamos mašininio mokymosi metodų taikymo ir panaudojimo galimybės, kuriant adaptyvias valdymo sistemas. Aprašomi svarbiausi šių sistemų kūrimui taikomi metodai, kuriant adaptyvaus valdymo sistemos modelį, taikomą aplinkos mikroklimato valdymui. Svarbu atskleisti klasikinių valdymo sistemų ir šiuolaikinių mašininio mokymo grindžiamų valdymo sistemų realizavimo principus, kartu atsakant į klausimus:

- Kokie mašininio mokymosi metodai leidžia realizuoti adaptyvią valdymo sistemą?
- Kokie adaptyvaus valdymo metodai leidžia sukurti uždaros aplinkos mikroklimato valdymo sistemą?

2.1. Adaptyvaus valdymo sistemos samprata

Adaptyvumo sąvoka, t.y. prisitaikymo galimybės samprata, yra atėjusi iš biologijos mokslo, kaip tyrimo objektas, nagrinėjantis ryšį tarp gyvo organizmo ir jį supančios aplinkos. Kompiuterių moksle adaptyvumas atsirado kartu su valdymo teorija ir kibernetika, bandant prisitaikymą susieti su uždaros valdymo sistemos kūrimo paradigma. Pagal šią paradigmą valdymo sistema reguliuoja įvairius artefaktus ir/ar tam tikrus atributus, leidžiančius keisti pačią sistemą, priklausomai nuo konteksto (Martín ir kt., 2008, Salehie ir Tahvildari, 2009).

Adaptyvumas bendru atveju valdymo sistemai išreiškiamas remiantis neigiamo grįžtamojo ryšio principu (Martín ir kt., 2008.):

$$x = -k \frac{\delta J}{\delta x} \quad (8)$$

kur x yra valdymo signalas, J – stebėjimas, kurį bandoma minimizuoti, k – koeficientas, nurodantis sistemos atsako dydį. Pagal šią formulę, sistemos elgsena x atitinka veiksmus, kurie leidžia minimizuoti siektinos ir esamos būsenos skirtumą. Šis adaptavimo principas (žinomas kaip gradiento mažinimas) plačiai taikomas parametrinio mokymosi algoritmuose, minimizuojant paklaidas. Kiekviena adaptyvi sistema turi tenkinti šias savybes:

- Pagal pastovumo dėsnį (Martín ir kt., 2008), kiekviena adaptyvi sistema privalo turėti pastovias kriterijų reikšmes, į kurias konverguoja sistemos būseną. Kitaip tariant, bet kuri adaptyvi sistema turi turėti valdomų parametrų atramines reikšmes, į kurias sistema artėtų kaip į tikslo būseną, eliminuojant sistemą veikiantį išorinį triukšmą;
- Neatliekant jokio veiksmo, sistema išlieka stabilioje būsenoje, kai tą sistemą neveikia jokie vidiniai ar išoriniai trikdžiai.

Remiantis šiomis savybėmis, adaptyvią sistemą galima apibrėžti taip: tegul S – sistemos būseną, kuri keičiasi keičiantis laikui t , E – išorinis veiksnys, turintis poveikį sistemos būsenai S . Sistema S bus adaptyvi tada ir tik tada, kai laikui artėjant į begalybę tikimybė, kad sistema pereis iš būsenos s į būseną s' , veikiant veiksniai E , bus lygi tikimybei, kad sistema pereis iš būsenos s į būseną s' nepriklausomai nuo veiksnio E . Matematiškai tai galima išreikšti:

$$\lim_{t \rightarrow \infty} P_t(s \rightarrow s' | E) = P_t(s \rightarrow s') \quad (9)$$

Kitaip tariant, įvykus tam tikram trikdžiui, sistema per baigtinį laiko tarpą pereina į stabilią būseną ir joje išlieka. Bet kuriuo atveju, sistemos adaptyvumas yra pagrįstas gebėjimu apsimokyti, t.y. mokymasis išreiškia sistemos pasikeitimus, kurie leidžia sistemai tą pačią užduotį atlikti efektyviau. Žinias apie aplinką, kurias agentas įgyja veikdamas toje aplinkoje, apibrėžiant kaip patirtį (angl. *experience*), o charakteristiką, leidžiančią įvertinti agento

atliekamų veiksmų naudą arba priartėjimą prie tikslo – veiksmingumo matą, galima apibrėžti mokymo sąvoka.

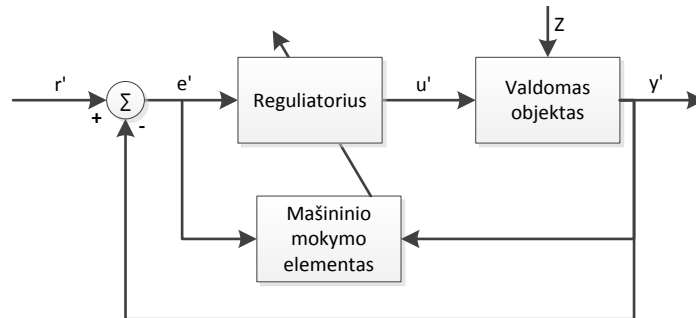
Mokymosi iš patirties programos apibrėžtis: sakome, kad kompiuterinė programa, atlikdama tam tikros klasės užduotis T su veiksmingumo matu P , mokosi iš patirties E , jeigu veiksmingumo matas P užduočiai T didėja kartu su patirtimi E (Russell ir Norvig, 2009).

Sudėtingiems adaptyvaus valdymo uždaviniams spręsti dažniausiai derinama klasikinės valdymo ir mašininio mokymo teorija, todėl toliau būtina paanalizuoti mašininio mokymo taikymo galimybes, kuriant adaptyvias valdymo sistemas.

2.2. Apsimokančios valdymo sistemos

Kai yra žinoma visa informacija apie valdomą objektą ir ta informacija gali būti deterministiškai aprašoma, reguliatoriui sukurti pakanka klasikinių valdymo sistemų projektavimo principų. Tačiau sprendžiant praktinius valdymo sistemų uždavinius, dažnai valdomo objekto aprašyti deterministiškai nėra galimybės. Todėl projektuojant tokio tipo valdymo sistemas naudojamos tik turimos žinios apie įrenginį (šiuo atveju dėl trūkstamų žinių gali atsirasti didelės valdymo sistemos paklaidos) arba sukuriamas reguliatorius, kuris geba išgauti trūkstamą informaciją veikimo metu (Fu, 1986). Pastarasis metodas, naudojant aproksimacijos metodus, leidžia nustatyti valdomo objekto nežinomus parametrus. Šių parametrų nustatymą atlieka mašininio mokymo elementas, kuris, surinkęs pakankamai žinių apie valdomą procesą, koreguoja reguliatorių, siekiant padidinti sistemos efektyvumą. Klasikinė apsimokančios uždaros automatinio valdymo sistemos schema pateikta 4 pav. Adaptyvią valdymo sistemą sudaro reguliatorius, valdomas objektas bei mašininio mokymo elementas. Valdomas objektas, veikiamas išorinių trikdžių Z , keičia savo būseną y' . Valdymo signalas u' šioje sistemoje formuojamas pagal skirtumą e' tarp atraminės (siektinos) vertės r' ir esamosios reguliuojamojo parametro y' reikšmių. Reguliatorius apibrėžia perdavimo funkciją, kuri

valdomo objekto būsenos skirtumo reikšmę e' atvaizduoja į objekto valdymo signalą u' . Siekiant kuo tiksliau apibrėžti reguliatoriaus perdavimo funkciją, kai trūksta žinių apie valdomą objektą, naudojamas mašininio mokymo elementas. Šis elementas koreguoja reguliatoriaus perdavimo funkcijos parametrus, kad būtų išduodamas kuo tikslesnis valdymo signalas u' .



4 pav. Klasikinė apsimokančios valdymo sistemos schema

Apsimokančių valdymo sistemų pranašumas pasireiškia taikant dinaminėje aplinkoje (Fu, 1986), kai nuolat keičiasi valdomo objekto sąlygos. Tokiu atveju, mašininio mokymo elementas leidžia nuolat atnaujinti reguliatoriaus parametrus, nuolat prisitaikant prie besikeičiančių aplinkos sąlygų.

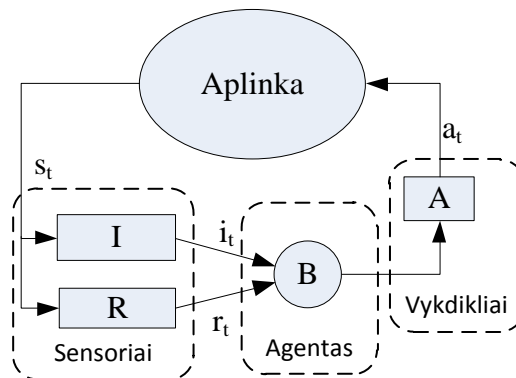
2.3. Mašininio mokymosi metodų taikymas valdymo sistemose

Egzistuoja keletas mašininio mokymosi tipų, kurių taikymas priklauso nuo konkrečios probleminės srities. Todėl ne visada galima išspręsti uždavinį taikant prižiūrimą mokymąsi, kada sistema bando išvesti bendrą taisyklę, remiantis pateiktų pavyzdinių duomenų aibe. Dažnai galima susidurti su uždaviniais, kurie neturi tikslų duomenų, leidžiančių išspręsti norimą uždavinį ar netgi suformuoti duomenų klasterius, naudojant neprižiūrimą mokymąsi. Tokiu atveju, siūloma naudoti skatinamąjį mokymąsi (angl. *reinforcement learning*), kuris yra glaudžiai susijęs su grįžtamoju ryšiu grindžiamu valdymu (Lewis ir Vrabie, 2009). Šis mašininio mokymosi metodas leidžia programiniam agentui apsimokyti nežinomoje aplinkoje iš patirties, kurią

agentas gauna jutiklių pagalba tyrinėdamas nežinomą aplinką, siekiant gauti didžiausią suminę paskatą. Paskata (angl. *reward*) šiuo atveju išreiškia agento atliekamų veiksmų veiksmingumo įvertį, kuri agentas gauna sąveikaudamas su aplinka.

2.4.1. Skatinamojo mokymosi modelis

Skatinamojo mokymosi pagrindinis uždavinys yra surasti optimalią strategiją pagal pasirinktus parametrus, kai agentas, atlikdamas veiksmus, gauna teigiamą arba neigiamą paskatą. Formaliai kalbant, agentas B , siekdamas tikslo tam tikrais laiko momentais t jaučia aplinkos būseną, naudodamasis jutikliais, kurie generuoja įvesties signalą i_t ir nusprendžia vykdyti veiksmą a_t pagal sensorinę informaciją ir aplinkos grįžtamąjį ryšį (paskatą) r_t . Mokymosi tikslas yra kiekviename žingsnyje parinkti veiksmą, kuris duotų didžiausią suminę paskatą (Sutton ir Barto, 2012). Klasikinis skatinamojo mokymosi modelis pavaizduotas 5 pav.



5 pav. Klasikinis skatinamojo mokymosi modelis (Sutton ir Barto, 2012)

Įvesties funkcija I yra aplinkos jutiminė funkcija duotuoju laiko momentu, kuri leidžia agentui „matyti“ aplinką. R yra paskatos funkcija. Taigi skatinamojo mokymosi modelį sudaro trys pagrindiniai komponentai:

- aplinkos būsenų aibė S , kuri gali būti suskaičiuojama arba nesuskaičiuojama, baigtinė arba begalinė;

- agento veiksmų aibė A , kuri gali būti suskaičiuojama arba nesuskaičiuojama;
- paskatos signalų aibė R , kuri gali būti suskaičiuojama arba nesuskaičiuojama.

Skatinamasis mokymasis yra pagrįstas bandymų ir klaidų mokymosi principu, kada agentas tyrinėja aplinką vykdydamas veiksmus iš galimos veiksmų aibės ir siekdamas surasti geriausią strategiją (sprendimų priėmimo funkcija, atvaizduojanti būsenų aibę į veiksmų aibę), kuri duotų didžiausią suminę paskatą.

Taigi sprendžiant skatinamojo mokymosi uždavinius, galima išskirti šiuos pagrindinius komponentus:

- Agentas – autonominė esybė, kuri mokosi jausdama aplinką sensorių pagalba ir veikia aplinką vykdyklių pagalba;
- Aplinka – nedeterministinė, kintanti laikui bėgant, gali būti aprašyta Markovo sprendimų procesu (angl. *Markov Decision Process*);
- Strategija (žymima π) – agento sprendimų priėmimo funkcija, atvaizduojanti būsenų aibę S į veiksmų aibę A ;
- Paskatos funkcija R – atvaizduojanti būsenų ir veiksmų poras į skaliarinį dydį, išreiškiantį agento atliekamų veiksmų veiksmingumo įvertį, kurį agentas gauna sąveikaudamas su aplinka;
- Vertės funkcija (angl. *value function*) – suminė paskatos vertė, kurią agentas gali surinkti atlikdamas prognozuojamus veiksmus.

Visi šie komponentai leidžia nusakyti skatinamojo mokymo metodu sprendžiamą uždavinį. Tačiau formuluojant skatinamojo mokymosi uždavinį, šių komponentų susietumas grindžiamas Markovo sprendimo procesu (angl. *Markov Decision Process – MDP*).

2.4.2. Markovo sprendimų procesas

Skatinamojo mokymo agento sąveiką su aplinka visiškai galima aprašyti naudojant Markovo sprendimų procesą, kuris leidžia atvaizduoti agento perėjimus iš vienos būsenos į kitą, kartu įvertinant perėjimų tikimybes p .

$$p_{ij}(a_k) \in [0,1], \quad \forall i, j, k. \quad (10)$$

$$\sum_j p_{ij}(a_k) = 1 \quad \forall i, j, k. \quad (11)$$

Kur a_k galimas veiksmas atitinkamoje būsenoje, p_{ij} – perėjimo tikimybė iš i -tosios į j -tąją būseną, $p_{ij}(a_k)$ – perėjimo tikimybė iš i -tosios į j -tąją būseną pritaikius veiksmą a_k . Be to, MDP gali būti deterministinis, kada perėjimo tikimybė gali būti arba 1, arba 0 ir nedeterministinis kitais atvejais.

Kiekviena būsena, kurioje yra agentas, turi atitinkamą informaciją, kuri visada leidžia tai pačiai būsenai ir paskatai parinkti visada vienodą veiksmą kitame žingsnyje. Ši savybė vadinama Markovo savybe, kuri formaliai nusako, jog perėjimo tikimybė p_{ij} iš būsenos i į būseną j visiškai priklauso nuo i -tosios būsenos ir atitinkamo veiksmo a_k . Kitaip tariant, agentas, priimdamas sprendimą, remiasi tik būsenos informacija.

Jeigu pažymėtume S_t agento pasaulio būseną laiko momentu t , A_t – veiksmą, pasirinktą laiko momentu t , r_t – paskatą, gautą perėjus į būseną S_t , tada matematiškai galima apibrėžti paskatos funkciją bendru atveju $R: S \times A \rightarrow \mathcal{R}$. Tai reiškia, kad būsenoje pritaikytas veiksmas grąžina paskatą iš realiųjų skaičių aibės. Be to, perėjimų tikimybės funkcija $p: S \times A \times S \rightarrow [0,1]$. Tai reiškia, kad visi veiksmai yra deterministiniai – būsenoje pritaikius veiksmą arba pereinama į kitą būseną, arba ne.

Generuojant agento būsenų perėjimo sekas surandamas kelias iki tikslo – uždavinio sprendinio suradimo. Tačiau priklausomai nuo parenkamų būsenų perėjimo tikimybių, tikslas gali būti pasiekiamas naudojant skirtingas būsenų perėjimo sekas. Todėl siekiant parinkti trumpiausią kelią iki tikslo, naudojamas optimalumo įvertinimo modelis.

2.4.3. Optimalumo įvertinimo modelis

Norint įvertinti agento vykdomų veiksmų veiksmingumą, būtina apibrėžti strategijos vertės funkciją V^π , kur π žymi strategiją, kuri kaip funkcija atvaizduoja būsenas į veiksmus $\pi: S \rightarrow A$. Optimizuojant strategijos vertės funkciją, dažniausiai naudojami trys modeliai:

1. Baigtinio horizonto modelis: agentas siekia optimizuoti suminę paskatą per numatomus h žingsnius.

$$E(\sum_{t=0}^h r_t) \quad (12)$$

Šiuo atveju agentas gali numatyti h žingsnių į priekį ir parinkti didžiausią suminę paskatą duodantį veiksmą;

2. Begalinio horizonto modelis: šiuo atveju paskata eksponentiškai yra mažinama, priklausomai nuo agento numatomų žingsnių skaičiaus, tokiu būdu, suteikiant didžiausią sekančio žingsnio paskatos vertę;

$$E(\sum_{t=0}^{\infty} \gamma^t r_t), \quad 0 \leq \gamma \leq 1 \quad (13)$$

3. Vidutinės paskatos modelis: šiuo atveju stengiamasi maksimizuoti vidutinę tolimų žingsnių paskatą.

$$\lim_{h \rightarrow \infty} E\left(\frac{1}{h} \sum_{t=0}^h r_t\right) \quad (14)$$

Aprašant sprendžiamą uždavinį Markovo sprendimo procesu, reikalingas algoritmas, kuris leistų surasti optimalią strategiją, naudojant optimalumo įvertinimo modelį. Vienas plačiausiai naudojamų tokių algoritmų – tai dinaminis programavimas.

2.4.4. Dinaminio programavimo principų taikymas

Markovo sprendimo procesu aprašomoms problemoms spręsti jau gana seniai naudojamas dinaminio programavimo (DP) algoritmas. DP algoritmas suranda optimalią strategiją π^* su optimalia strategijos vertės funkcija V^* geriausiam MDP modeliui. Optimali strategija yra tokia, kurios vertės funkcijos reikšmė yra didžiausia visoms aplinkos būsenoms:

$$V^*(s) = \max_{\pi} E_{\pi}[\sum_{t=0}^{\infty} \gamma^t r_t], \quad \forall s \in S, \quad 0 \leq \gamma \leq 1 \quad (15)$$

Taigi norint įvertinti strategijos optimalumą, būtina surasti vertės funkcijos aproksimaciją, kuri dažniausiai išreiškiama Belmano lygtimi:

$$V^\pi(s) = \sum_{a \in A} \pi(s, a) \sum_{s' \in S} p_{ss'}(a) [R(S_t, A_t) + \gamma V^\pi(s')], \quad (16)$$

$$\forall s \in S, \quad 0 \leq \gamma \leq 1$$

Kur $\pi(s, a)$ yra tikimybė parinkti veiksmą a būsenoje s , naudojant π strategiją.

2.4.5. Laikinių skirtumų mokymasis

Laikinių skirtumų (angl. *Temporal Difference – TD*) mokymas, kaip ir dinaminis programavimas, rekursiniu būdu apskaičiuoja vertės funkciją. Šis algoritmas leidžia realiu laiku įvertinti strategijos vertės funkciją, skaičiuojant gretimų būsenų vertės funkcijų skirtumus. Tarkime, jeigu turime vertės funkcijos $V(s)$ aproksimaciją $\hat{V}(s)$ būsenoje s , ir vertės funkcijos aproksimaciją $\hat{V}(s')$ kitame žingsnyje s' tada vertės funkcijos atnaujinimas paprasčiausiu atveju TD(0) užrašomas:

$$\tilde{V}_{t+1}(s) = \tilde{V}_t(s) + \alpha [r_{t+1} + \gamma \tilde{V}_t(s') - \tilde{V}_t(s)], \quad 0 < \alpha < 1 \quad (17)$$

Kur α – mokymosi greitis.

Pastebėsime, jog šiuo atveju optimalumas vertinamas skaičiuojant laikinių skirtumų paklaidą (angl. *TD error*):

$$\tilde{\delta}_{t+1} = r_{t+1} + \gamma \tilde{V}_t(s') - \tilde{V}_t(s) \quad (18)$$

Tai reiškia, kad pasiekus optimalią būseną gaunama paskata ir vertės funkcijų pokytis turi būti artimas 0. Be to, jeigu mokymosi greitis atitinkamai artėja į 0 ir yra įvertinama kiekviena būseną pagal fiksuotą strategiją π , tada TD(0) algoritmas užtikrina vertės funkcijos konvergavimą į optimalią reikšmę (Sutton ir Barto, 2012, Kaelbling, Littman ir Moore, 1996). Tačiau šis mokymosi algoritmas nėra efektyvus, kadangi vieno stebėjimo metu yra vertinamas tik vienas vertės funkcijos skirtumas. Šio algoritmo efektyvumui padidinti buvo sukurtas universalesnis TD(λ) algoritmas, kuris mokymo procese naudoja ne tik praeito žingsnio vertės funkcijos skirtumą (kaip TD(0) atveju), bet ir atitinkamo žingsnių skaičiaus istoriją, t.y.:

$$\tilde{V}_{t+1}(u) = \tilde{V}_t(u) + \alpha \tilde{\delta}_{t+1} e_t(u), \quad 0 < \alpha < 1 \quad (19)$$

Kur e – tinkamumo (angl. *eligibility*) matas:

$$e_t(u) = \sum_{k=0}^t (\gamma \lambda)^{t-k} \delta_{u,s_k}, \quad 0 \leq \lambda \leq 1 \quad (20)$$

$$\delta_{u,s_k} = \begin{cases} 1, & u = s_k \\ 0, & \text{kitu atveju} \end{cases} \quad (21)$$

Tinkamumo kelias (angl. *eligibility trace*) e leidžia agentui įsiminti jau aplankytas būsenas ir įvertinti, kaip dažnai buvo aplankytos naujos būsenos.

Realiu laiku atnaujinant tinkamumo matą, galima pasinaudoti formulėmis:

$$\begin{aligned} e_t(u) &= \delta_{u,s_t} + \gamma \lambda \sum_{k=0}^{t-1} (\gamma \lambda)^{(t-1)-k} \delta_{u,s_k} \\ &= \delta_{u,s_t} + \gamma \lambda e_{t-1}(u), \end{aligned} \quad (22)$$

Arba:

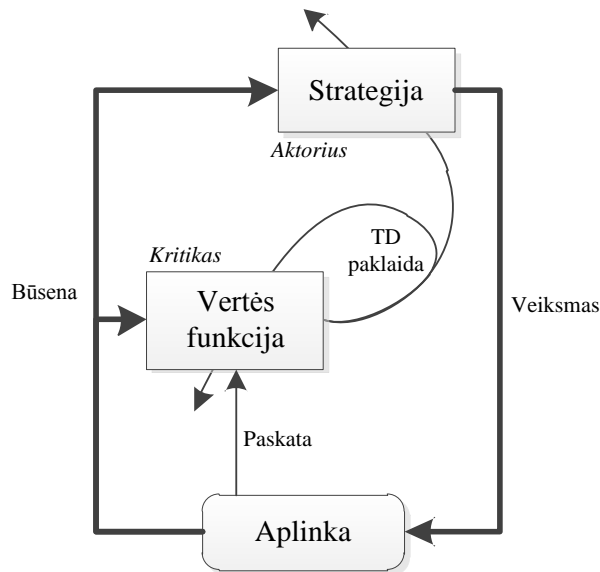
$$e_t(u) = \begin{cases} \gamma \lambda e_{t-1}(u) + 1, & u = s_k \\ \gamma \lambda e_{t-1}(u), & \text{kitu atveju} \end{cases} \quad (23)$$

Šis tinkamumo mato vertinimo metodas vadinamas kaupiamuoju, kadangi, pradėdant nuo pradinės būsenos, yra kaupiama informacija apie jau aplankytas būsenas. Lyginant su TD(0) mokymosi metodu, TD(λ) mokymosi atveju yra greitesnis konvergavimas, tačiau sunaudojama daugiau skaičiavimo resursų, reikalingų analizuoti agento praeities būsenas (Sutton ir Barto, 2012).

2.4.6. Aktoriaus – kritiko metodas

TD mokymosi metodo esmė – veiksmo parinkimas pagal vertės funkcijos įvertį kiekvienai būsenai ir veiksmui. Tačiau egzistuoja tam tikros TD mokymosi konfigūracijos, kai vertės funkcijos įvertis nėra naudojamas tiesioginiam veiksmo parinkimui. Vienas tokių metodų – aktoriaus-kritiko metodas, kuris, naudodamas dvi atskiras atminties struktūras, leidžia atvaizduoti strategiją nepriklausomai nuo vertės funkcijos (6 pav.) (Sutton ir Barto, 2012). Strategijos struktūra atitinka aktorių, kuris būseną atvaizduoja į veiksmą, o apskaičiuota vertės funkcija atitinka kritiką, kuris būseną atvaizduoja į aktoriaus veiksmų veiksmingumo skaitinę vertę. Kitaip tariant,

kritikas atlieka strategijos koregavimą pagal vertės funkciją, apskaičiuodamas TD paklaidą ir keisdamas aktorius bei kritiko struktūrą.



6 pav. Skatinamojo mokymo aktorius - kritiko architektūra (pagal Sutton ir Barto, 2012)

TD paklaida, kuri išreiškia tam tikros veiklos įvertį, šiuo atveju gali būti apskaičiuojama pagal formulę:

$$\delta_t = R_{t+1} + \gamma V(S_{t+1}) - V(S_t), \quad (24)$$

kur V – vertės funkcija.

Teigiama TD paklaida reiškia, jog ateityje toks veiksmas turi būti pastiprintas, o neigiama – susilpnintas veiksmas.

Šio metodo pranašumas tas, jog kritiko struktūrą galima įgyvendinti naudojant vertės funkcijos aproksimaciją, kuri nereikalauja iš anksto apibrėžti visų galimų agento būsenų aibę.

2.4.7. Vertės funkcijos aproksimavimas

Kadangi šiame darbe nagrinėjamas uždavinys, kai afekto ir aplinkos būseną aprašantys dydžiai yra tolydūs, diskretus būsenos atvaizdavimas gali būti problematiškas, nes tolydus MDP gali prarasti Markovo savybę, jei diskretizuojant būsenas naudojamas pakankamai ilgas būsenų išrinkimo periodas (angl. *sampling period*). Tai pasireiškia tuo, kad atsiranda tarpinės būsenos tarp išrinkimo periodo, kurių agentas negali atskirti, tačiau šios

būsenos turi įtaką agento atliekamiems veiksams. Tokiu atveju, kai naudojamos tolydžios būsenų ir veiksmų erdvės, siūloma naudoti radialinių bazinių funkcijų (RBF) neuroninius tinklus tiesinei funkcijos aproksimacijai, kadangi gaunamas tikslesnis būsenų atvaizdavimas lyginant su būsenų diskretizavimu bei nėra sunku aproksimuoti naudojant mašininio mokymo metodus (Doya, 1996, Li ir kt., 2009).

Jeigu būseną sudaro N parametru, kurių kiekvienas turi aktyvavimo faktorių iš intervalo $[0, 1]$, tiesinę funkcijos aproksimaciją galima užrašyti taip:

$$f(x) = \sum_{i=1}^N \phi_i(x) \cdot w_i, \quad (25)$$

kur $\phi(x)$ yra aktyvavimo funkcija, o w_i i -tojo požymio svoris. Aktyvavimo funkcija realizuojama naudojant Gauso funkciją, kurios reikšmė i -tajam požymiui priklauso nuo būsenos s atstumo iki požymio centro c_i ir požymio standartinis nuokrypis σ_i :

$$\phi_s(i) = \exp\left(-\frac{\|s - c_i\|^2}{2\sigma_i^2}\right), \quad (26)$$

RBF tinklui apmokyti yra naudojamas mašininio mokymo algoritmas, siekiant priderinti aktorius ir kritiko funkcijas. Šiuo atveju TD paklaida apskaičiuojama pagal formulę:

$$\delta_{TD}(t) = r(t) + \gamma V(t+1) - V(t), \quad (27)$$

Kur $r(t)$ - paskata, $0 < \gamma < 1$ – diskonto faktorius naudojamas įtakos prognozuojamoms paskatomis apibrėžimui. Aktoriaus ir kritiko svorių vektorius θ atnaujinamas pagal formulę:

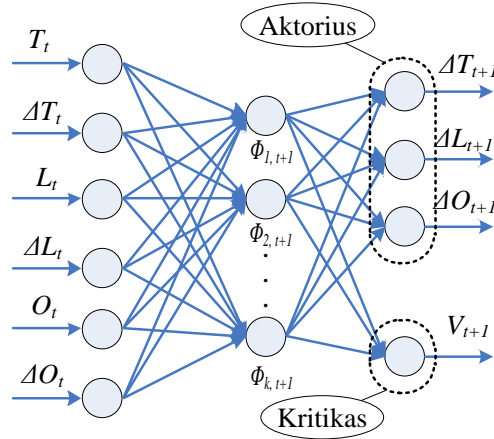
$$\vec{\theta}_{t+1} = \vec{\theta}_t + \alpha \delta_t \vec{e}_t, \quad (28)$$

Kur α – mokymosi greitis, o tinkamumo kelias apskaičiuojamas:

$$\begin{aligned} \vec{e}_0 &= 0, \\ \vec{e}_{t+1} &= \gamma \lambda \vec{e}_{t-1} + \nabla_{\vec{\theta}_t} V(t). \end{aligned} \quad (29)$$

Aktoriaus ir kritiko realizacijai gali būti naudojamas vienas RBF neuroninis tinklas, kadangi tiek kritiko, tiek aktorius įvesties ir paslėptas sluoksniai yra identiški (7 pav.). Toks aktorius ir kritiko realizacijos metodas

leidžia išvengti pasikartojančių skaičiavimų ir taip padidinti mokymosi efektyvumą (Sedighizadeh ir Rezazadeh, 2008).



7 pav. Aktoriaus ir kritiko įgyvendinimas, naudojant RBF neuroninį tinklą

Aktoriaus ir kritiko RBF neuroninis tinklas sudarytas iš šių pagrindinių komponentų:

- Įvesties sluoksnis, kur kiekvienas mazgas žymi sistemos būsenos kintamuosius (temperatūra, apšvietimas, oro kokybė bei šių parametrų pokyčiai) laiko momentu t ir tiesiogiai perduoda į paslėptą sluoksnį;
- Paslėptasis sluoksnis, kurio kiekvieno mazgo išvestis apskaičiuojama pagal formulę (30);
- Išvesties sluoksnis, sudarytas iš aktoriaus ir kritiko dalių. m -tasis aktoriaus dalies išvesties mazgas ir kritiko dalies vertės funkcija apskaičiuojami atitinkamai pagal formules:

$$\Delta_m(t) = \sum_{j=1}^k w_{mj}(t) \Phi_j(t) \quad (30)$$

$$V(t) = \sum_{j=1}^k v_j(t) \Phi_j(t) \quad (31)$$

Kur w_{mj} žymi svorius tarp j -tojo paslėpto mazgo ir m -tojo aktoriaus mazgo, o v_j žymi svorius tarp j -tojo paslėpto sluoksnio mazgo ir kritiko dalies mazgo.

2.4. Antrojo skyriaus išvados

Uždaros aplinkos mikroklimato valdymo sistemos aprašymas yra pakankamai sudėtingas, apimantis daugiakriterinį aplinkos parametrų valdymą bei žmogaus fiziologinių būsenų nagrinėjimą. Todėl tokiai sistemai realizuoti, būtina taikyti mašininio mokymo metodus, kurie geba išgauti trūkstamas žinias apie sistemą jos veikimo metu.

Kuriant adaptyvią uždaros aplinkos valdymo sistemą, automatinio valdymo sistemos principus lengviausia suderinti su skatinamojo mašininio mokymo paradigma. Todėl adaptyvaus valdymo ir afekto atpažinimo metodų integraciją galima realizuoti naudojant aktorius-kritiko skatinamojo mokymo metodą su vertės funkcijos aproksimacija.

Adaptyviai uždaros aplinkos mikroklimato valdymo sistemai sukurti būtina sudaryti funkciją, kuri grąžintų komforto įvertį pagal toje aplinkoje esančio žmogaus afekto įvertį.

3. AFEKTO ATPAŽINIMAS UŽDAROS APLINKOS MIKROKLIMATO VALDYMO SISTEMOJE

Šiame skyriuje pateikiamas uždaros aplinkos mikroklimato adaptyvios valdymo sistemos modelis, kuris leidžia reguliuoti aplinkos mikroklimato parametrus pagal afekto vertinimą. Remiantis ankstesniuose skyriuose atlikta analize, šiame skyriuje pateikiami uždaros aplinkos valdymo metodų integracijos su afekto atpažinimo metodais realizacijos principai, kurie leidžia užtikrinti efektyvų adaptyvių paslaugų uždaros aplinkos mikroklimato valdymo sistemoje išvystymą.

3.1. Afekto atpažinimu grindžiamų sistemų apžvalga

Kompiuterinis afekto vertinimas padarė didelį įnašą į žmogaus ir kompiuterio sąveiką, kuri yra vienas iš svarbiausių komponentų išmaniųjų sistemų kūrime, teikiant paslaugas adaptuojamas prie žmogaus poreikių.

Pagrindiniai pasiekimai, vertinant žmogaus reakciją ir jos būsenas, susikoncentravo į afektinės kompiuterijos technologijas, kurių moksliniai tyrimai grindžiami žmogaus biologinio grįžtamojo ryšio analize (Picard, 1995). Šios analizės pagalba vystomos sistemos gali įvertinti žmogaus fiziologinius rodiklius ir tokiu būdu atpažinti jo reakciją į aplinkos poveikį. Taikant biologinį grįžtamąjį ryšį, pasirinktinai gali būti fiksuojami vienas arba keletas rodiklių, atspindinčių organizme vykstančius procesus. Analizuojant žmogaus fiziologinius signalus, galima įvertinti reakciją į tam tikrus subjektui svarbius aplinkos pokyčius arba, kitaip tariant, afektą ir atitinkamai nustatyti emocinę būseną bei nuotaiką.

Nors afektinės kompiuterijos bendras tikslas išlieka žmogaus ir kompiuterio sąsajos kūrimas, dirbtinio intelekto kontekste ji nagrinėjama keliais aspektais:

- žmogaus afekto vertinimas, naudojant fiziologinių parametru atpažinimą, siekiant nustatyti paslaugų ar tam tikrų reiškinių įtaką žmogui (Forest ir kt., 2006; Kim ir kt., 2004),
- bei emocinės būsenos imitavimas, kaip kompiuterinės sistemos grįžtamasis ryšys (Marreiros ir kt., 2007b; Martin ir kt., 2008; Cowie ir kt., 2001; Castellano ir kt., 2010).

Pastaroji tyrimų kryptis orientuojasi į robotizuotas sistemas, kurios galėtų išreikšti emocines būsenas per atitinkamas vaizdines ar garsines priemones, t.y.:

- dirbtinės veido mimikos imitavimas,
- vaizdo keitimas ekrane,
- skirtingų garsų skleidimas ir pan.

Emocinės būsenos imitavimas taip pat naudojamas tyrimuose, siekiant nustatyti, kokią įtaką turi emocinis faktorius priimant grupinius sprendimus (Marreiros ir kt. 2007a, 2007b).

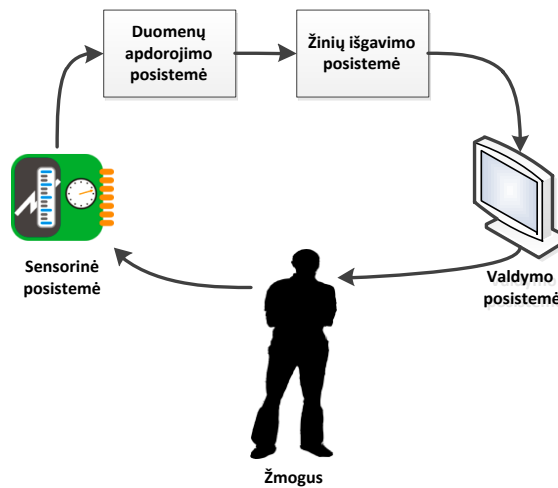
Afekto vertinimo tyrimai orientuoti į nuo nuotaikos priklausančių e. paslaugų teikimą, įgyvendinant skirtingus scenarijus. Pavyzdžiui, (Forest ir kt. 2006) moksliniame darbe parodyta, kaip matuojant žmogaus fiziologinius signalus (elektrokardiogramą, kvėpavimo ritmą bei balso ir odos laidumo pokyčius), belaidžių technologijų pagalba, nuotoliniu būdu, galima nustatyti žmogui gresiantį pavojų ir pagal tai iškviešti pagalbą. Analogiškai, kiti mokslininkai analizuoja, kaip dėvimi jutikliai leidžia stebėti specialiųjų tarnybų darbuotojų (ugniagesių, medikų, policininkų ir t.t.) emocinę būseną ir tokiu būdu vadovaudamasis asmuo gali koordinuoti komandos veiksmus, užduočių paskirstymą ir pan. (Gonzales et al. 2006). Tai parodo, jog kompiuterinis afekto atpažinimas yra labai svarbus gerinant paslaugų kokybę bei didinant darbo efektyvumą.

Mokslininkai (Kaklauskas ir kt., 2011) parodė, jog apjungiant kelias disciplinas (psichologijos, filosofijos, informacijos valdymo ir sprendimų priėmimo ekspertų žinias, dirbtinio intelekto ir biometrines technologijas)

galima sukurti biometrinę streso valdymo sistemą. Ši sistema, naudojant kompiuterines technologijas, leidžia įvertinti žmogaus streso lygį ir pasiūlyti streso mažinimo strategiją. Streso atpažinimas taip pat buvo pritaikytas kuriant biometrinę intelektualią studentų pasiekimų įsivertinimo sistemą (Kaklauskas ir kt., 2010). Ši sistema leidžia įvertinti nuotolinių studijų studentų žinių lygį, apjungiant tradicinius žinių ir gebėjimų vertinimo bei streso analizės metodus. Tolimesniame tyrime (Kaklauskas ir kt., 2013) analizuojamas konkretus pritaikymo atvejis, kai balso ir veido biometriniai duomenys panaudojami lanksčiai žinių vertinimo sistemai kurti.

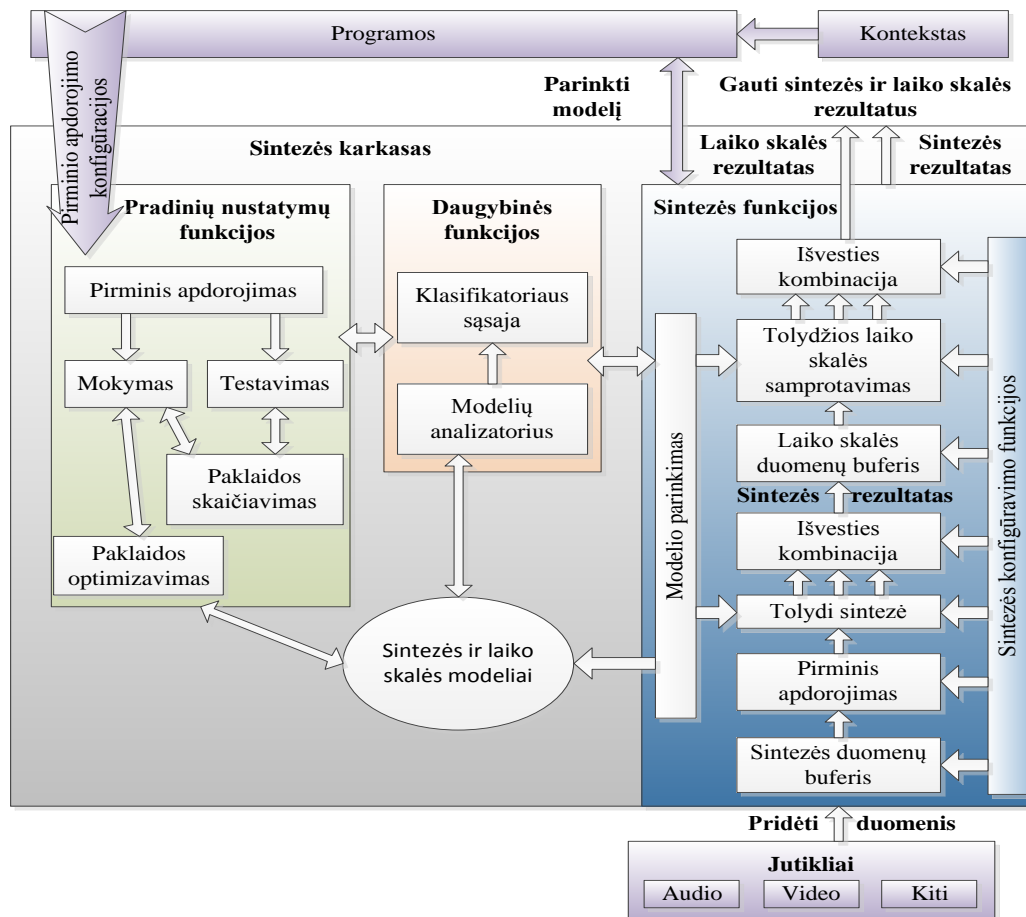
Afektu atpažinimo metodais grindžiamos sistemos turi tam tikrų panašumų. Architektūriniu požiūriu galima išskirti 4 pagrindinius komponentus, randamus šiuo metu egzistuojančiose afektine kompiuterija grindžiamose sistemose (8 pav.), t.y. :

1. Sensorinė posistemė, kuri apima įrenginius (vaizdo kameros, mikrofonai, odos laidumo jutikliai, elektrokardiogramos jutikliai ir kt.), leidžiančius fiksuoti kiekybinius duomenis kaip žmogaus afektą atvaizduojančius fiziologinius signalus;
2. Duomenų apdorojimo posistemė, kuri apima neapdorotų duomenų (angl. *raw data*) filtravimo, sužymėjimo, parametrų išskyrimo procesus. Tokiu būdu, ši posistemė leidžia jutiklių neapdorotus duomenis transformuoti į atitinkamus kiekybinius fiziologinių signalų vertinimus pagal tam tikrus požymius. Kitaip tariant, posistemė gražina fiziologinius požymius;
3. Žinių išgavimo posistemė, kuri leidžia įvertinti afektą pagal fiziologinius požymius;
4. Valdymo posistemė apima procesus nuo paprasčiausio emocinės būsenos atvaizdavimo vartotojui iki fizinių įrenginių valdymo.



8 pav. Afekto atpažinimo metodais grindžiamų sistemų pagrindiniai konstrukciniai komponentai

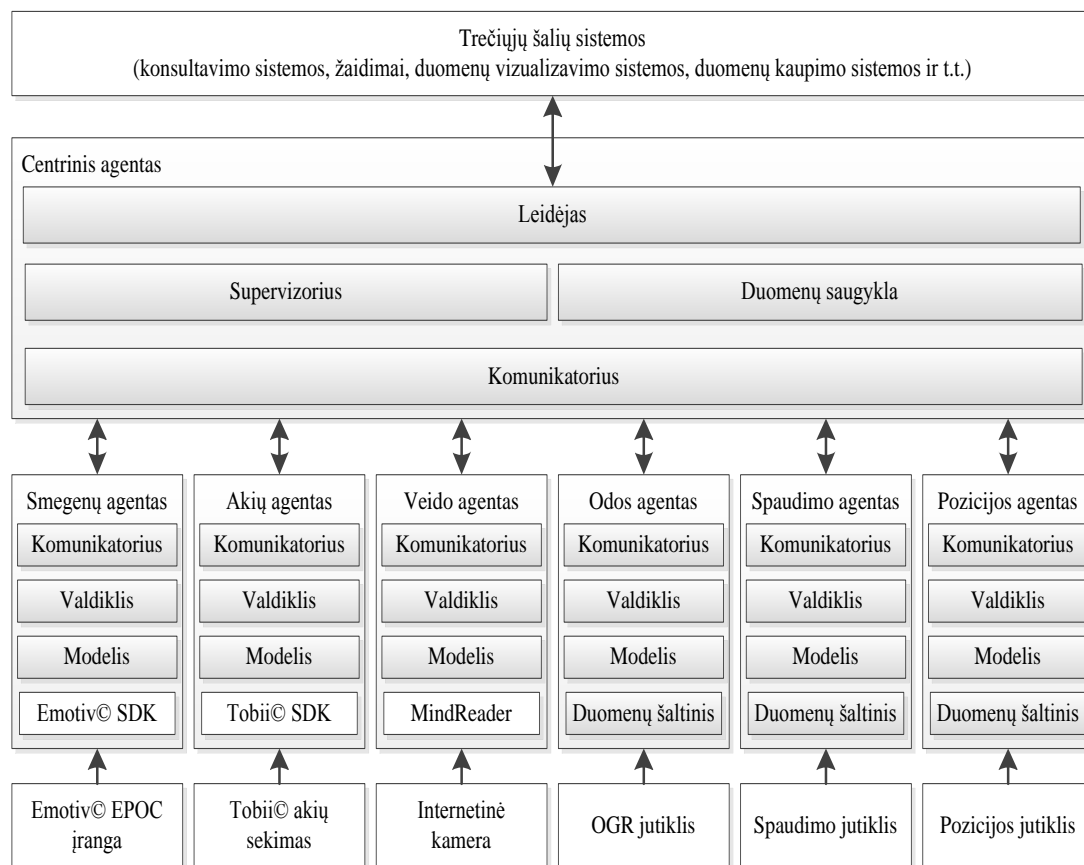
Egzistuoja įvairūs afektine kompiuterija grindžiamų sistemų architektūriniai sprendimai, kurie dažniausiai priklauso nuo sistemos taikymo dalykinės srities. Pavyzdžiui, (Vildjiounaite ir kt., 2009) moksliaame darbe buvo pasiūlyta daugiamodalinio auditorijos emocinės būsenos atpažinimo sistema (9 pav.). Pasiūlyto karkaso pagrindinis privalumas – galimybė integruoti keletą afekto atpažinimo metodų, tačiau, kaip teigia patys autoriai, sistemos patikimumas gali mažėti dėl klaidingos įvesties informacijos.



9 pav. Daugiamodalinio auditorijos emocinės būsenos atpažinimo sistemos pavyzdys (pagal Vildjiounaite ir kt., 2009)

Pagrindines sistemos dalis sudaro jutikliai, kurie nuskaito žmogaus fiziologinius signalus; duomenų apdorojimo, klasifikavimo, mašininio mokymo algoritmų sintezės karkasas, kuris, priklausomai nuo taikomosios srities kontekstinės informacijos, leidžia parinkti atitinkamą modelį.

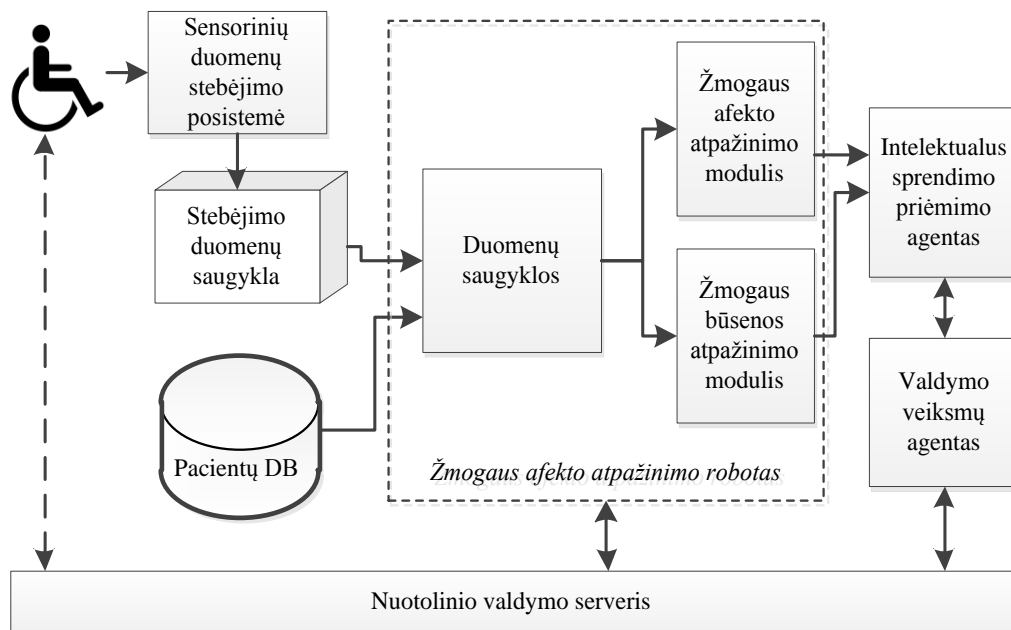
Tačiau universalūs pirminių duomenų apdorojimo metodai ne visada pasiteisina, todėl (Gonzalez-Sanchez ir kt., 2011) pasiūlė agentinių sistemų modeliavimo principais sukurtą daugiamodalinį afekto atpažinimo sistemos modelį (10 pav.).



10 pav. Agentinėmis sistemomis grindžiamos daugimodalinės afekto atpažinimo sistemos pavyzdys (pagal Gonzalez-Sanchez ir kt., 2011)

Šios sistemos privalumas toks, kad kiekvieną fiziologinį signalą apdoroja ir analizuoja atskiras agentas, todėl, atsižvelgiant į įvesties duomenų specifiką, parenkamas tinkamiausias duomenų apdorojimo ir analizės metodas.

Kitas kompiuterinio afekto vertinimo taikymas orientuotas į intelektualių paslaugų kūrimą socialinės e. rūpybos srityje (Bielskis ir kt., 2008; Bielskis ir kt., 2009; Bielskis ir kt., 2010; Dzemydienė ir kt., 2010; Drungilas ir kt., 2010). Siūlomi sprendimai grindžiami išskirstytomis sprendimų paramos agentinėmis sistemomis, kurios leidžia valdyti nuotolines robotizuotas sistemas ir tokiu būdu asistuoti neįgalius asmenis. Šių sistemų privalumas tas, kad yra galimybė kaupti žmogaus fiziologinius duomenis iš keletos jutiklių duomenų saugyklose ir, remiantis šių duomenų analize, adaptuoti sprendimų paramos sistemą.



11 pav. Išskirstyta afekto vertinimo ir sprendimų priėmimo agentinė sistema (Dzemydienė ir kt., 2010)

3.2. Uždaros aplinkos mikroklimato valdymo sprendimų pavyzdžiai

Išmanioji aplinka įvardijama kaip fizinis pasaulis, kuriame didelį vaidmenį atlieka nepastebimi jutikliai, vykdikliai, monitorių ir kompiuteriniai elementai, įterpti į objektus, susietus su mūsų kasdieniu gyvenimu (Weiser ir kt., 1999). Būtent vykdikliai leidžia keisti išmaniosios aplinkos parametrus, taip keičiant žmogų supančios aplinkos mikroklimato parametrus, siekiant tam tikrą komfortą užtikrinančių sąlygų. Tokių sistemų pagrindu tampa daiktų interneto technologijos, kurios leidžia susieti fizinius objektus į sąveikaujančią aplinką.

Mokslinėje literatūroje galima surasti įvairių sistemų aprašymo pavyzdžių, kurios pagal tam tikras užduotas vertes geba keisti supančios aplinkos parametrus, tokiu būdu reguliuojant aplinkos mikroklimatą. Tokios sistemos konstruojamos, siekiant mažinti energijos sąnaudas arba sukuriant žmogaus veiklai optimalią oro kokybę, apšvietimo, temperatūros palaikymo aplinką. Optimalaus mikroklimato sudarymas yra labai svarbus uždaru patalpų

darbo vietos mikroklimato valdymo sistemose, nes nuo aplinkos komforto lygio priklauso darbo vietos ergonominiai rodikliai, kurie veikia žmogaus sveikatą, darbo produktyvumą, emocijas, motyvaciją ir kt. (Masatoshi ir kt., 2010). Mikroklimato reguliavimo uždaviniai ypač aktualūs ir plačiai nagrinėjami kuriant išmaniojo būsto sistemas. Kuriami įvairūs išmaniųjų aplinkų modeliai, akcentuojant patogumą vartotojui, energijos suvartojimą, saugumą (Kazanavičius ir kt., 2011). Taip pat didelis dėmesys skiriamas sistemos architektūriniais sprendimams, kai įterptinės realaus laiko sistemos realizuojamos remiantis daugelio agentų paradigma (Kazanavičius ir kt., 2009).

Intelektualios aplinkos kūrimo srityje vykdoma nemažai projektų, siekiant pasiūlyti architektūrinius elektroninių prietaisų apjungimo į bendrą visumą sprendimus (IoT-A, 2013). Tarpinės programinės įrangos kuriamos įvairialypių fizinių įrenginių apjungimui, siekiant sukurti patogias įrenginių valdymo paslaugas (HYDRA, 2010). Įterptinių sistemų apjungimas ir intelektualizuotų paslaugų teikimas užtikrina vartotojiškumą (Smarcos, 2012).

Sensorizuotos aplinkos architektūriniai sprendimai siūlomi projektuose (ESNA/ITEA2, 2013; Exalted, 2013). Iki šiol tai daugiausiai kuriamos skirtingų platformų atskiros technologinės sistemos, kurias siekiama apjungti į išmanųjį tinklą. Šios srities moksliniai tyrimai skiria daug dėmesio informacinių komunikacinių technologijų kompanijų iniciatyvoms išmaniųjų objektų komunikacijai vystyti. Didieji gamintojai iš daiktų interneto technologijų tikisi nepaprastai didelės pridėtinės vertės.

Strateginė tokių projektų vystymo svarba Lietuvai, Europos Sąjungai, pasauliui grindžiama 2010 m. birželio 15 d. Europos Parlamento rezoliucija dėl daiktų interneto (2009/2224(INI)), IT kūrimo ir plėtros koncepcijos, patvirtintos Lietuvos Respublikos Vyriausybės 2007 m. kovo 21 d. nutarimu Nr. 321 (Žin., 2007, Nr. 40-1489) nuostatomis, ir Bendrosios nacionalinės kompleksinės programos, patvirtintos Lietuvos Respublikos

švietimo ir mokslo ministro 2007 m. gruodžio 3 d. įsakymu Nr. ISAK-2336 (Žin., 2008, Nr. 7-262, Nr. 122-4641) dokumentais.

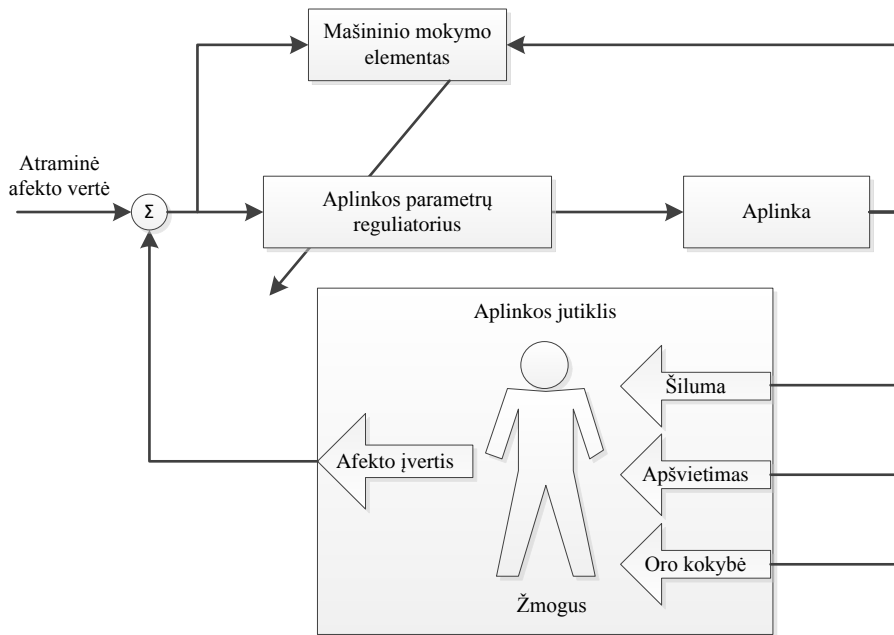
Artimiausiu metu tikimasi sparčios daiktų interneto plėtros ir jaučiama saugaus, skaidraus bei daugiašalio daiktų interneto valdymo būtinybė. Ateities internetas peržengs įprastas šiandienines įmonių bendravimo ribas, nes bus vis labiau susietas su fizinių objektų pasauliu. Daiktų internetas turėtų sudaryti galimybes, naudojant elektroninio identifikavimo sistemas ir judriojo ryšio bevielius prietaisus, tiesiogiai ir visiškai atpažinti skaitmeninius subjektus, fizinius objektus, kad būtų galima nenutrūkstamai rinkti, kaupti, perduoti ir apdoroti su jais susijusius duomenis. Tikimasi, kad dėl daiktų interneto skvarbos pagerės sąveika tarp asmenų ir daiktų bei sąveika tarp pačių daiktų, galinti duoti didžiulę naudą ES piliečiams.

Šiuo metu egzistuojantys intelektualios aplinkos sprendimai gali būti tobulinami, nagrinėjant afekto atpažinimo taikymo galimybes mikroklimato automatinio valdymo sistemų kūrimo. Šiuo metu egzistuojančios mikroklimato reguliavimo sistemos nėra pakankamai automatizuotos ir patogios vartotojui (Eiben ir kt., 2010). Todėl būtina ieškoti adaptyvių uždaros aplinkos komforto valdymo algoritmų, kuriuos būtų galima integruoti kartu su afekto atpažinimo metodais.

3.3. Afekto atpažinimo ir adaptyvaus valdymo metodų integravimas

Siekiant sukurti adaptyvią aplinkos mikroklimato valdymo sistemą, kuri sudarytų žmogui labiausiai tinkamas uždaros aplinkos komforto sąlygas, būtina apjungti afekto atpažinimo ir adaptyvaus valdymo metodus. Pagal šį principą sistema gebėtų keisti uždaros aplinkos mikroklimato parametrus, kai valdymo sistemos grįžtamojo ryšio grandinėje aplinkos sensorinę informaciją išreiškia žmogaus afekto įvertis. Bendras tokios sistemos vaizdas pateiktas 12 pav. Šios adaptyvios automatinio valdymo sistemos etaloninę reikšmę atitinka atraminė afekto vertė, kuri nusako, koks turi būti siekiamas žmogaus afekto įvertis.

Žmogus dalyvauja sistemoje kaip aplinkos komforto jutiklis, kurio afekto įvertis leidžia nustatyti aplinkos komforto parametų tinkamumą tam žmogui.



12 pav. Aplinkos mikroklimato valdymo sistema naudojanti afekto vertinimą kaip grįžtamąjį ryšį

Pagal pastatų šildymo, šaldymo, oro kondicionavimo Amerikos inžinierių bendruomenės (angl. *American Society of Heating, Refrigerating and Air Conditioning Engineers – ASHRAE*) suformuotus standartus, gyvenimo sąlygų kokybę, kitaip tariant, aplinkos komforto sąlygas apibrėžia trys parametrai: šiluminis komfortas, vizualinis komfortas ir patalpų oro kokybė (ASHRAE, 2005).

Šiluminis komfortas apibūdina žmogaus savijautos būseną, išreikštą per šilumos ir masės perdavimo bei energijos balanso lygtis. Iki šiol dažniausiai naudojamas šiluminio komforto kiekybinis vertinimas yra grindžiamas psichologiniais eksperimentais ir terminų parametų analize. Tai reiškia, kad žmonės su įvairiais rūbais ir atliekantys skirtingas veiklas patenka į skirtingų oro temperatūrų, skirtingo drėgnumo, skirtingų oro srauto aplinkas. Po to paprašoma įvertinti komforto lygį, pagal ASHRAE šilumos vertinimo skalę (5 lentelė). Tokiu būdu, apklausus didelę grupę žmonių, išvedamas nuspėjamas

vidutinis balsas (angl. *predicted mean vote* – *PMV*), kuris ir nusako atitinkamos patalpos zonos komforto lygį.

5 lentelė. Šiluminio komforto vertinimo skalė (pagal ASHRAE, 2005)

Reikšmė	Pojūtis
+3	Karšta
+2	Šilta
+1	Silpnai šilta
0	Neutralu
1	Silpnai vėsu
2	Vėsu
3	Šalta


Siekdamas objektyviai įvertinti PMV reikšmę, Fangeris (Fanger, 1982) pasiūlė šio dydžio skaičiavimo metodiką. Anot jo, terminį komfortą nusakantis dydis stipriai koreliuoja su odos temperatūra, prakaitavimu ir žmogaus aktyvumu. Todėl:

$$PMV = 3,155(0,303e^{-0.114M} + 0.028)L' \quad (32)$$

Kur M – metabolizmo laipsnis, L' – terminis krūvis kaip skirtumas tarp vidinės šilumos ir šilumos kiekio atiduodamo į aplinką.

PMV išreiškia šiluminio komforto įvertį, tačiau galima manyti, jog egzistuoja žmonių grupės, kurios nebuvo patenkintos tam tikros aplinkos terminiu komfortu. Terminiu komfortu nepatenkintų žmonių procentinę išraišką nusako PPD (angl. *Percentage of People Dissatisfied*) indeksas, kurio ryšys su PMV (Fanger, 1982) išreiškiamas:

$$PPD = 100 - 95e^{-(0.03353PMV^4 + 0.2179PMV^2)} \quad (33)$$



13 pav. PMV ir PPD dydžių tarpusavio priklausomybė (Fanger, 1982)

Vizualinis komfortas nusako patalpų apšvietimo parametrus (CIBSE, 1994): šviesos intensyvumas, spalva, apšvietimo stabilumas ir pan. Mokslinėje literatūroje pateikiamos bendros patalpų apšvietimo rekomendacijos, atitinkančios vizualinio komforto sąlygas. Tačiau skirtingai negu šiluminio komforto atveju, nėra nusistovėjusi vizualinio komforto kiekybinio vertinimo indekso skaičiavimo metodika, vertinant žmogaus fiziologinius parametrus.

Oro kokybė, panašiai kaip ir vizualinis komfortas, nusakomas pagal patalpų bendras CO₂ koncentracijos rekomendacijas (ASHRAE, 1999).

Šiluminio, vizualinio ir oro kokybės komforto objektyvus vertinimas galimas matuojant žmogaus fiziologinius parametrus. Panašiai kaip šiluminio komforto atveju, kada yra matuojami žmogaus odos temperatūrų skirtumai, galima vertinti ir kitas charakteristikas, kurios atspindi žmogaus afektą prie skirtingų aplinkos temperatūros, apšvietimo ir oro kokybės sąlygų. Afekto įvertį suvedant į vienmatį skaliarinį dydį, galima gauti uždaros aplinkos komforto valdymo grįžtamąjį ryšį.

3.4. Adaptyvios mikroklimato valdymo sistemos grįžtamojo ryšio realizavimas

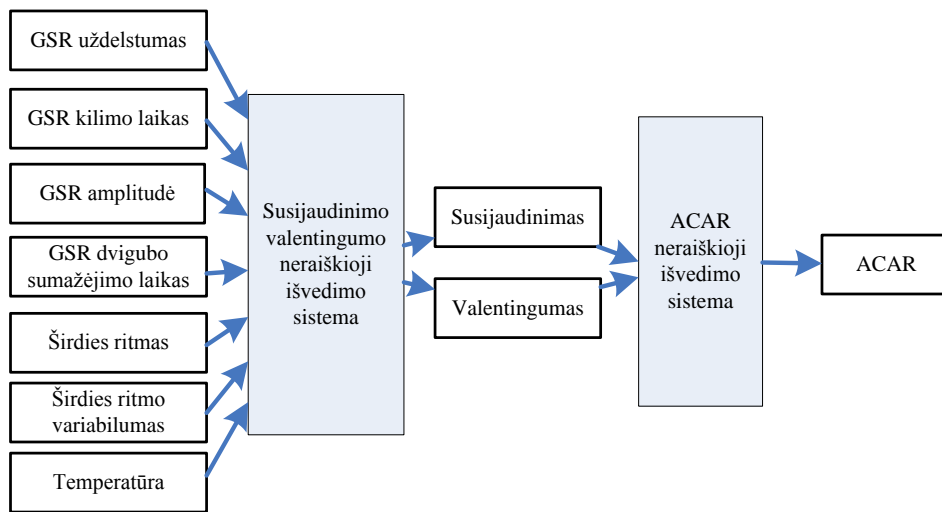
Remiantis ASHRAE sudaryta komforto vertinimo skale, adaptyvios valdymo sistemos grįžtamojo ryšio funkcija turi grąžinti reikšmes iš intervalo

$[-3, 3] \in \mathcal{R}$. Tai reiškia, kad naudojant dviejų dimensijų afekto vertinimo modelį, kuris leidžia valentingumo ir susijaudinimo įverčiais atvaizduoti bet kurią emocinę būseną, galima išreikšti adaptyvios valdymo sistemos grįžtamojo ryšio vertę iš intervalo $[-3, 3] \in \mathcal{R}$. Šią vertę, taikant adaptyvaus valdymo skatinamojo mokymo paradigmą, vadinsime visasupančio komforto afekto paskata (angl. *Ambient Comfort Affect Reward - ACAR*), kurią kaip funkciją išreiškiame:

$$ACAR = f\{ar(t_o, ecg, gsr), va(t_o, ecg, gsr)\}, ACAR \in [-3, 3], \quad (34)$$

kur *ar* ir *va* atitinka susijaudinimo ir valentingumo lygį išreiškiančios funkcijos priklausančios nuo žmogaus fiziologinių parametrų: *t_o* – odos temperatūros, *ecg* – elektrokardiogramos (ECG), ir *gsr* – odos galvaninės reakcijos (GSR).

Daugelyje darbų (Bielskis ir kt., 2009; Bielskis ir kt., 2010; Dzemydienė ir kt., 2010; Drungilas ir kt., 2010) buvo parodyta, jog (33) funkcija gali būti aproksimuojama naudojant neuroninius tinklus, neraiškiają logiką ar kitus regresijos metodus. Kadangi nėra pakankamai duomenų, kurie leistų matematiškai aprašyti ACAR indekso funkciją nuo fiziologinių parametrų, reikalingas ekspertinis vertinimas. Ekspertas, naudodamas apytikslius samprotavimus, gali išvesti pakankamai tikslią funkciją. Šiuo atveju (33), funkcijos aproksimavimui labiausiai tinkamas metodas yra neraiškioji logika, kaip vienas plačiausiai naudojamų universalių aproksimatorių. Remiantis mokslininkų sudarytomis afekto vertinimo metodikomis (Russell, 1980; Mandryk, 2005; Perry, 2007; Ekman, 1992), fiziologiniai parametrai transformuojami naudojant dviejų dimensijų afekto vertinimo modelį, kurie toliau gali būti naudojami apibrėžiant kitas charakteristikas. Naudojant neraiškiają logiką galima sudaryti dvi neraiškiasias išvedimo sistemas, kurios nuosekliai sujungtos išveda susijaudinimo ir valentingumo vertes, o iš jų – ACAR koeficientą (14 pav.).



14 pav. ACAR koeficiento neraiškioji išvedimo sistema

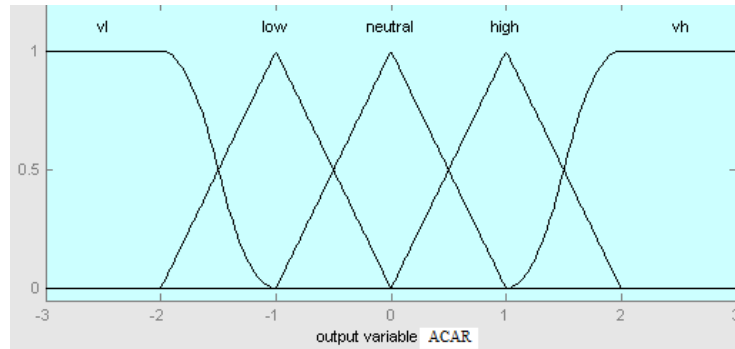
Tarkime, turime U — universumą, kur elementas x priklauso U , o F yra kokia nors savybė. Universumo poaibis $A \subseteq U$, kurio elementai tenkina savybę F , apibrėžiamas kaip aibė sutvarkytų porų: $A = \{x, \mu_A(x) \mid x \in U\}$, kur $\mu_A(x)$ — charakteringoji (priklusomybės) funkcija, turinti reikšmę 1, jeigu x tenkina savybę F ir 0 — priešingu atveju.

$$\mu_A(x) = \begin{cases} 1, & x \in A \\ 0, & x \notin A \end{cases} \quad (35)$$

Neraiškiosios aibės skiriasi nuo įprastų tuo, kad jos elementams x iš aibės U nėra vienareikšmio atsakymo taip/ne priklausomai nuo to, ar x turi F savybę, ar ne. Iš to aiškėja, kad neraiškūs poaibiai A iš universalios aibės U apibrėžiami kaip sutvarkytų aibių poros: $A = \{x, \mu_A(x) \mid x \in U\}$, kur $\mu_A(x)$ - priklausomumo funkcija, įgyjanti reikšmes iš visiškai sutvarkytos aibės M' . Tarkime, kad tai yra intervalas $[0, 1]$. Priklausomumo funkcija parodo elemento x priklausomumo laipsnį poaibiui A . Jei $M' = \{0, 1\}$, tai neraiškūs poaibiai A gali būti nagrinėjamas kaip įprasta arba neraiškioji aibė.

Šiuo atveju, norint apibrėžti ACAR koeficiento priklausomumo laipsnį valentingumo parametrui, turi būti suformuojamos priklausomumo funkcijos,

kurios ir išreikš priklausomumo laipsnį norimo parametro lingvistiniams kintamiesiems (15 pav.)



15 pav. Neraiškiosios logikos ACAR priklausomumo funkcijos

ACAR koeficientas yra išvedamas iš valentingumo ir susijaudinimo parametrų, taikant neraiškiasias taisykles, kurios ir yra neraiškaus samprotavimo pagrindas. Naudojant neraiškiają išvedimo sistemą yra išvedamas dydis iš intervalo $[0, 1] \in \mathcal{R}$, kuris pasako, kiek sakinio konsekventas B yra teisingas, žinant sakinio antecedento teisingumo laipsnį.

Tarkime žinoma, kad x yra A' ir turime taisyklę, jei x yra A , tada y yra B . Tada galima išvesti, kad y yra B' , kur B' reiškia neraiškiają aibę, artimą B , taikant, kad A' yra artimas A . Formaliai tai galima užrašyti:

$$(x \text{ is } A' \text{ and } A \rightarrow B) \rightarrow (B \text{ is } B') \text{ toks, kad :} \quad (36)$$

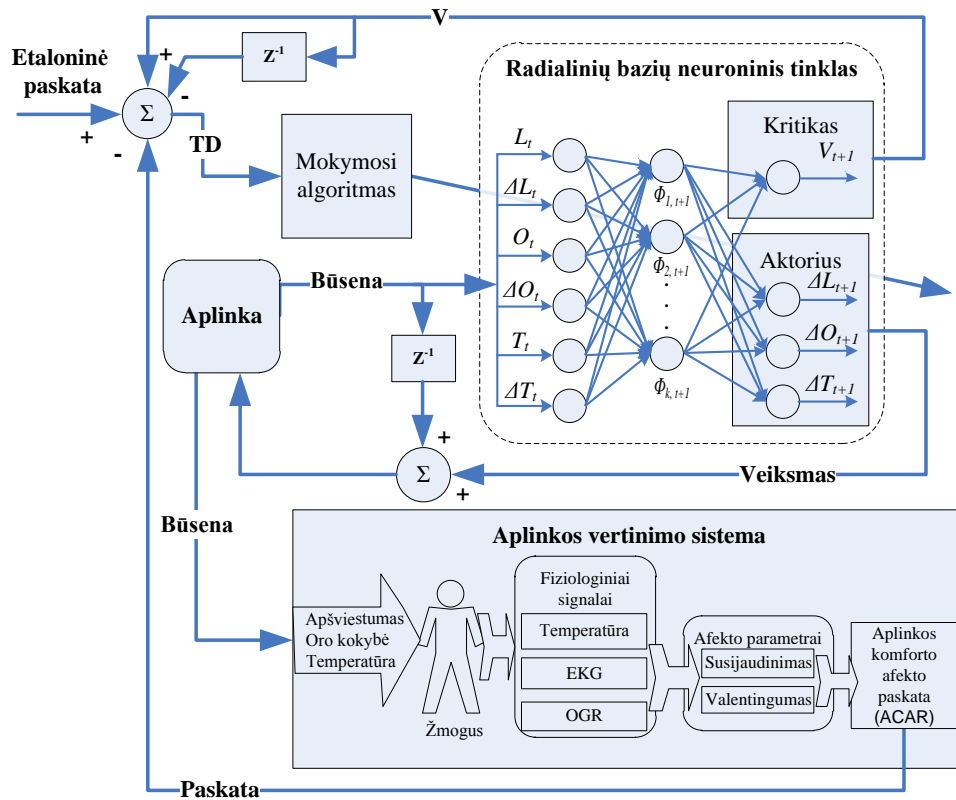
$$\mu_{B'}(y) = \max_x \min[\mu_{A'}(x), \mu_R(x, y)]$$

Kur $\mu_R(x, y)$ yra neraiškaus ryšio priklausomumo funkcija, taikant implikaciją (\rightarrow). Atvaizdavimas iš duotos įvesties į išvestį, naudojant neraiškiają logiką, yra atliekamas naudojant neraiškiają išvedimo sistemą, kuri duoda išvedimą pagal neraiškiają įvesties informaciją ir taikant neraiškiasias taisykles.

3.5. Skatinamojo mokymosi taikymas uždaros aplinkos mikroklimate reguliavimui

Intelektualios aplinkos valdymo sistemos kūrimas yra grindžiamas adaptyviomis elektroninėmis paslaugomis, kurios gali prisitaikyti prie vartotojų poreikių.

Skaitmeninio valdymo požiūriu galima sudaryti modelį, leidžiantį valdyti uždaros aplinkos mikroklimatą formuojančių įrenginių parametrus (temperatūrą, apšvietimą, oro kokybę) pagal žmogaus afekto kompiuterinį vertinimą. Remiantis šiuo principu, projektuojama uždara valdymo sistema, naudojant skatinamojo mokymosi ir afekto įvertinimo metodus (16 pav.).



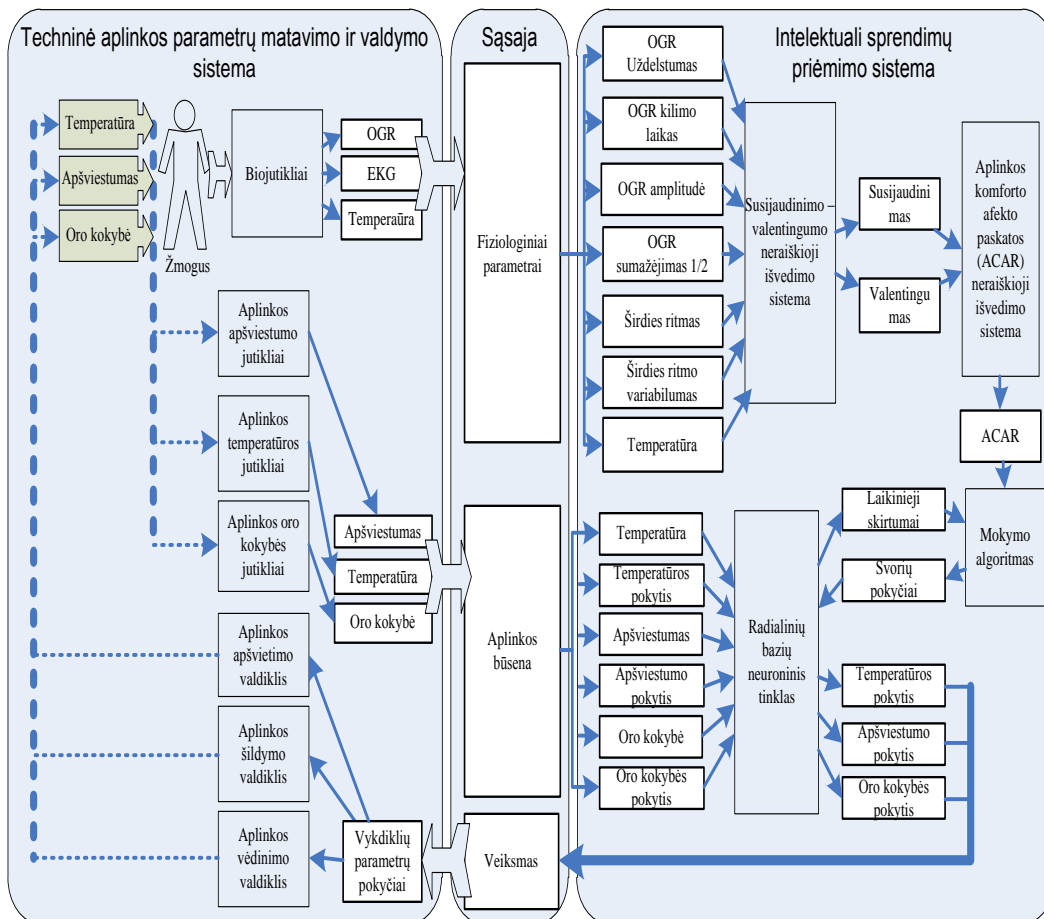
16 pav. Skatinamuoju mokymu grindžiamas uždaros aplinkos mikroklimato valdymo sistemos modelis

Uždaros aplinkos mikroklimato valdymo modelis apjungia aplinkos vertinimo sistemą, radialinių bazių neuroninį tinklą ir mokymosi algoritmą.

Pirmiausia yra fiksuojama etaloninė paskata, t.y. paskatos vertė, kuri atitiks optimalią aplinkos mikroklimato būseną (šiuo atveju etaloninė paskata bus lygi 0). Aplinkos vertinimo sistema grąžina aplinkos komforto afekto paskatą (ACAR). Ši sistema leidžia pagal afekto įvertį nustatyti aplinkos komfortabilumo indeksą (ACAR).

Aplinkos parametrai, nusakantys aplinkos būseną, taip pat yra fiksuojami ir radialinių bazių neuroninio tinklo įvestyje. Kadangi fiksuojami 3 aplinkos būsenos parametrai ir kartu paimant pirmuosius šių parametru skirtumus gaunami 6 RBF tinklo įvesties parametrai. RBF tinklo išvestys atitinka kritiko ir aktorius signalus. Kritiko signalas fiksuojamas kaip vertės funkcija (V), kuri kaip pagrindinis parametras naudojamas laikinųjų skirtumų (TD) apskaičiavimui. Laikinieji skirtumai tiesiogiai veikia mokymosi algoritmą, kuris leidžia adaptuoti RBF tinklu realizuotą aktorius ir kritiko struktūrą. Aktorius signalas fiksuojamas kaip veiksmas – t.y. aplinkos parametru pokyčiai, kurie reikalingi norint pasiekti optimalią aplinkos būseną. Pagal pasiūlytą aplinkos mikroklimato valdymo modelį, sistema turėtų pasiekti optimalią aplinkos būseną, minimizuojant etaloninės paskatos ir ACAR indekso skirtumą.

Remiantis ankstesniuose skyriuose atlikta metodų analize, galima išskirti tris pagrindines aplinkos mikroklimato valdymo sistemos dalis: techninę įrangą, kuri valdo ir matuoja aplinkos parametrus, intelektualią posistemę, kuri atsakinga už sprendimo priėmimą bei sąsają, kuri apjungia techninę bei intelektualiąją posistemas (17 pav.).



17 pav. Išvystyta aplinkos mikroklimato adaptyvaus valdymo, pagal žmogaus afekto vertinimą, sistemos architektūra

Šios sistemos veikimas grindžiamas bandymų ir klaidų keliu, kai yra ieškoma tokių aplinkos parametru, kurie žmonėms, esantiems toje aplinkoje, sudarytų geriausią aplinkos komfortą.

Techninę aplinkos parametru matavimo ir valdymo sistemą sudaro įterptiniai įrenginiai, „jaučiantys“ aplinkos būseną, kurios pagrindiniai parametrai:

- apšviestumas;
- šiluma
- oro kokybė (CO₂ kiekį ore).

Šių parametru keitimas galimas naudojant atitinkamus vykdyklius (šildytuvą, ventiliatorių bei šviestuvą), kurie leidžia keisti aplinkos būseną, taip keičiant uždaros aplinkos mikroklimatą. Kadangi aplinkos parametru valdymas

grindžiamas žmogaus afekto vertinimu, tai techninei posistemei priklauso ir instrumentiniai biosensoriai, naudojami žmogaus fiziologinių signalų nuskaitymui:

- odos galvaninei reakcijai,
- elektrokardiogramai,
- odos temperatūrai.

3.6. Trečiojo skyriaus išvados

Analizuojant afekto atpažinimo metodus ir adaptyvaus valdymo principus pastebėta, jog kiekybinis afekto įvertinimas leidžia sukurti uždaros automatinės aplinkos mikroklimato valdymo sistemos grįžtamąjį ryšį.

Adaptyvią mikroklimato valdymo sistemą galima realizuoti įjungiant kompiuterinį afekto vertinimą į grįžtamojo ryšio grandinę.

Afekto kiekybinį vertinimą traktuojant kaip paskatos funkciją, galima sukonstruoti komforto adaptavimo pagal afekto vertinimą modelį, naudojant skatinamojo mokymosi metodus.

4. UŽDAROS APLINKOS MIKROKLIMATO VALDYMO SISTEMOS EKSPERIMENTINIAI TYRIMAI

Šiame skyriuje pateikiami eksperimentiniai tyrimai, siekiant eksperimentiškai patvirtinti sukurtos komforto adaptavimo pagal afekto vertinimą sistemos veikimą bei įvertinti jos stabilumą. Pateikiami sistemos verifikavimo ir testavimo rezultatai siekiant įrodyti, jog sukurta aplinkos komforto parametrų adaptyvaus valdymo sistema leidžia pasiekti optimalius apšvietimo, temperatūros ir oro kokybės parametrus pagal toje aplinkoje esančio žmogaus afekto vertinimą. Siekiant išspręsti šį uždavinį, būtina:

- Fiksuojant ir analizuojant žmogaus fiziologinius parametrus sudaryti žinių bazę, kuri atvaizduotų fiziologinius parametrus į afektą nusakančią būseną;
- Remiantis sudaryta žinių baze, sumodeliuoti afekto įvertį išreiškiančią paskatos funkciją;
- Ištirti sukurtos uždaros aplinkos mikroklimato valdymo sistemos stabilumą.

4.1. Eksperimentinio tyrimo metodika

Eksperimentiniai tyrimai atliekami naudojant 1 skyriuje atrinktus afekto įvertinimo metodus, 2 skyriuje pateiktą adaptyvaus valdymo metodą bei 3 skyriuje sukurtą uždaros aplinkos mikroklimato valdymo sistemos modelį. Siekiant atlikti sukurtos sistemos validaciją ir verifikaciją bei eksperimentiškai įvertinti sistemos elgseną, buvo sukurtas ir panaudotas prototipinis fiziologinių signalų matavimo techninės įrangos maketas. Remiantis išmatuotais žmogaus odos galvaninės reakcijos, elektrokardiogramos, odos temperatūros duomenimis bei ekspertiniu vertinimu, naudojant skirtingus aplinkos būsenos

scenarijus, buvo sudarytas aplinkos mikroklimato adaptyvios valdymo sistemos imitacinis modelis.

Eksperimentiniai tyrimai suskirstyti į 3 etapus:

1. Afekto vertinimo tyrimas, siekiant patikrinti afekto įvertinimo galimybes. Šiam tyrimui yra nuskaitomi trys žmogaus fiziologiniai signalai (odos galvaninė reakcija, elektrokardiograma ir pirštų temperatūra). Atliekant pirminį duomenų apdorojimą taikomi filtrai, išskiriami parametrai. Tokiu būdu sudaroma duomenų imtis prižiūrimam mokymui. Naudojant sudarytą mokymo imtį, apmokomas neuroninis tinklas spręsti daugiakriterinį klasifikavimo uždavinį, t.y. atvaizduoti fiziologinius parametrus emocinių būsenų nominaliąja skale. Statistiškai įvertinami gauti rezultatai;
2. Paskatos funkcija išreikšto afekto vertinimo tyrimas. Šiuo atveju, pasinaudojant surinktais fiziologinių matavimų duomenimis bei naudojant ekspertinį vertinimą, sudaroma neraiškioji išvedimo sistema, kuri ir sudaro aplinkos būsenos atvaizdavimo į aplinkos komforto afekto paskatą funkciją;
3. Mikroklimato reguliavimo tyrimas. Šiame etape pateikiamas imitacinis modeliavimas remiantis 3 skyriuje sudarytu adaptyvios valdymo sistemos modeliu. Tyrimo rezultatai įvertinami lyginant aplinkos mikroklimato regulatoriaus stabilizuotumą.

4.2. Afekto vertinimo duomenų aprašymas


Remiantis anksčiau atliktais tyrimais (Bielskis ir kt., 2008; Bielskis ir kt., 2009; Bielskis ir kt., 2010; Dzemydienė ir kt., 2010; Drungilas ir kt., 2010), buvo parodyta, jog afektą pakankamai tiksliai charakterizuoja trijų žmogaus fiziologinių signalų (odos galvaninė reakcija, elektrokardiograma ir pirštų temperatūra) parametrai.

GSR dažnai naudojama kaip vienas pagrindinių fiziologinių signalų, kadangi odos laidumas labai jautriai reaguoja į emocinius sujaudinimus (angl.

arousal) ir tokiu būdu pakankamai informatyviai perteikia žmogaus afektinę būseną (Cacioppo ir Tassinari, 1990; Mandryk, 2005; Rani, 2003). Nuo pat pirmųjų tyrimų GSR buvo siejama su emociniais pasikeitimais, nerimu, dėmesingumu.

GSR fiziologinį signalą apibūdina 4 fiziologiniai parametrai, kurie bus naudojami kaip kriterijai vertinant afektą (3 pav.):

1. Uždelsimas Lat (angl. *Latency*), kuris nusako laiko tarpą nuo stimulo pradžios iki kreivės kilimo pradžios;
2. Kreivės kilimo laikas RT (angl. *Rise Time*), t.y. intervalas, nurodantis, kiek laiko trunka, kol odos laidumas pasiekia piką;
3. Amplitudė A (angl. *Amplitude*), kuri nusako odos laidumo pokytį;
4. Kreivės mažėjimas HRT (angl. *Half Recovery Time*), kuris nusako, per kiek laiko kreivė sumažėja iki pusės amplitudinės reikšmės (Wang ir McCreary, 2006).



18 pav. Tipinė GSR kreivė, su ją charakterizuojančiais fiziologiniais parametrais

Taip pat yra žinoma, jog jaudinantis širdies ritmas didėja, nuobodžiaujant – mažėja. Širdies veikla atspindi daug esminių psichologinių ir fiziologinių būsenų, kadangi yra stipriai susieta su simpatine bei parasimpatetine nervų sistema (Markienė, 2000). Dėl šių dviejų nervų sistemų įtakos atsiranda širdies ritmo variabilumas (angl. *HRV – Heart Rate Variability*). Svarbiausia šioje vietoje yra tai, jog HRV svyruoja tam tikrų dažnių ribose, priklausomai nuo žmogaus emocinės būsenos. Tyrimuose su HRV dažniausiai yra naudojami du dažnių spektrai – aukšto (0,15-0,4 Hz) ir žemo (0,04-0,15 Hz) dažnio. Aukšto

dažnio HRV pasireiškia dėl parasimpatinės nervų sistemos, esant ramybės, atsipalaidavimo būsenoje.

Taigi šiame darbe naudojami du ECG fiziologinio signalo parametrai (kriterijai) – širdies ritmas ir širdies ritmo kitimas.

Dar vienas afektui įvertinti gana dažnai naudojamas fiziologinis signalas – tai odos temperatūra, kuri keičiasi dėl kraujotakos sistemos pokyčių: kraujagyslių pasipriešinimo ar arterinio kraujospūdžio pasikeitimų, kuriuos reguliuoja autonominė nervų sistema. Tyrimais yra įrodyta, jog odos temperatūra skirtingose kūno vietose kinta skirtingai, priklausomai nuo emocinės reakcijos į stimulą. Pavyzdžiui, odos temperatūra smilkinių srityje didėja patiriant neigiamas emocijas ir mažėja esant teigiamoms emocijoms. Pirštų temperatūros, priešingai negu smilkinių srityje, didėjimas susijęs su teigiamomis emocijomis, mažėjimas – su neigiamomis (Perry, 2007). Todėl temperatūrą galima laikyti kaip gana reikšmingą kriterijų vertinant afektą.

Taigi, apibendrinant, yra 7 kriterijai, kuriais remiantis bus vertinamas afektas:

- GSR uždelstumas,
- GSR kilimo laikas,
- GSR amplitudė,
- GSR kritimo laikas,
- ECG ritmas,
- ECG ritmo kitimas,
- Temperatūra.

4.3. Afekto vertinimo tyrimas

Fiksuojami fiziologiniai signalai dažnai yra sumišę su triukšmais. Triukšmų šaltiniai gali būti įvairūs: 50 Hz dažnio triukšmai, besiindukuojantys stebimojo žmogaus kūne, jutikliuose, laiduose ar kitokiuose elektronikos komponentuose dėl elektros energijos tiekimo linijų ar instaliacijos, taip pat bevielio ryšio ar elektronikos įrenginių aukštojo dažnio triukšmai. Triukšmais

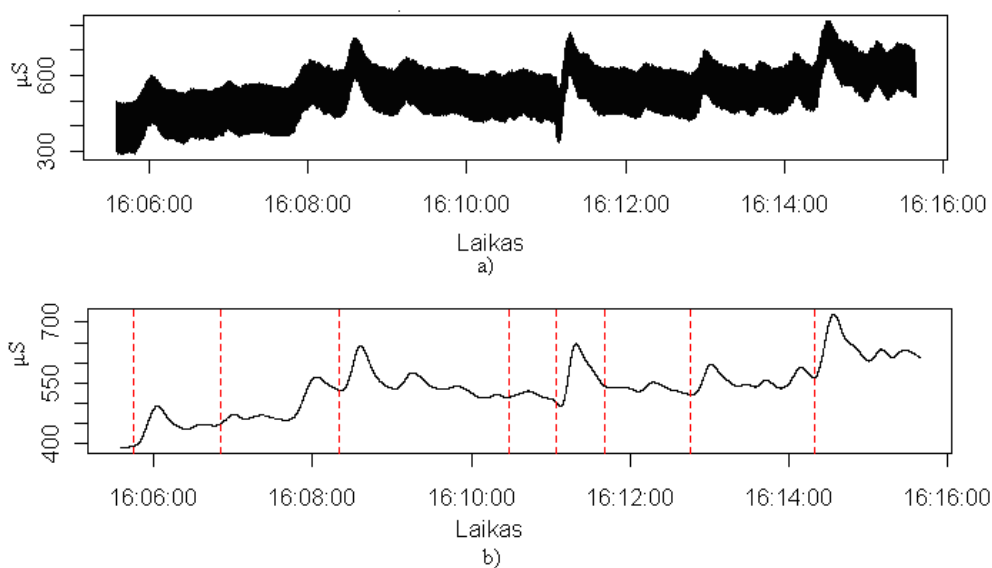
taip pat gali būti ir kiti stebimojo žmogaus fiziologiniai signalai. Pavyzdžiui, matuojant elektrokardiogramą, triukšmas gali būti to paties žmogaus elektromiograma (Lukočius, 2005).

Pagrindinė skaitmeninių duomenų apdorojimo priemonė – skaitmeniniai filtrai. Skaitmeninių filtrų pranašumai prieš analoginius filtrus (Analog Devices, 2003):

- yra tikslesni;
- turi tiesinę fazinę charakteristiką (baigtinės delsos impulsiniai filtrai);
- neturi paklaidų dėl komponentų parametrų kitimo, keičiantis išorės veiksniams (pvz., nejautrūs temperatūrai);
- yra lankstūs. Gali būti panaudojami kaip adaptyvūs filtrai;
- juos lengva patikrinti ir projektuoti.


Skaitmeninių filtrų trūkumas tas, kad jiems reikia greito skaitmeninių duomenų apdorojimo procesoriaus. Kitaip tariant, skaitmeninio filtravimo būdu sunku pasiekti analoginio filtravimo greitį.

Filtruojant ECG ir GSR signalus puikiai tinka branduolinis glodinimas su Gauso pasiskirstymo funkcijos branduoliu, kuris R statistinio paketo aplinkoje yra realizuotas *ksmooth* funkcija. GSR skaitmeninių duomenų filtravimo rezultatas pateiktas 19 pav.




19 pav. GSR signalo filtravimas naudojant branduolinį glodinimą. a) nefiltruoti duomenys, b) filtruoti duomenys

Kaip matome, šis metodas idealiai pašalina nereikalingą triukšmą. Analogiškai, 20 pav. pateikti apdoroti ECG duomenys, naudojant branduolinį glodinimą.



20 pav. ECG signalo filtravimas naudojant branduolinį glodinimą. a) nefiltruoti duomenys, b) filtruoti duomenys

ECG signalo tyrimo dalį sudaro HRV skaičiavimas, naudojant *PhysioNet* ECG signalų duomenų bazes. HRV apskaičiuoti naudojama spektrinė analizė. Žemiau pateiktas HRV spektras, naudojant AR metodą, gaunamas aiškiai išskirtas spektras – 0,2214 Hz, kuris priklauso aukštam HRV dažnių spektrui (21 pav.).

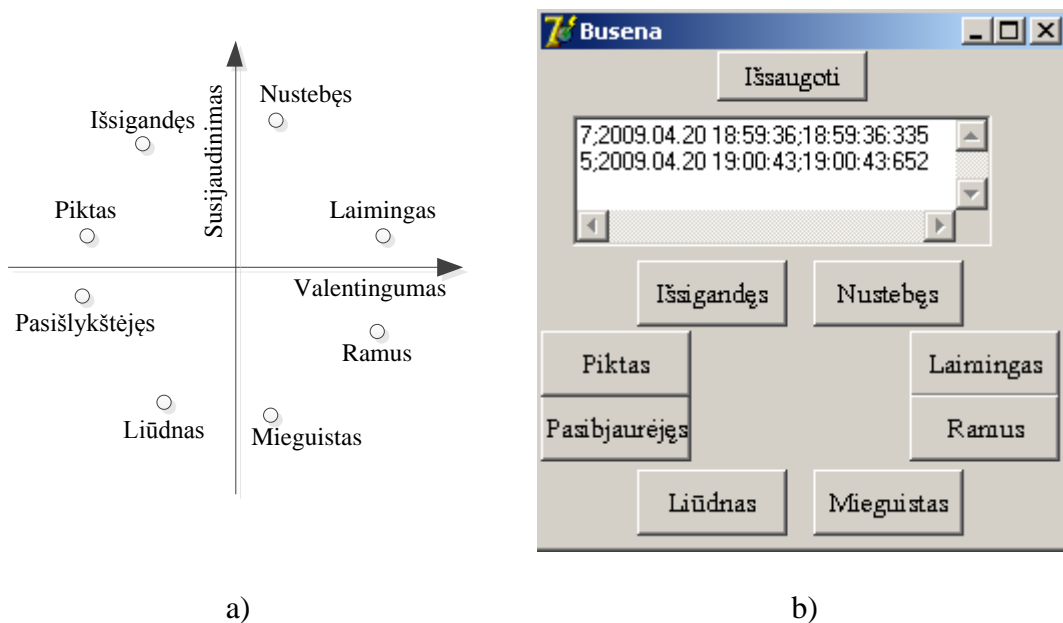


21 pav. Širdies ritmo variabilumo spektrinė analizė, naudojant AR metodą

HRV spektrinės analizės metu išskirtą spektro reikšmę (netransformuojant į aukšto ar žemo HRV dažnio spektrus) galima panaudoti kaip fiziologinį parametą afektui įvertinti.


4.3.1. GSR tyrimas

Šio fiziologinio signalo tyrimo duomenų kaupimas buvo atliekamas naudojant GSR matuoklį, realizuotą pagal 2 pav. pateiktą schemą. Kadangi GSR požymių klasifikavimui naudojamas prižiūrimasis mokymas, tai mokymo ir testavimo duomenys privalo turėti klasę nusakantį atributą. Būsenų aibė sudaroma pagal Russell pasiūlytą susijaudinimo – valentingumo aibę (22 pav.). Buvo sukurta programa, kuri į duomenų bazę užfiksuoja emocinę būseną atitinkančią klasę bei tikslų sisteminių laiką (22 pav.).



22 pav. a) emocinių būsenų erdvė pagal (Russell, 1980), b) emocinių būsenų fiksavimo įrankis

Taigi GSR skaitmeniniai duomenys išfiltruojami naudojant branduolinią glodinimą bei uždedama stimulo informacija. Gautas rezultatas pateiktas (23 pav.). Vertikalios punktyrinės linijos rodo stimulo padėtį laiko atžvilgiu.



23 pav. GSR duomenys su pažymėtais stimulais. a) nefiltruoti duomenys, b) filtruoti duomenys

4.3.2. „Mokytojo triukšmo“ šalinimas panaudojant SOM

Fiksuojant diskrečias būsenas neišvengiamai susiduriama su „mokytojo triukšmu“. Šis reiškinys atsiranda dėl sužymėjimo klaidų – kai mokymo egzemplioriui priskiriama klaidinga klasė (Alpaydin, 2004). Konkrečiai šiuo atveju būna sunku įvertinti realią emocinę būseną dėl jų persidengiamumo. Pavyzdžiui, sunku pasirinkti, kurioje būsenoje esama – ar labiau ramus, ar mieguistas, ar ramus, ar liūdnas ir pan. Šiai problemai spręsti naudojamas SOM, kuris, iš naujo sudarydamas duomenų imties klasterius, turėtų pašalinti sužymėjimo klaidas („mokytojo triukšmą“).


Taigi SOM tinklui mokyti bus naudojamas neprižiūrimas mokymas, kuris duomenų imtyje ieško natūralių panašumų. Šiuo atveju, SOM'as R^4 erdvės įėjimo duomenis paskirsto į dvimatį neuronų masyvą. Kiekvienas neuronas turi taip pat keturmatį savo svorių vektorių.

24 pav. pavaizduotas 10x10 neuronų SOM tinklas, kurio kiekvienas neuronas turi keturmatį svorių vektorių, atitinkantį 4 GSR požymius. Paveiksle pavaizduoti skaičiai nusako mokymo imties egzempliorių klasę, o skirtingos spalvos rodo, kaip tinklas suskirstė klases pagal panašumą.



24 pav. Fiziologinių parametų klasterizavimas naudojant SOM

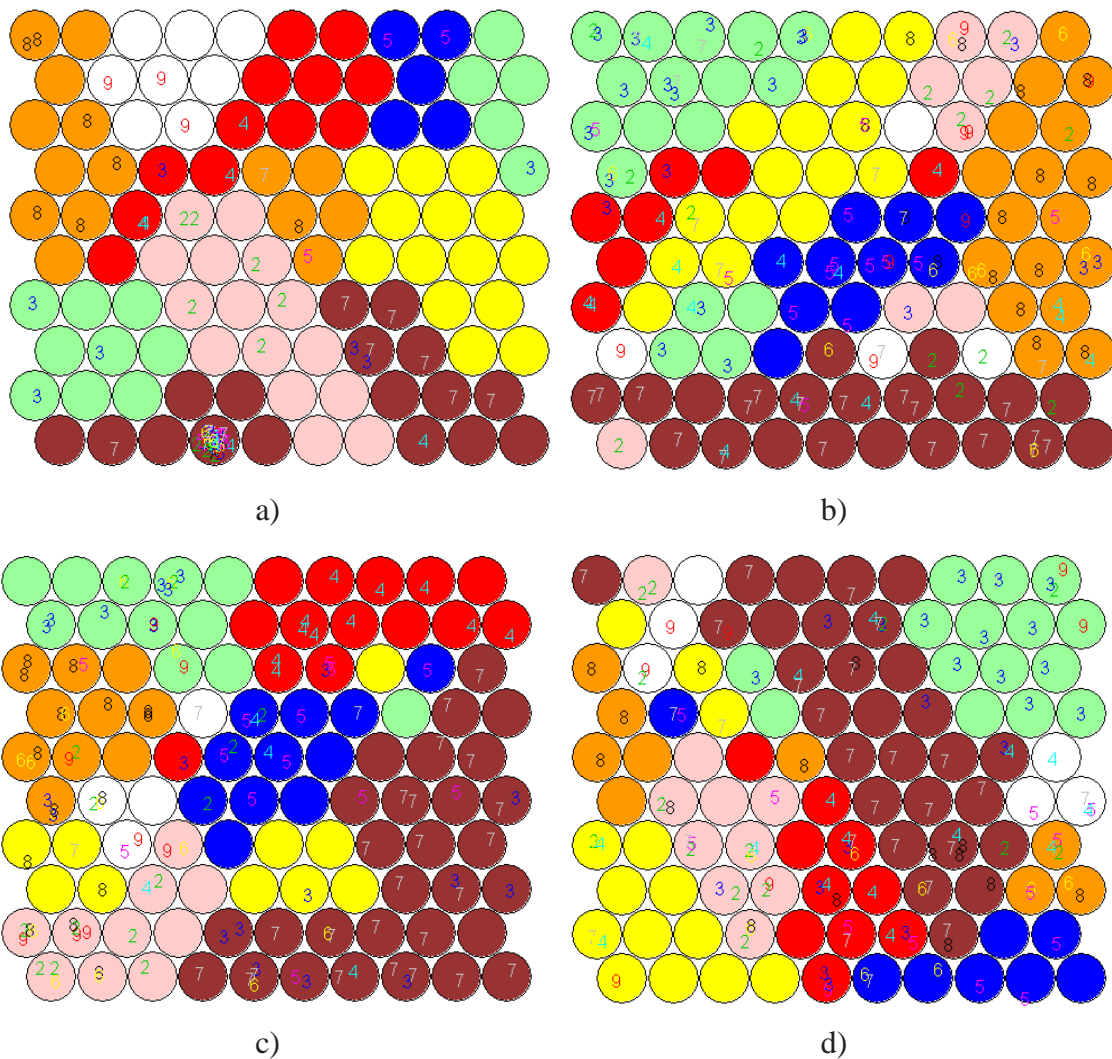
Tinklo mokymosi progresas pavaizduotas 25 pav. Kaip žinoma, SOM'o neuronai yra sugrupuojami pagal panašumą (atstumą), todėl mokymas kiekvienoje iteracijoje matuojamas vidutiniu atstumu iki artimiausio neurono.



25 pav. SOM mokymo proceso įvertinimas

Klasterizavimo tikslumas, lyginant su mokymo imtimi, gali būti įvertintas pagal (1) formulę.

Taigi šiuo atveju, klasterizavimo tikslumas yra 75.00%. Galima daryti išvadą, kad skirtingų emocinių būsenų parametrų klasės pakankamai skiriasi, kad būtų galima atlikti emocinių būsenų klasifikavimą. Kad būtų galima sužinoti, kuris GSR požymis labiausiai turi įtakos tokiam klasterių suskirstymui, atliktas klasterizavimas pagal kiekvieną požymį. Rezultatas pateiktas 26 pav.



26 pav. Fiziologinių parametų klasterizavimas, naudojant SOM pagal kiekvieną požymį: a) uždelstumą (Lat.), b) pakilimo laiką (RT), c) amplitudę (A), d) hrt

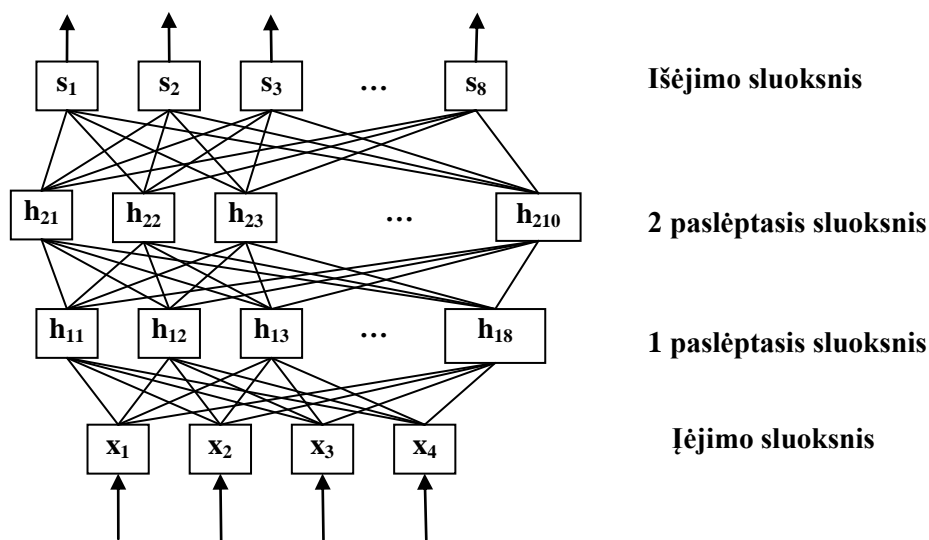
Klasterizavimo tikslumas pagal Lat, RT, A ir HRT atitinkamai yra: 44.70%, 52.27%, 52.27% ir 48.48%. Taigi RT ir A labiausiai koreliuoja su emocinėmis būsenomis, o mažiausiai įtakos turi Lat parametras. Kita vertus, tik apjungus visus keturis fiziologinius parametrus gaunamas pakankamai aukštas tikslumo įvertinimas – 75,00%.

4.3.3. Fiziologinių parametų klasifikavimas

Fiziologinių parametų klasifikavimui į emocinių būsenų erdvę naudojamas daugiasluoksnis perceptronas. Įėjimo sluoksnį sudaro 4 neuronai, atitinkantys 4 GSR požymius, o išėjimo sluoksnyje 8 neuronai, atitinkantys 8

diskrečias emocines būsenas. Eksperimentiškai lieka nustatyti paslėptų sluoksnių ir juose esančių neuronų skaičių.


Mokymo imčiai sudaryti naudojama 60% visos duomenų imties. Iš likusių 40% sudaroma testavimo imtis. Šiuo atveju, sparčiausiai neuroninio tinklo mokymas vyko su dviem paslėptais sluoksniais, atitinkamai su 8 ir 10 neuronų pirmajame ir antrajame sluoksniuose (27 pav.). Paslėptųjų sluoksnių neuronų perėjimo funkcija buvo naudojama tangentinė sigmoidinė, o išėjimo sluoksnyje – sigmoidinė.



27 pav. Daugiasluoksnių perceptrono topologija afekto atpažinimui

MLP mokymas atliktas dviem būdais – naudojant mokymo imtį, sudarytą iš SOM apdorotų duomenų ir naudojant su SOM neapdorotus duomenis. Testavimo imtis abiem atvejais naudojama neapdorota su SOM.

28 pav. pavaizduotas paklaidos mažėjimas kiekvienoje mokymo iteracijoje. Paryškinta linija žymi MLP mokymą, naudojant su SOM apdorotą mokymo imtį, o plonoji linija – naudojant neapdorotus mokymo duomenis.




28 pav. Daugiasluksnio perceptrono mokymosi progresas atskirais atvejais

Akivaizdžiai matoma, jog pašalinus „mokytojo triukšmą“, mokymas vyksta daug greičiau. Norint išsiaiškinti, kaip pasikeis (ar iš vis pasikeis) klasifikavimas, atliktas testavimas. Naudojant mokymą su apdorotais duomenimis klasifikavimo tikslumas lygus $35.78 \pm 1.91\%$. Antruoju atveju $32.11 \pm 8.07\%$. Taigi ir pagal klasifikavimo tikslumo kriterijų „mokytojo triukšmo“ šalinimas buvo naudingas.

4.4. Paskatos funkcija išreikšto afekto vertinimo tyrimas

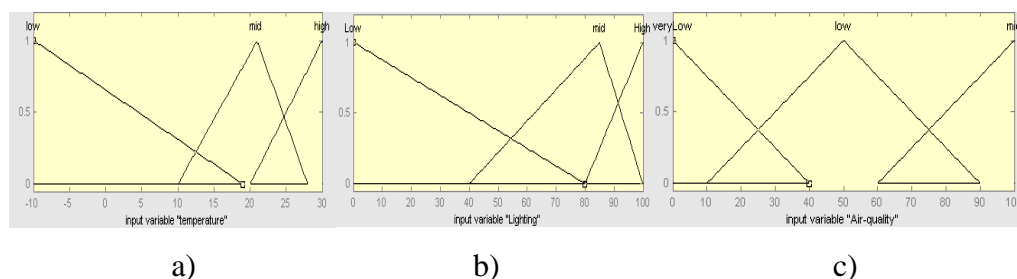
Kaip buvo minėta 3 skyriuje, tam tikrų paslaugų gerinimo algoritmo paskatos funkcija gali būti išreikšta afekto įverčiu. Šiuo atveju paslaugą atitiks mikroklimato reguliavimas t.y., apšvietimo, šildymo, oro kokybės parametru keitimas. Remiantis Russell emocinės būsenos vertinimo modeliu, galima teigti, jog maksimalus komfortas pasiekiamas, kai susijaudinimo vertė artima 0, o valentingumo vertė artima 1. Darant prielaidą, jog maksimalų patalpos komfortą sukuria oro temperatūra 22°C , apšvietimo intensyvumas 95%, oro kokybė 90%, galima sudaryti funkciją, kuri atvaizduotų patalpos mikroklimato parametru reikšmes į dvimatį afekto įvertį – susijaudinimo ir valentingumo

laipsnį. Kadangi afekto įverčiams neįmanoma nustatyti griežtų ribų, funkcijai sudaryti pasinaudotas neraiškiųjų skaičių metodas, įgyvendinant Matlab Fuzzy Logic Toolbox paketu. Bendra afekto neraiškiosios išvedimo sistemos architektūra pateikta 29 pav., kur sistemos įvestis atitinka temperatūros, apšvietumo ir oro kokybės parametrus, o išvestis – susijaudinimo (Arousal) ir valentingumo (Valence) įverčius.




29 pav. Neraiškioji susijaudinimo ir valentingumo išvedimo sistema

Kadangi neraiškioji išvedimo sistema operuoja lingvistiniais kintamaisiais, tai skaitinių reikšmių transformavimas atliekamas pagal 30 pav. pateiktas neraiškiasias funkcijas.



30 pav. Afekto neraiškiosios išvedimo sistemos įvesties lingvistinių kintamųjų funkcijos: a) temperatūros, b) apšvietimo, c) oro kokybės

Analogiškai išvesties lingvistinių kintamųjų transformavimas į skaitines reikšmes atliekamas pagal 31 pav. pateiktas lingvistinių kintamųjų funkcijas.




31 pav. Susijaudinimo ir valentingumo neraiškiosios išvedimo sistemos išvesties lingvistinių kintamųjų funkcijos: a) susijaudinimo (Arousal), b) valentingumo (Valence)

Susijaudinimo ir valentingumo neraiškiosios sistemos išvedimas pagrįstas taisyklių baze. Kadangi kiekvieną įvesties kintamąjį sudaro trys lingvistiniai kintamieji, tai, norint apimti visą įvesties lingvistinių kintamųjų aibę, būtina sudaryti 27 taisykles (32 pav.). Taisyklės sudaromos ekspertiniu būdu, kad bet kuri temperatūros, apšviestumo ir oro kokybės reikšmė būtų atvaizduota į atitinkamą valentingumo ir susijaudinimo sritį, nusakančią afekto vertę.

1. If (Temperature is Low) and (Lighting is Low) and (Air-quality is VeryLow) then (Arousal is Low)(Valence is Low)
2. If (Temperature is Low) and (Lighting is Low) and (Air-quality is Low) then (Arousal is Low)(Valence is Low)
3. If (Temperature is Low) and (Lighting is Low) and (Air-quality is Mid) then (Arousal is Low)(Valence is Low)
4. If (Temperature is Low) and (Lighting is Mid) and (Air-quality is VeryLow) then (Arousal is Mid)(Valence is Low)
5. If (Temperature is Low) and (Lighting is Mid) and (Air-quality is Low) then (Arousal is Mid)(Valence is Low)
6. If (Temperature is Low) and (Lighting is Mid) and (Air-quality is Mid) then (Arousal is Mid)(Valence is Mid)
7. If (Temperature is Low) and (Lighting is High) and (Air-quality is VeryLow) then (Arousal is High)(Valence is Low)
8. If (Temperature is Low) and (Lighting is High) and (Air-quality is Low) then (Arousal is High)(Valence is Low)
9. If (Temperature is Low) and (Lighting is High) and (Air-quality is Mid) then (Arousal is High)(Valence is Mid)
10. If (Temperature is Mid) and (Lighting is Low) and (Air-quality is VeryLow) then (Arousal is Low)(Valence is Low)
11. If (Temperature is Mid) and (Lighting is Low) and (Air-quality is Low) then (Arousal is Low)(Valence is Mid)
12. If (Temperature is Mid) and (Lighting is Low) and (Air-quality is Mid) then (Arousal is Mid)(Valence is Mid)
13. If (Temperature is Mid) and (Lighting is Mid) and (Air-quality is VeryLow) then (Arousal is Mid)(Valence is Low)
14. If (Temperature is Mid) and (Lighting is Mid) and (Air-quality is Low) then (Arousal is Mid)(Valence is Mid)
15. If (Temperature is Mid) and (Lighting is Mid) and (Air-quality is Mid) then (Arousal is Mid)(Valence is High)
16. If (Temperature is Mid) and (Lighting is High) and (Air-quality is VeryLow) then (Arousal is Mid)(Valence is Low)
17. If (Temperature is Mid) and (Lighting is High) and (Air-quality is Low) then (Arousal is Mid)(Valence is Mid)
18. If (Temperature is Mid) and (Lighting is High) and (Air-quality is Mid) then (Arousal is High)(Valence is High)
19. If (Temperature is High) and (Lighting is Low) and (Air-quality is VeryLow) then (Arousal is Low)(Valence is Low)
20. If (Temperature is High) and (Lighting is Low) and (Air-quality is Low) then (Arousal is Low)(Valence is Low)
21. If (Temperature is High) and (Lighting is Low) and (Air-quality is Mid) then (Arousal is Low)(Valence is Low)
22. If (Temperature is High) and (Lighting is Mid) and (Air-quality is VeryLow) then (Arousal is High)(Valence is Low)
23. If (Temperature is High) and (Lighting is Mid) and (Air-quality is Low) then (Arousal is High)(Valence is Low)
24. If (Temperature is High) and (Lighting is Mid) and (Air-quality is Mid) then (Arousal is High)(Valence is High)
25. If (Temperature is High) and (Lighting is High) and (Air-quality is VeryLow) then (Arousal is High)(Valence is Low)
26. If (Temperature is High) and (Lighting is High) and (Air-quality is Low) then (Arousal is High)(Valence is Low)
27. If (Temperature is High) and (Lighting is High) and (Air-quality is Mid) then (Arousal is High)(Valence is High)


32 pav. Afekto neraiškiosios išvedimo sistemos taisyklių bazė

Žemiau pateiktas sudarytos funkcijos dalinis atvaizdavimas trimatėje erdvėje (kadangi yra trys argumentai ir dvi funkcijos reikšmės, funkcija atvaizduojama atskiromis funkcijomis su dviem argumentais ir viena funkcijos reikšme)




a)

b)



c)

d)



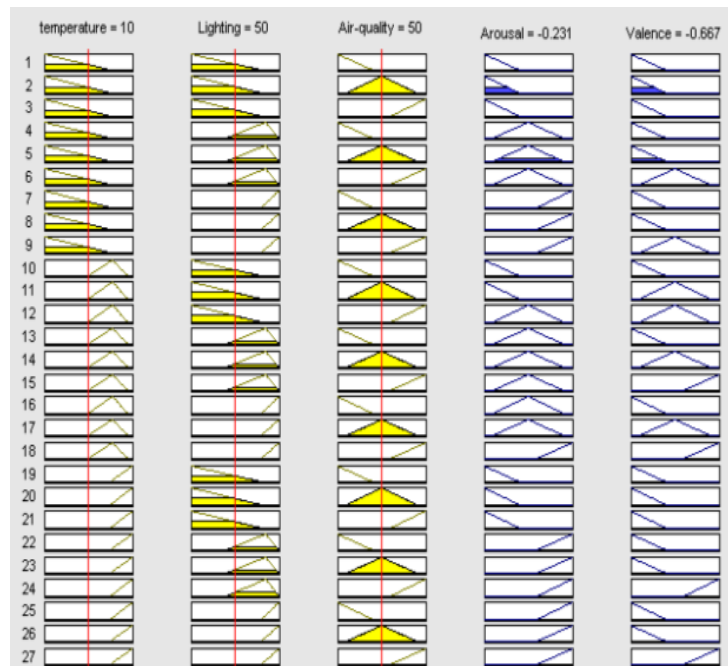
e)

f)

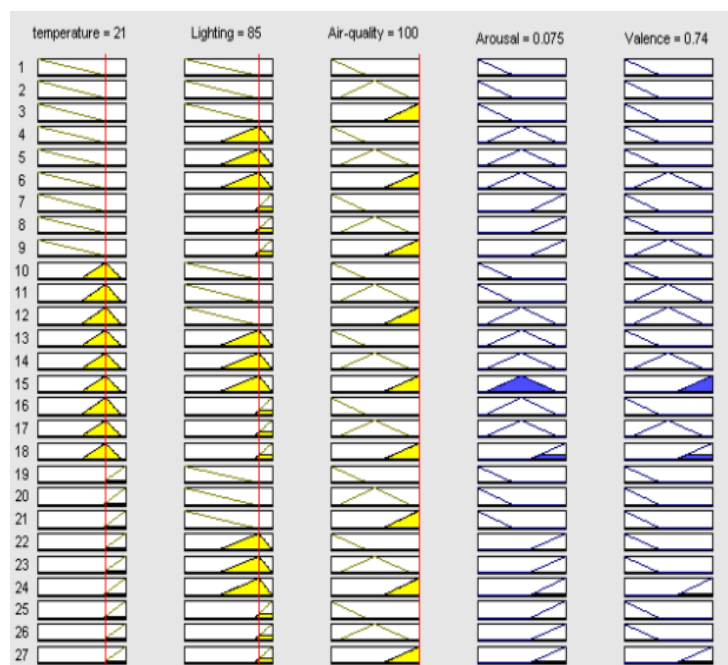
33 pav. Afekto atvaizdavimo funkcijos: a) susijaudinimo priklausomybė nuo apšvietimo ir temperatūros, b) susijaudinimo priklausomybė nuo oro kokybės ir temperatūros, c) susijaudinimo priklausomybė nuo oro kokybės ir apšvietimo, d) valentingumo priklausomybė nuo oro kokybės ir apšvietimo, e) valentingumo priklausomybė nuo oro kokybės ir temperatūros, f) valentingumo priklausomybė nuo apšvietimo ir temperatūros

Pagal pateiktus grafikus galima matyti, jog afekto įverčiuose susijaudinimas artimas 0 ir valentingumas artimas 1 tik tokiu atveju, kai aplinkos parametrų reikšmės artimos atitinkamiems dydžiams: oro temperatūra 22°C, apšvietimo intensyvumas 85%, oro kokybė 95%. Tai patvirtina ir taisyklių aktyvavimo testavimas (34 pav., 35 pav.). Vertinant žemą aplinkos komforto laipsnį (temperatūra = 10°C, apšvietimo intensyvumas = 50%, oro kokybė = 50%), susijaudinimas=-0,231, valentingumas = -0,667. Pagal Russell emocinių būsenų modelį tai atitinka apytiksliai liūdną emocinę būseną. Vertinant aukštą aplinkos komforto laipsnį (temperatūra = 21°C, apšvietimo

intensyvumas = 85%, oro kokybė = 100%), susijaudinimas=0,075, valentingumas = 0,74. Pagal Russell emocinių būsenų modelį tai atitinka apytiksliai laimingą emocinę būseną.



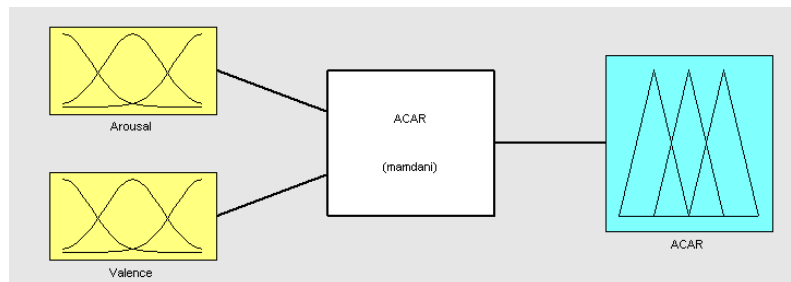
34 pav. Afekto išvedimo sistemos taisyklių aktyvacija, kai vertinamas žemas aplinkos komforto laipsnis



35 pav. Afekto išvedimo sistemos taisyklių aktyvacija, kai vertinamas aukštas aplinkos komforto laipsnis

4.4.1. ACAR funkcijos tyrimas

Kadangi bus tiriamas komforto adaptavimas pagal afekto vertinimą, naudojant $TD(\lambda)$ skatinamojo mokymosi algoritmą, būtina sudaryti funkciją, kuri transformuotų afekto įvertį iš susijaudinimo ir valentingumo į atitinkamą kiekybinę paskato vertę – ACAR indeksą. Šiuo atveju taip pat naudojama neraiškioji ACAR indekso išvedimo sistema, kurios bendra architektūra pateikta 36 pav.




36 pav. Neraiškioji ACAR indekso išvedimo sistema

ACAR indekso neraiškiosios sistemos išvedimas pagrįstas taisyklių baze. Kadangi kiekvieną įvesties kintamąjį sudaro penki lingvistiniai kintamieji, tai norint apimti visą įvesties lingvistinių kintamųjų aibę, būtina sudaryti 25 taisykles (37 pav.). Taisyklės sudaromos ekspertiniu būdu, kad bet kuri susijaudinimo ir valentingumo reikšmė būtų atvaizduota į afekto kiekybinę vertę nusakančią ACAR indekso reikšmę. Taisyklės sudaromos taip, kad „laimingą“ emocinę būseną (kai susijaudinimas artimas 0, o valentingumas artimas 1) atitiktų ACAR indeksas, artimas 0.

1. If (Arousal is VeryLow) and (Valence is VeryLow) then (ACAR is VeryLow)
2. If (Arousal is VeryLow) and (Valence is Low) then (ACAR is VeryLow)
3. If (Arousal is VeryLow) and (Valence is Neutral) then (ACAR is Low)
4. If (Arousal is VeryLow) and (Valence is High) then (ACAR is Low)
5. If (Arousal is VeryLow) and (Valence is VeryHigh) then (ACAR is Low)
6. If (Arousal is Low) and (Valence is VeryLow) then (ACAR is VeryLow)
7. If (Arousal is Low) and (Valence is Low) then (ACAR is VeryLow)
8. If (Arousal is Low) and (Valence is Neutral) then (ACAR is Low)
9. If (Arousal is Low) and (Valence is High) then (ACAR is Low)
10. If (Arousal is Low) and (Valence is VeryHigh) then (ACAR is Low)
11. If (Arousal is Neutral) and (Valence is VeryLow) then (ACAR is VeryLow)
12. If (Arousal is Neutral) and (Valence is Low) then (ACAR is Low)
13. If (Arousal is Neutral) and (Valence is Neutral) then (ACAR is Low)
14. If (Arousal is Neutral) and (Valence is High) then (ACAR is Neutral)
15. If (Arousal is Neutral) and (Valence is VeryHigh) then (ACAR is Neutral)
16. If (Arousal is High) and (Valence is VeryLow) then (ACAR is VeryLow)
17. If (Arousal is High) and (Valence is Low) then (ACAR is Low)
18. If (Arousal is High) and (Valence is Neutral) then (ACAR is High)
19. If (Arousal is High) and (Valence is High) then (ACAR is High)
20. If (Arousal is High) and (Valence is VeryHigh) then (ACAR is High)
21. If (Arousal is VeryHigh) and (Valence is VeryLow) then (ACAR is VeryLow)
22. If (Arousal is VeryHigh) and (Valence is Low) then (ACAR is VeryLow)
23. If (Arousal is VeryHigh) and (Valence is Neutral) then (ACAR is High)
24. If (Arousal is VeryHigh) and (Valence is High) then (ACAR is VeryHigh)
25. If (Arousal is VeryHigh) and (Valence is VeryHigh) then (ACAR is VeryHigh)

37 pav. ACAR indekso neraiškiosios išvedimo sistemos taisyklių bazė

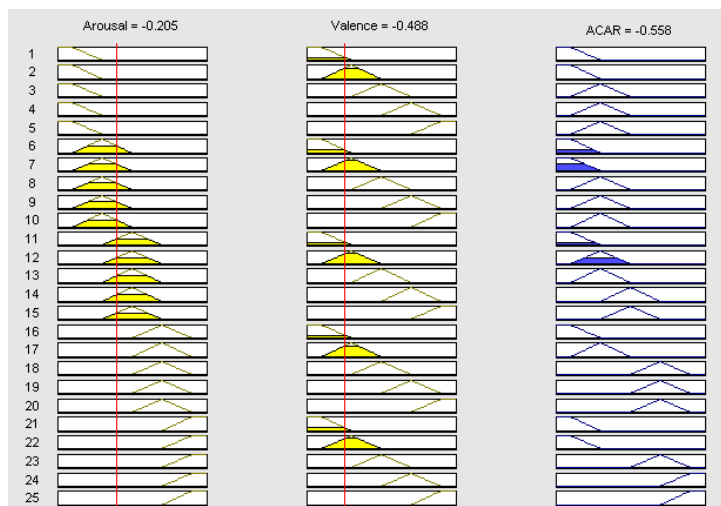
Žemiau pateiktas sudarytos funkcijos atvaizdavimas trimatėje erdvėje (38 pav.).



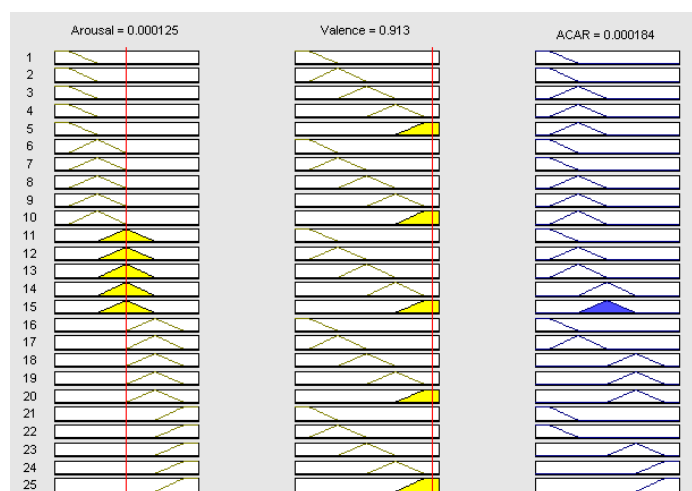
38 pav. ACAR indekso atvaizdavimo funkcija nuo susijaudinimo ir valentingumo

Pagal pateiktą grafiką galima matyti, jog ACAR indeksas artimas 0, kai susijaudinimas artimas 0, o valentingumas artimas 1. Tai patvirtina ir taisyklių aktyvavimo testavimas (39 pav., 40 pav.). Vertinant neigiamą valentingumo ir

neigiamą susijaudinimo laipsnį (susijaudinimas = -0,205, valentingumas = -0,488), ACAR indeksas = -0,558. Vertinant nulinį susijaudinimą ir aukštą teigiamą valentingumą (susijaudinimas = 0,000125, valentingumas = 0,913), ACAR indeksas = 0,000184.



39 pav. ACAR indekso išvedimo sistemos taisyklių aktyvacija, kai vertinamas neigiamas valentingumas ir neigiamas susijaudinimas



40 pav. ACAR indekso išvedimo sistemos taisyklių aktyvacija, kai vertinamas nulinis susijaudinimas (angl. *arousal*) ir aukštas teigiamas valentingumas (angl. *valence*)

4.5. Adaptyvios uždaros aplinkos mikroklimato valdymo sistemos tyrimas

Mikroklimato reguliavimo pagal afekto vertinimą imitacinis modeliavimas atliktas pagal šiuos žingsnius:

1. Fiksuojama pradinė aplinkos mikroklimato būseną (temperatūra, apšviestumas, oro kokybė);
2. Naudojant afekto neraiškiają išvedimo sistemą, apskaičiuojamos valentingumo ir susijaudinimo kiekybinės reikšmės duotai aplinkos būsenai;
3. Naudojant ACAR indekso neraiškiają išvedimo sistemą, apskaičiuojamas ACAR indeksas;
4. Taikomas $TD(\lambda)$ algoritmas ir apskaičiuojamas veiksmas (temperatūros, apšviestumo ir oro kokybės pokyčiai) bei parametru korekcijos;
5. Pritaikomi apskaičiuoti veiksmai bei pakoreguojami veiksmo ir vertės aproksimuojamų funkcijų svoriai;
6. Grįžtama į 2 žingsnį, kol bus pasiektas norimas tikslumas arba fiksuotas iteracijų skaičius.

Detalus mikroklimato reguliavimo pagal afekto vertinimą algoritmo pseudokodas pateiktas 41 pav.

```

Input:  $state_{t=0}$  // pradinė aplinkos būseną
Output: state trace // būsenų seka
          action trace // veiksmų seka
          temporal difference trace // laikinųjų skirtumų seka
          value trace // vertės funkcijos seka
Initialize:  $\Delta reward$  // paskatos pokytis
               $ARVA_{t=0}$  // pradinis susijaudinimo-valentingumo įverčio vektorius
               $ACAR_{t=0}$  // ACAR indeksas pradiniu laiko momentu
              center // RBF centrai
               $\sigma$  // RBF funkcijų pločiai
               $\gamma$  // diskonto faktorius
               $\lambda$  // nykimo faktorius
               $e_{t=0}=0$  // tinkamumo kelias
               $\alpha$  // mokymosi greitis
               $v$  // RBF neuroninio tinklo aktorius dalies svoriai
               $w$  // RBF neuroninio tinklo kritiko dalies svoriai
FOR each  $t^{th}$  observation DO
  FOR each action DO
    Initialize:  $V_j=0$ 
    FOR each  $j^{th}$  basis function center DO
      
$$\phi_j^{critic} = \exp\left(-\frac{\|state_t - center_j\|^2}{2\sigma_j^2}\right)$$

      
$$V_j = V_j + \phi_j^{critic} \cdot w_j$$

    ENDFOR
    
$$e_{t+1} = \gamma \cdot \lambda \cdot e_t + \phi_j^{critic}$$

    
$$\delta_t = ACAR_{t+1} + V_{j-1} - \gamma \cdot V_j$$
 // laikinasis skirtumas
    FOR each basis function center  $j$  DO
      
$$w_j = w_j + \alpha \cdot \delta_t \cdot e_{t+1} \cdot \Delta reward$$

    ENDFOR
    Initialize:  $action_t=0$ 
    FOR each basis function center  $j$  DO
      
$$v_j = v_j + \alpha \cdot \delta_t \cdot e_{t+1} \cdot \Delta reward$$

      
$$\phi_j^{actor} = \exp\left(-\frac{\|state_t - center_j\|^2}{2\sigma_j^2}\right)$$

      
$$action_t = action_t + \phi_j^{actor} \cdot v_j;$$

    ENDFOR
    get new state:  $state_{t+1} = state_t + action_t$ 
    simulate Arousal Valence:  $ARVA_{t+1} = FIS(state_{t+1})$ 
    // FIS – Neraiškioji išvedimo sistema (Fuzzy Inference System)
    
$$ACAR_{t+1} = FIS(ARVA_{t+1});$$

    
$$\Delta Reward = ACAR_{t+1} - ACAR_t$$

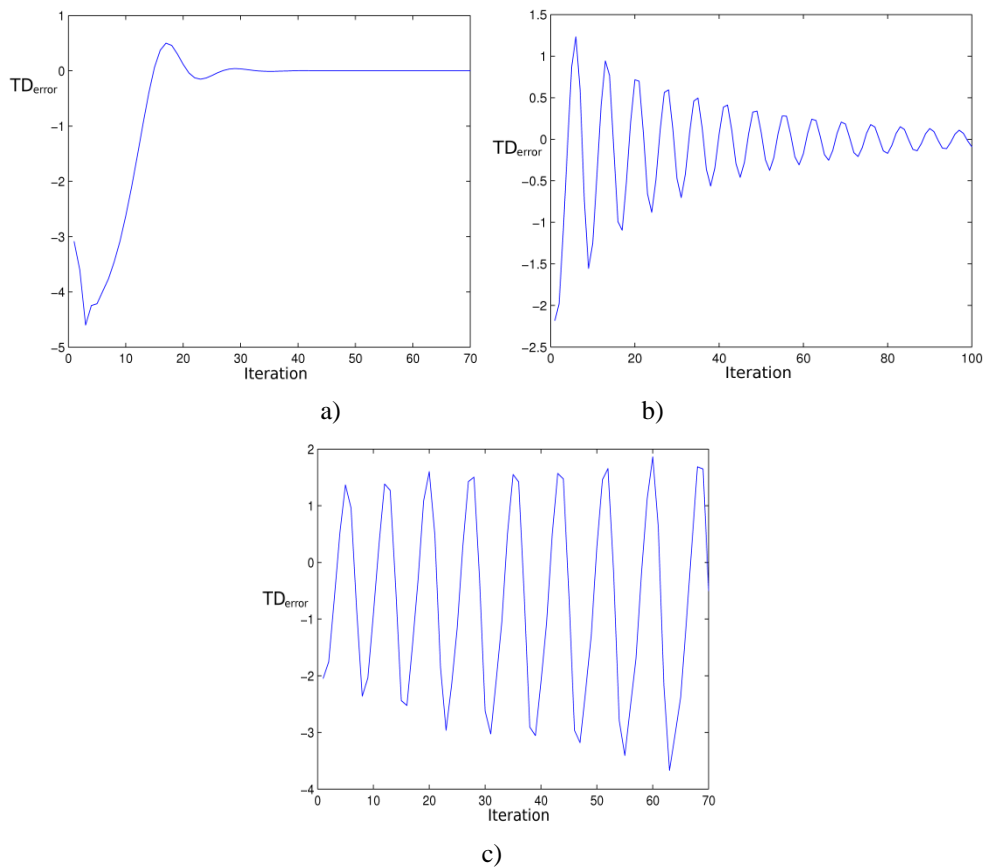
  ENDFOR
ENDFOR

```

41 pav. Aplinkos mikroklimato reguliavimo algoritmo pseudokodas


Pagrindinė charakteristika, kuri leidžia įvertinti mikroklimato reguliavimo sistemos stabilumą – tai laikinių skirtumų dinamika. Jos pokytis tiesiogiai proporcingas valdymo signalui, todėl laikinių skirtumų konvergavimas į 0 per baigtinį laiko intervalą reiškia, jog valdymo sistema yra stabili.

Eksperimento metu atitinkami imitacinio modelio parametrai (γ , λ , α) buvo keičiami. Priklausomai nuo to buvo gauti skirtingi rezultatai (42 pav.).



42 pav. Laikinių skirtumų (TDerror) dinamika naudojant atitinkamus reguliatoriaus parametrus: a) $\gamma=0.8$, $\lambda=0.5$, $\alpha=0.2$; b) $\gamma=0.8$, $\lambda=0.5$, $\alpha=0.01$; c) $\gamma=0.9$, $\lambda=0.9$, $\alpha=0.02$

Analogiškai, vertinant adaptyvios sistemos gebėjimą sureguliuoti aplinkos temperatūrą, apšviestumą ir oro kokybę, gauti rezultatai pateikti (43 pav.)



43 pav. Uždaros aplinkos charakteristikų dinamika naudojant atitinkamus reguliatoriaus parametrus: a) $\gamma=0.95$, $\lambda=0.9$, $\alpha=0.5$; b) $\gamma=0.8$, $\lambda=0.5$, $\alpha=0.2$

Adaptvyvi valdymo sistema negali tinkamai funkcionuoti, kol nėra surinkta pakankamai žinių apie valdomą sistemą, todėl, priklausomai nuo pradinių sąlygų, kai vyksta sistemos apmokymas, parenkami netikslūs veiksmai. Šis reiškinys matomas 43 pav. a. pradinėse iteracijose, kada agentas, tyrinėdamas aplinką, parenka veiksmus, kol suranda tinkamiausią strategiją pasiekti optimalius komforto parametrus.

4.6. Ketvirtojo skyriaus išvados

Siekiant kiekybiškai įvertinti afektą, naudojant fiziologinius parametrus buvo sukurtas ir išbandytas sistemos prototipo modelis, gebantis nuskaityti fiziologinius signalus, kaupti diskretizuotų signalų duomenis, iš jų išskirti fiziologinius parametrus bei juos interpretuoti.

Sudarant daugiasluoksnio perceptrono mokymo imtį neišvengta klasės atributo sužymėjimo klaidų. Tyrimas parodė, jog pašalinus „mokytojo triukšmą“ iš mokymo imties, daugiasluoksnio perceptrono mokymas vyksta sparčiau, be to, padidėja klasifikavimo tikslumas.

Remiantis afekto vertinimo principais buvo sudaryta ekspertinė afekto įverčio funkcija, kuri leidžia realizuoti adaptyvios sistemos grįžtamojo ryšio grandinę.

Eksperimentiniai imitacinio modeliavimo rezultatai parodė, jog naudojant aktorius-kritiko skatinamojo mokymosi modelį bei afekto įverčio funkciją, buvo pasiekti optimalūs apšvietimo, temperatūros ir oro kokybės parametrai, pagal toje aplinkoje esančio žmogaus afekto vertinimą

Bendrosios išvados

1. Remiantis atlikta pasaulio mokslinių darbų analize afekto atpažinimo srityje bei afekto atpažinimo metodų lyginamąja analize, galima teigti, jog kompiuteriniai afekto atpažinimo metodai pakankamai tiksliai leidžia įvertinti žmogaus reakciją į aplinkos pokyčius, todėl kaip tam tikros konstrukcijos gali būti naudojamos kuriant adaptyvių paslaugų (pavyzdžiui, aplinkos komforto adaptavimo) valdymo pagal vartotojų poreikius sistemas.

2. Siekiant padidinti afekto atpažinimo tikslumą, pasiūlytas fiziologinių žmogaus parametrų klasterizavimo, naudojant SOM, ir klasifikavimo, naudojant MLP, metodų apjungimas. Šis sprendimas leidžia panaikinti mokymo imties sužymėjimo klaidas ir taip padidinti klasifikavimo tikslumą, sprendžiant įvairaus pobūdžio uždavinius, kai apsimokančiose sistemose yra taikomi prižiūrimo mokymosi algoritmai.

3. Analizuojant afekto atpažinimo metodus ir adaptyvaus valdymo principus pastebėta, jog kiekybinis afekto įvertinimas leidžia sukurti uždaros aplinkos automatinės mikroklimato valdymo sistemos grįžtamąjį ryšį. Šis principas leido sukurti naują uždaros aplinkos mikroklimato valdymo metodą, išsiskiriantį tuo, jog žmogus dalyvauja sistemoje kaip aplinkos komforto jutiklis, kurio afekto įvertis leidžia nustatyti aplinkos komforto parametrų tinkamumą tam žmogui. Tai vienas naujausių afekto atpažinimo metodų pritaikymas, kuriant adaptyvias, prie žmogaus poreikių prisitaikančias paslaugas.

4. Uždaros aplinkos mikroklimato valdymo sistemos aprašymas yra pakankamai sudėtingas, apimantis daugiakriterinį aplinkos parametrų valdymą bei žmogaus fiziologinių būsenų nagrinėjimą. Aktoriaus-kritiko skatinamojo mašininio mokymo metodo, kuris geba išgauti trūkstamas žinias apie sistemą jos veikimo metu, taikymas leido realizuoti adaptyvią uždaros aplinkos

mikroklimato reguliavimo sistemą. Skirtingai negu šiuo metu siūlomų mikroklimato reguliavimo sistemų, pasiūlytas metodas, priklausomai nuo konteksto, leidžia adaptuoti vartotojui teikiamas paslaugas dinaminio pobūdžio dalykinėse srityse.

5. Eksperimentinis uždaros aplinkos mikroklimato valdymo sistemos tyrimas parodė, jog galima pasiekti optimalius apšvietimo, temperatūros ir oro kokybės parametrus pagal toje aplinkoje esančio žmogaus afekto vertinimą. Tai parodo, jog žmogaus afekto vertinimo metodų integracija su skatinamojo mokymosi metodais užtikrina efektyvų adaptyvių paslaugų uždaros aplinkos mikroklimato valdymo sistemoje išvystymą.

Literatūros sąrašas

- Alpaydin, E. (2004). *Introduction to Machine Learning (Adaptive Computation and Machine Learning)*. The MIT Press, Cambridge, Massachusetts, London, England.
- Analog Devices (2003). *Mixed – Signal and MLP Design Techniques*. Library of Congress Cataloging – in Publication Data.
- ASHRAE (1999). *ANSI/AHRAE Standard 62-1999, Ventilation for Acceptable Indoor Air Quality*. ASHRAE, Atlanta, Georgia.
- ASHRAE (2005). *Handbook – Fundamentals*. American Society of Heating
- Bielskis, A.A., Denisovas, V., Drungilas, D., Gričius, G., Ramašauskas, O. (2008). Modeling of Intelligent Multi-Agent based E-health Care System for People with Movement Disabilities. *Elektronika ir elektrotechnika*, Kaunas, Technologija, 86(6), pp. 37-42.
- Bielskis, A.A., Dzemydienė, D., Denisov, V., Andziulis, A., Drungilas, D. (2009). An Approach Of Multi-Agent Control Of Bio-Robots Using Intelligent Recognition Diagnosis Of Persons With Moving Disabilities. *Technological And Economic Development Of Economy*, 15(3), pp. 377-394.
- Bielskis, A.A., Denisovas, V., Drungilas, D., Gričius, G., Dzemydienė, D. (2010). Multi-Agent-Based Human Computer Interaction of E-Health Care System for People with Movement Disabilities. *Elektronika ir elektrotechnika*, (7), pp. 77-82.
- Bielskis, A.A., Dzemydienė, D., Drungilas, D., Gričius, G., Goročovik, A., Gadliauskaitė, R. (2011). Afekto atpažinimo metodų lyginamoji analizė. *XV kompiuterininkų konferencijos mokslo darbai*, Žara, pp. 19-32.
- Bielskis, A.A., Guseinovicė, E., Dzemydienė, D., Drungilas, D., Gričius, G. (2012). Ambient Lighting Controller Based on Reinforcement Learning

- Components of Multi-Agents. *Electronics and Electrical Engineering*, Kaunas, Technologija, 121(5), pp. 79-84.
- Chanel G., Kierkels J. J. M., Soleymani M., Pun T. (2009) Short-term emotion assessment in a recall paradigm. *International Journal of Human Computer Studies*, pp. 607–627.
- Canento, F., Fred, A., Silva, H., Gamboa, H., Lourenco, A. (2011). Multimodal Biosignal Sensor Data Handling for Emotion Recognition. *IEEE SENSORS Proceedings*, pp. 647–650.
- Castellano, G., Leite, I., Pereira, A., Martinho, C., Paiva, A., McOwan, P.W. (2010). Affect Recognition for Interactive Companions: Challenges and Design in Real-World Scenarios. *Journal on Multimodal User Interfaces*, 3(1-2), pp. 89–98.
- CIBSE (1994). *Code for Interior Lighting*, CIBSE Publications.
- Cowie, R., Douglas-Cowie, E., Tsapatsoulis, N., Votsis, G., Kollias, S., Fellenz, W., Taylor, J. (2001). Emotion Recognition in Human-Computer Interaction. *IEEE Signal Processing Magazine*, 18(1), pp. 32–80.
- Crnkovic, G.D. (2010). Constructive Research and Info-Computational Knowledge Generation. *Model-Based Reasoning in Science and Technology, Studies in Computational Intelligence*, (314), pp. 359-380.
- Dolcos, F., Labar, K.S. Cabeza, R. (2004). Dissociable Effects of Arousal and Valence on Prefrontal Activity Indexing Emotional Evaluation and Subsequent Memory: an Event-Related fMRI Study. *NeuroImage*, (23), pp. 64-74.
- Doya, K., (1996). Temporal Difference Learning in Continuous Time and Space. *Advances in Neural Information Processing Systems*, (8), p.1073-1079.
- Drungilas, D., Bielskis, A.A. (2012). Cloud Interconnected Affect Reward Based Automation Ambient Comfort Controller. *Electronics and Electrical Engineering*, Kaunas, Technologija, 126(10), pp. 49–52.

- Drungilas, D., Bielskis, A.A., Denisov, V., Dzemydienė, D. (2010). Data Mining Approaches for Intelligent E-Social Care Decision Support System. *Artificial Intelligence and Soft Computing, Part I, LNAI*, (6113), Springer, pp. 605-612.
- Drungilas, D., Bielskis, A.A., Denisov, V. (2010). An Intelligent Control System Based on Non-Invasive Man Machine Interaction. *Innovations in Computing Sciences and Software Engineering*, Springer, pp. 63–68.
- Duda R., Hart P., 1973. Pattern Classification and Scene Analysis. *IEEE Transactions on Automatic Control*, IEEE Explore, 19(4), pp. 462 – 463.
- Dzemydienė, D., Bielskis, A.A., Andziulis, A., Drungilas, D., Gričius, G. (2010). Recognition of Human Emotions in Reasoning Algorithms of Wheelchair Type Robots. *Informatica*, 21(4), pp. 521–532.
- Dzemydienė, D., Bielskis, A.A., Andziulis, A., Drungilas, D., Dzindzalieta, R., Gričius, G. (2010). The Reinforcement Framework of a Decision Support System for the Localization and Monitoring of Intelligent Remote Bio Robots. *Proceedings of the 10th International Conference Reliability and Statistics in Transportation and Communication*, October 20-23, Riga, Latvia, pp. 207–217.
- Eyben, F., Wöllmer, M., Poitschke, T., Schuller, B., Blaschke, C., Färber, B., Nguyen-Thien, N. (2010). Emotion on the Road—Necessity, Acceptance, and Feasibility of Affective Computing in the Car. *Advances in Human Computer Interaction 2010*, pp. 1-17. Available at: <http://www.hindawi.com/journals/ahci/2010/263593/>.
- Ekman, P. (1982). *Emotion in the Human Face*, Cambridge University Press, Cambridge, UK.
- Ekman, P. (1992). An Argument for Basic Emotions. *Cognition and Emotion*, 6(3), pp. 169-200.
- Ekman, P. (1994). Moods, Emotions, and Traits. *In The Nature of Emotion: Fundamental Questions*, P. Ekman and R. J. Davidson, Eds., New York: Oxford University Press, pp. 56–58.

- ESNA/ITEA2. (2013). *EU Project European Sensor Network Architecture*, Prieiga: <http://www.sics.se/esna>
- Exalted. (2013). *EU Project Expanding LTE for Devices*. Prieiga: <http://www.ict-exalted.eu/>
- Fanger, P.O. (1982). *Thermal Comfort*, Robert E. Krieger Publishing Company, Malabar, FL.
- Fletcher, R.R., Ming-Zher, P., Eydgahi, H. (2010). Wearable Sensors: Opportunities and Challenges for Low-Cost Health Care. *Engineering in Medicine and Biology Society (EMBC)*, Annual International Conference of the IEEE, pp. 1763–1766.
- Fleureau, J., Penet, C., Guillotel, P., Demarty, C.H. (2012). Electrodermal Activity Applied to Violent Scenes Impact Measurement and User Profiling. *Systems, Man, and Cybernetics (SMC)*, IEEE International Conference, pp. 3310–3315.
- Forest, F., Oehme, A., Yaici, K., Verchere-Morice, C. (2006). Psycho-Social Aspects of Context Awareness in Ambient Intelligent Mobile Systems. *In 15th IST Mobile and Wireless Communication Summit*.
- Fu, K.S. (1986). Learning Control Systems-Review and Outlook. *IEEE transactions on pattern analysis and machine intelligence*, 8(3), pp. 327–342.
- Gockley, R., Simmons, R., Forlizzi, J. (2006). Modeling Affect in Socially Interactive Robots. *Robot and Human Interactive Communication. The 15th IEEE International Symposium*, pp. 558–563.
- Gonzalez, G., De La Rosa, J.L., Dugdale, J., Pavard, B., El Jed, M., Pallamin, N., Angulo, C., Klann, M. (2006). Towards Ambient Recommender Systems: Results of New Cross-Disciplinary Trends. *In Proceedings of ECAI Workshop on Recommender Systems*, pp. 128-133.
- Gonzalez-Sanchez, J., Chavez-Echeagaray, M. E., Atkinson, R., Burleson, W. (2011). ABE: An Agent-Based Software Architecture for a Multimodal Emotion Recognition Framework. *Ninth Working IEEEIFIP Conference*

- on *Software Architecture*, pp. 187–193. Available at: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5959690>
- HYDRA (2010). *The EU Project HYDRA*, Prieiga: <http://www.hydrmiddleware.eu/news.php>
- IoT-A. (2013). *EU FP7 Project Internet-of-Things Architecture*, Prieiga: <http://www.iot-a.eu/public/terminology>.
- Kaelbling, L.P., Littman, M.L. Moore, A. W. (1996). Reinforcement Learning: A Survey. *Journal of Artificial Intelligence Research*, (4), pp. 237-285.
- Kaklauskas, A., Vlasenko, A., Raudonis, V., Zavadskas, E.K., Gudauskas, R., Seniut, M., Juozapaitis, A., Jackute, I., Kanapeckiene, L., Rimkuvienė, S., Kaklauskas, G. (2013). Student Progress Assessment with the Help of an Intelligent Pupil Analysis System. *Engineering Applications of Artificial Intelligence*, 26(1), pp. 35-50.
- Kaklauskas, A., Zavadskas, E.K., Pruskus, V., Vlasenko, A., Bartkiene, L., Paliskiene, R., Zemeckyte, L., Gerstein, V., Dzemyda, G., Tamulevicius, G. (2011). Recommended Biometric Stress Management System. *Expert Systems with Applications*, 40(15), pp. 6150-6165.
- Kaklauskas, A., Zavadskas, E.K., Pruskus, V., Vlasenko, A., Seniut, M., Kaklauskas, G., Matuliauskaite, A., Gribniak, V. (2010). Biometric and Intelligent Self-Assessment of Student Progress system. *Computers & Education*, 55(2), pp. 821-833.
- Kamarauskas, J. (2009). *Asmens atpažinimas pagal balsą*. Daktaro disertacija, Vilnius, Technika, 152 p.
- Kazanavicius, E., Imbrasas, D., Razukas, M., Skersys, T., Butleris, R., Nemuraite, L., Suomi, R. (2011). Service Provisioning Framework for Digital Smart Home Services. In T. Skersys, R. Butleris, L. Nemuraite, & R. Suomi (Eds.), *Building the e-World Ecosystem*, (353), pp. 99–109.
- Kazanavicius, E., Kazanavicius, V., Ostaseviciute, L. (2009). Agent-Based Framework For Embedded Systems Development In Smart

- Environments. In *Targamadze, R (Eds.), Information Technologies' 2009*, pp. 194–200.
- Kim, K.H., Bang, S.W., Kim, S.R. (2004). Emotion Recognition System Using Short-Term Monitoring of Physiological Signals. *Medical Biological Engin. Comput.*, (42), pp. 419–427.
- Lewis, F., Vrabie, D. (2009). Reinforcement Learning and Adaptive Dynamic Programming for Feedback Control. *Circuits and Systems Magazine, IEEE*, 9(3), pp. 32–50.
- Li, C.-G.L.C.-G., Wang, M.W.M., Huang, Z.-J.H.Z.-J. Zhang, Z.-F.Z.Z.-F. (2009). An Actor-Critic Reinforcement Learning Algorithm Based on Adaptive RBF Network. *Proceedings of the Eighth International Conference on Machine Learning and Cybernetics*, pp. 984–988.
- Lisetti, C., Nasoz, F., Lerouge, C., Ozyer, O., Alvarez, K. (2003). Developing Multimodal Intelligent Affective Interfaces for Tele-Home Health Care. *Int. J. Hum.-Comput. Stud*, 59(1), pp. 245–255.
- Lukočius, R., Virbalis, J.A., Daunoras, J., Vegys, A. (2005). Interaktyviosios aprangos signalų apdorojimo sistema. *Electronics and Electrical Engineering*, Kaunas, Technologija, 61(5), pp. 13-17.
- Maaoui, C., Pruski, A., Abdat, F. (2008). Emotion Recognition for Human-Machine Communication. *IEEE/RSJ International Conference on Intelligent Robots and Systems*, IEEE Explore, pp. 1210 – 1215.
- Mandryk, R.L. (2005). *Modeling User Emotion in Interactive Play Environments: A Fuzzy Physiological Approach*. PhD thesis, 273 p.
- Markienė, Z. O. (2000). *Klinikinė elektrokardiografija*. Monografija, Vilnius.
- Marreiros, G., Santos, R., Novais, P., Machado, J., Ramos, C., Neves, J., Bulas-Cruz, J. (2007a). Argumentation-Based Decision Making In Ambient Intelligence Environments. In *Proceedings of Progress in Artificial Intelligence, 13th Portuguese Conference on Artificial Intelligence (EPIA), Lecture Notes in Computer Science*, (4874), Springer Berlin, pp. 309–322.

- Marreiros, G., Santos, R., Ramos, C., Neves, J., Novais, P., Machado, J., Bulas-Cruz, J. (2007b). Ambient Intelligence in Emotion Based Ubiquitous Decision Making. *In Proceedings of the 2nd Workshop on Artificial Intelligence Techniques for Ambient Intelligence (AITAmI)*, J. C. Augusto and D. Shapiro, Eds., pp. 86–91.
- Martín, H.J.A., Lope, J., Maravall, D. (2008). Adaptation, Anticipation and Rationality in Natural and Artificial Systems: Computational Paradigms Mimicking Nature. *Natural Computing*, 8(4), pp.757–775.
- Masatoshi, A., Mitsunori, M., Tomoyuki, H., Masato, Y. (2010). Optimization of the Height of Height-Adjustable Luminaire for Intelligent Lighting System. *Artificial Intelligence and Soft Computing, Lecture Notes in Computer Science*, (6114), pp. 355–362.
- Oatley, K., Johnson-Laird, P.N. (1987). Towards a Cognitive Theory of Emotions. *Cognition Emotion*, (1), pp. 29–50.
- Perry, J.C. (2007). *The Psychophysiology of Risk Processing and Decision Making at a Regional Stock Exchange*. PhD thesis, Massachusetts Institute of Technology.
- Picard, R.W. (1995). *Affective Computing*. M.I.T Media Laboratory Perceptual Computing Section Technical Report
- Rani, P. (2003). *Human Robot Collaboration Based on Affect Sensing*. Vanderbilt University, 188 p.
- Rani, P., Liu, C., Sarkar, N. (2006). An Empirical Study of Machine Learning Techniques for Affect Recognition in Human-Robot Interaction. *Pattern Analysis and Applications*, (9), pp. 58–69.
- Raudys, Š. (2008) *Žinių išgavimas iš duomenų*. Klaipėdos universiteto leidykla, 172 p.
- Russell, J.A. (1980). A Circumplex Model of Affect. *Journal of Personality and Social Psychology*, 39(6), pp. 1161–1178.
- Russell, S., Norvig, P. (2009). *Artificial Intelligence: A Modern Approach*, Prentice Hall in AI, 1152 p.

- Salehie, M., Tahvildari, L. (2009). Self-Adaptive Software: Landscape and Research Challenges. *ACM Transactions on Autonomous and Adaptive Systems*, 4(2), pp.1–42.
- Sedighzadeh, M., Rezazadeh, A. (2008). Adaptive PID Controller Based on Reinforcement Learning for Wind Turbine Control. *Engineering and Technology*, pp. 257–262.
- Smarcos. (2012). *EU FP7 Project Smarcos*. Prieiga: <http://www.smarcos-project.eu/>
- Sutton, R.S., Barto, A.G. (2012). *Reinforcement Learning: an Introduction*. The MIT Press, Cambridge, 320 p.
- Takahashi, K. (2004). Remarks on Emotion Recognition from Bio-Potential Signals. *Proceedings of the 2nd International Conference on Autonomous Robots and Agents*, Palmerston North, New Zealand, pp. 186–191.
- Vildjiounaite, E., Kyllonen, V., Vuorinen, O., Makela, S.M., Keranen, T., Niiranen, M., Knuutinen, J., Peltola, P. (2009). Requirements and Software Framework for Adaptive Multimodal Affect Recognition. *3rd International Conference on Affective Computing and Intelligent Interaction and Workshops*, IEEE, pp. 1-7.
- Villon, O., Lisetti, C. (2006). A User-Modeling Approach to Build User's Psycho-Physiological Maps of Emotions using Bio-Sensors. *Robot and Human Interactive Communication*, pp. 269-276.
- Wang, P., McCreary, H. (2006). *EDA Sensor*. Prieiga: http://courses.cit.cornell.edu/ee476/FinalProjects/s2006/hmm32_pjw32/index.html.
- Wehrens, R., Buydens, L.M.C. (2007). Self- and Super-Organizing Maps in R: the Kohonen Package. *Journal of Statistical Software*, 21(5), pp. 1–19.
- Weiser, M., Gold, R., Brown, J.S. (1999). The Origins of Ubiquitous Computing Research at PARC in the Late 1980s. *IBM Systems Journal*, 38(4), pp. 693–696.

Autoriaus publikacijų disertacijos tema sąrašas

Mokslų žurnaluose, referuojamuose Mokslinės informacijos instituto (ISI) duomenų bazėse

1. Drungilas, D., Bielskis, A.A. (2012). Cloud Interconnected Affect Reward Based Automation Ambient Comfort Controller. *Electronics and Electrical Engineering*, Kaunas, Technologija, 126(10), pp. 49–52.
2. Bielskis, A.A., Guseinovicienė, E., Dzemydienė, D., Drungilas, D., Gričius, G. (2012). Ambient Lighting Controller Based on Reinforcement Learning Components of Multi-Agents. *Electronics and Electrical Engineering*, Kaunas, Technologija, 121(5), pp. 79–84.
3. Dzemydienė, D., Bielskis, A.A., Andziulis, A., Drungilas, D., Gričius, G. (2010). Recognition of Human Emotions in Reasoning Algorithms of Wheelchair Type Robots. *Informatica*, 21(4), pp. 521–532.
4. Bielskis, A.A., Denisovas, V., Drungilas, D., Gričius, G., Dzemydienė, D. (2010). Multi-Agent-Based Human Computer Interaction of E-Health Care System for People with Movement Disabilities. *Electronics and Electrical Engineering*, Kaunas, Technologija, (7), pp. 77–82.
5. Bielskis, A.A., Dzemydienė, D., Denisov, V., Andziulis, A., Drungilas, D. (2009). An Approach of Multi-Agent Control of Bio-Robots Using Intelligent Recognition Diagnosis of Persons With Moving Disabilities. *Technological and Economic Development of Economy*, 15(3), pp. 377–394.

Konferencijų pranešimų medžiagoje, referuotose Mokslinės informacijos instituto (ISI) duomenų bazėje Thomson ISI Proceedings

1. Drungilas, D., Bielskis, A.A., Denisov, V., Dzemydienė, D. (2010). Data Mining Approaches for Intelligent e-Social Care Decision Support

System. *Lecture Notes in Computer Science, Artificial Intelligence and Soft Computing* (6113), Springer, pp. 605–612.

Straipsniai kituose recenzuojamuose moksliniuose leidiniuose

1. Bielskis, A.A.; Guseinovicė, E.; Žutautas, L., Drungilas, D., Dzemydienė, D., Gričius, G. (2013). Modeling of Ambient Comfort Affect Reward Based on Multi-Agents in Cloud Interconnection Environment for Developing the Sustainable Home Controller. *Ecological Vehicles and Renewable Energies (EVER), 2013 8th International Conference and Exhibition on*, 5(1), pp. 27–30.
2. Gričius, G., Drungilas, D., Guseinovicė, J., Grigaitis, K., Bielskis, A.A. (2013). Modeling of the Cloud Interconnected Human Friendly Multi-Agent Based Sustainable Power Controller. *Balkan journal of electrical & computer engineering*, 2(1), Kirklareli / Turkey, pp. 49–55.
3. Drungilas, D., Bulbenkienė, V., Eglynas, T., Harja, J. (2012). Analysis and Research of Integration of Different Remote Control Methods and Subsystems, for Development of the Distributed Remote Control Radio Telescope Framework. *Space Research Review*, Ventspils, Latvia, pp. 149–158.
4. Dzemydienė, D., Bielskis, A.A., Andziulis, A., Drungilas, D., Dzindzalieta, R., Gričius, G. (2010). The Reinforcement Framework of a Decision Support System for the Localization and Monitoring of Intelligent Remote Bio Robots. *Proceedings of the 10th International Conference Reliability and Statistics in Transportation and Communication*, Riga, Latvia, pp. 207–217.
5. Drungilas, D., Bielskis, A.A., Denisov, V. (2010). An Intelligent Control System Based on Non-Invasive Man Machine Interaction. *Innovations in Computing Sciences and Software Engineering*, Springer, pp. 63–68.
6. Dzemydienė, D., Bielskis, A.A., Andziulis, A., Drungilas, D., Dzindzalieta, R. (2010). Sensorinių tinklų taikymo pavyzdžiai

intelektualiai aplinkai kurti belaidžių technologijų priemonėmis. *Technologijos Mokslo Darbai Vakarų Lietuvoje*, Klaipėda: Klaipėdos universiteto leidykla, pp. 160–164.

7. Bielskis, A.A., Dzemydienė, D., Drungilas, D., Gricius, G., Gorochovik, A., Gadliauskaitė, R. (2011). Afekto atpažinimo metodų lyginamoji analizė. *XV kompiuterininkų konferencijos mokslo darbai*, Žara, pp. 19–32.

Darius Drungilas

AFEKTO ATPAŽINIMO IR ADAPTYVAUS PASLAUGŲ VALDYMO
METODŲ INTEGRAVIMAS UŽDAROS APLINKOS MIKROKLIMATO
VALDYMO SISTEMOJE

Daktaro disertacija

Technologijos mokslai (T 000)

Informatikos inžinerija (07 T)

Darius Drungilas

INTEGRATION OF METHODS OF AFFECT RECOGNITION AND
ADAPTIVE CONTROL OF SERVICES IN THE ENCLOSED
ENVIRONMENT MICROCLIMATE CONTROL SYSTEM

Doctoral dissertation

Technological sciences (T 000)

Informatics engineering (07 T)