



KAUNO TECHNOLOGIJOS UNIVERSITETAS
INFORMATIKOS FAKULTETAS
PROGRAMŲ INŽINERIJOS KATEDRA

Mindaugas Vasiljevas

ROBOTO VALDYMO SISTEMOS NEURONINĖS KOMPIUTERIO
SĄSAJOS TYRIMAS

Magistro darbas

Vadovas
Prof. Robertas Damaševičius

KAUNAS, 2013



KAUNO TECHNOLOGIJOS UNIVERSITETAS
INFORMATIKOS FAKULTETAS
PROGRAMŲ INŽINERIJOS KATEDRA

Mindaugas Vasiljevas

ROBOTO VALDYMO SISTEMOS NEURONINĖS KOMPIUTERIO
SĄSAJOS TYRIMAS

Magistro darbas

Vadovas
Prof. R. Damaševičius

(data, parašas)

Recenzentas
doc. dr. T. Blažauskas

(data, parašas)

Studentas
M. Vasiljevas

(data, parašas)

KAUNAS, 2013

AUTENTIŠKUMO PATVIRTINIMAS

Rašant šį darbą:

1. Pateikiama medžiaga nėra plagijuojama bei nepažeidžia trečiųjų asmenų autorių teisių.
2. Jei darbe naudojama kitų autorių medžiaga, tai aiškiai deklaruojama, pateikiant nuorodas į literatūros sąrašą.
3. Literatūros sąraše nėra pateikiami šaltiniai, kurie nebuvo cituoti magistrinio darbo tekste.

SANTRAUKA

Neuroninė kompiuterio sąsaja – tai alternatyvus būdas valdyti kompiuterį nenaudojant rankų. Ji gali būti apibrėžta, kaip komunikavimo sistema, kuri leidžia valdyti kompiuterį ar kitą skaitmeninį įrenginį, naudojant nervinės kilmės fiziologinius signalus. Pagrindinė neuroninės kompiuterio sąsajos taikymo sritis yra neįgaliesiems skirti įrenginiai. Tai ne tik specifiniai įrenginiai, tokie, kaip galūnių protezai, tačiau ir kompiuteriai su papildoma aparatine ir programine įranga, kuri leidžia žmonėms, nevaldantiems rankų, valdyti kompiuterį. Taip pat išmanieji invalido vežimėliai, kuriuos galima vairuoti nenaudojant rankų judesių.

Šiame darbe analizuojama neuroninė kompiuterio sąsaja, skirta vežimėlio tipo roboto valdymui. Pateikiama mūsų sukurta neuroninės kompiuterio sąsajos sistema, gebanti nuskaityti žmogaus EEG ir galvos raumenų EMG signalus, juos apdoroti, klasifikuoti ir jų pagalba valdyti vežimėlio tipo robotą. Taip pat pateikiamas trijų komandų vežimėlio tipo roboto valdymo per galvos paviršinio EMG signalo lygį metodas. Pateikiami roboto valdymo taikant šį metodą tikslumo eksperimentai ir jų rezultatai.

SUMMARY

Neural computer interface is alternative way to control computer without hands. It is defined as a communication system which allows user control computer or any other digital device using neural breed physiological signal. The main application of neural computer interface is various devices for people with disabilities. For example, electronic prosthetic limbs, PC's with additional hardware and software which allows people with motor disabilities to control PC or intelligent wheelchairs.

In this work we are analyzing neural computer interface applied for robot control. The author presents neural computer interface system which allows to read EEG and head surface EMG signals, pre-process the signals, classify the signals and control Arduino 4WD robot. We also propose approach to control robot with head surface EMG signal amplitude using 3 control commands. Robot control research using proposed approach is presented.

TURINYS

Paveikslėlių sąrašas	9
Lentelių sąrašas.....	11
TERMINŲ IR SANTRUMPŲ ŽODYNAS	12
1. Įvadas	13
1.1. Dokumento paskirtis.....	13
1.2. Darbo tikslas.....	14
1.3. Mokslinis naujumas	14
1.4. Uždaviniai	14
2. Neuroninės kompiuterio sąsajos analizė	14
2.1. Įėjimo signalai	14
2.2. Neuroninės kompiuterio sąsajos sistemų tipai	17
2.2.1. <i>Smegenų – kompiuterio sąsaja.....</i>	<i>17</i>
2.2.2. <i>EMG naudojančios neuroninės kompiuterio sąsajos sistemos</i>	<i>19</i>
2.2.3. <i>Biokibernetinės adaptyviosios sistemos</i>	<i>20</i>
2.3. Taikomi metodai	21
2.3.1. <i>Duomenų apdorojimo metodai.....</i>	<i>21</i>
2.3.2. <i>Duomenų klasifikavimo metodai</i>	<i>22</i>
2.4. Egzistuojančios sistemos.....	31
2.4.1. <i>BCI2000 sistema</i>	<i>32</i>
2.4.2. <i>OpenViBE sistema.....</i>	<i>32</i>
2.4.3. <i>BCILAB.....</i>	<i>32</i>
2.4.4. <i>BCI++ sistema</i>	<i>32</i>
2.4.5. <i>xBCI sistema</i>	<i>32</i>
2.4.6. <i>Sistemų palyginimas.....</i>	<i>32</i>
2.5. Analizės išvados.....	33

3.	Neuroninės kompiuterio sąsajos sistemos projektinė dalis	33
3.1.	Sistemos paskirtis	33
3.2.	Sistemos panaudos atvejų diagrama	34
3.3.	Funkciniai reikalavimai.....	35
3.4.	Nefunkciniai reikalavimai	35
3.4.1.	<i>Reikalavimai sistemos išvaizdai.....</i>	35
3.4.2.	<i>Reikalavimai panaudojamumui.....</i>	36
3.4.3.	<i>Reikalavimai vykdymo charakteristikoms</i>	36
3.4.4.	<i>Reikalavimai veikimo sąlygoms</i>	36
3.4.5.	<i>Reikalavimai saugumui</i>	36
3.5.	Sistemos architektūros modelis.....	37
3.5.1.	<i>Sistemos skirstymas į paketus</i>	37
3.5.2.	<i>Duomenų nuskaitymo modulis</i>	38
3.5.3.	<i>Duomenų apdorojimo modulis.....</i>	39
3.5.4.	<i>Apmokymo modulis</i>	39
3.5.5.	<i>Duomenų klasifikavimo modulis</i>	40
3.5.6.	<i>Įrenginio valdymo modulis.....</i>	41
3.5.7.	<i>Tiesioginio valdymo modulis</i>	41
3.5.8.	<i>Grafinės vartotojo sąsajos modulis.....</i>	42
3.6.	Naudojami trečiųjų šalių komponentai.....	42
3.7.	Naudojama aparatūrinė įranga	43
3.7.1.	<i>„OCZ NIA“ įrenginys</i>	43
3.7.2.	<i>„NeuroSky MindSet“ įrenginys</i>	43
3.7.3.	<i>„Arduino 4WD“ įrenginys</i>	44
4.	Neuroninės kompiuterio sąsajos tyrimai	44
4.1.	Valdymas per paviršinį EMG signalą	44

5.	Neuroninės kompiuterio sąsajos eksperimentinė dalis.....	47
5.1.	Roboto valdymo eksperimentai	47
5.1.1.	<i>Tyrimo eiga</i>	47
5.1.2.	<i>Tyrimo rezultatai.....</i>	48
5.2.	EEG duomenų apdorojimo ICA metodu tyrimas	55
5.2.1.	<i>Tyrimo aprašymas.....</i>	55
5.2.2.	<i>Tyrimo rezultatai.....</i>	56
6.	Išvados.....	56
7.	Literatūra.....	57

PAVEIKSLĖLIŲ SĄRAŠAS

1 pav.	Elektrookulogramos elektrodų montavimo vietos.	16
2 pav.	Smegenų – kompiuterio sąsajos bazinis modelis.	18
3 pav.	EMG naudojančios neuroninės kompiuterio sąsajos sistemos principinė schema.	20
4 pav.	Biokibernetinės adaptyviosios sistemos modelis.	21
5 pav.	Viensluoksnis perceptronas.	23
6 pav.	Tiesioginio sklidimo neuroninis tinklas.	24
7 pav.	Tikimybinis neuroninis tinklas.	25
8 pav.	Tiesinio klasifikatoriaus sprendimo plokštumos.	26
9 pav.	Atskirtos skirtingos klasės	27
10 pav.	Netiesinis klasifikatorius.	28
11 pav.	Nepriklausomų komponentų analizės metodas.	30
12 pav.	Neuroninės kompiuterio sąsajos sistemos panaudos atvejų diagrama.	34
13 pav.	Sistemos suskirstytos į paketus vaizdas.	37
14 pav.	Duomenų nuskaitymo modulio klasių diagrama.	38
15 pav.	Duomenų apdorojimo modulio klasių diagrama.	39
16 pav.	Apmokymo modulio klasių diagrama.	39
17 pav.	Duomenų klasifikavimo modulio klasių diagrama.	40
18 pav.	Įrenginio valdymo modulio klasių diagrama.	41
19 pav.	Tiesioginio valdymo modulio klasių diagrama.	41
20 pav.	Grafinės vartotojo sąsajos modulio klasių diagrama.	42
21 pav.	„OCZ NIA“ įrenginys [24].	43
22 pav.	„NeuroSky MindSet“ įrenginys [23].	44
23 pav.	„Arduino 4WD“ robotas [7].	44
24 pav.	Valdymo per signalo lygį principinė schema.	45
25 pav.	Valdymo per signalo lygį vartotojo sąsaja	46
26 pav.	Signalų lygio dalinimas į atskirus intervalus.	47
27 pav.	„OCZ NIA“ įrenginio montavimo pavyzdys.	48
28 pav.	Pirmojo subjekto valdymo tikslumas.	50
29 pav.	Antrojo subjekto valdymo tikslumas.	51
30 pav.	Trečiojo subjekto valdymo tikslumas.	52
31 pav.	Ketvirtojo subjekto valdymo tikslumas.	52
32 pav.	Penktojo subjekto valdymo tikslumas.	53
33 pav.	Bandymų tikslumų pokytis kiekvienam subjektui	54

34 pav.	Bendras kiekvieno subjekto valdymo tikslumas.....	54
35 pav.	Atskirų komandų tikslumo grafikas.....	55

LENTELIŲ SĄRAŠAS

1 lentelė.	Sistemų palyginimas	33
2 lentelė.	Pirmojo subjekto eksperimento rezultatai	49
3 lentelė.	Antrojo subjekto eksperimento rezultatai	49
4 lentelė.	Trečiojo subjekto eksperimento rezultatai	49
5 lentelė.	Ketvirtojo subjekto eksperimento rezultatai	50
6 lentelė.	Penktojo subjekto eksperimento rezultatai	50
7 lentelė.	EEG duomenų apdorojimo ICA metodu tyrimo rezultatai	56

TERMINŲ IR SANTRUMPŲ ŽODYNAS

1. EEG – elektroencefalograma
2. EMG – elektromiograma
3. EOG – elektrookulograma
4. ECG – elektrokardiograma
5. GSR – galvaninis odos atsakas arba odos laidumas (angl. Galvanic Skin Response)
6. SVM – atraminių vektorių metodas (angl. Support Vector Machine)
7. FFT – greitoji Furje transformacija
8. DCT – diskrečioji kosinusinė transformacija
9. TKEO – Taiger – Kaiser energijos operatorius
10. ICA – nepriklausimų komponentų analizė (angl. Independent Component Analysis)
11. PCA – principinių komponentų analizė (angl. Principal Component Analysis)
12. BCI – smegenų – kompiuterio sąsaja (angl. Brain – computer interface)
13. Neuroninė kompiuterio sąsaja – komunikavimo sistema, kuri leidžia valdyti kompiuterį ar kitąskaitmeninį įrenginį panaudojant nervinės kilmės fiziologinius signalus.
14. Smegenų – kompiuterio sąsaja – komunikavimo sistema, kuri leidžia valdyti kompiuterį ar kitąskaitmeninį įrenginį panaudojant žmogaus mentalines būsenas.
15. Biokibernetinė adaptyvioji sistema – tai sistema, kuri geba keisti savo funkcionalumą ar išvaizdą priklausomai nuo žmogaus fiziologinės būsenos.

1. ĮVADAS

Kompiuteriai ir kiti skaitmeniniai įrenginiai (mobilieji telefonai, robotai ir pan.) daro vis didesnę įtaką žmogaus gyvenime. Jie taikomi įvairiose srityse ir taikymo sričių tik daugėja. Vykstant labai sparčiai skaitmeninių įrenginių plėtrai, neišvengiamai atsiranda poreikis ieškoti naujų komunikacijos ir valdymo būdų. Vienas iš alternatyvių skaitmeninio įrenginio ir žmogaus komunikavimo būdų yra neuroninės kompiuterio sąsajos. Neuroninė kompiuterio sąsaja leidžia žmogui valdyti kompiuterį ar kitą skaitmeninį įrenginį nenaudojant rankų. Valdymui naudojami žmogaus nervų ląstelių generuojami elektriniai impulsai (EEG, EMG, EOG, ECG). Vietoje pelės ir klaviatūros, reikalingi specialūs įrenginiai, skirti žmogaus neuroelektrinių signalų nuskaitymui. Tobulėjant elektronikai pinga žmogaus fiziologinių signalų skaitytuvai, atsiranda nebrangių nuskaitymo įrenginių, o tai dar labiau skatina neuroninės kompiuterio sąsajos plėtrą.

Pagrindinė neuroninės kompiuterio sąsajos taikymo sritis – neįgaliesiems skirti įrenginiai. Ši technologija leidžia mažinti neįgaliųjų, turinčių rimtų motorikos sutrikimų, skaitmeninę ir socialinę atskirtį. Tokie įrenginiai, kaip virtualios klaviatūros [1], išmanieji invalido vežimėliai [2, 3, 4], leidžia siekti šių tikslų. Neuroninės kompiuterio sąsajos sistemos gali būti taikomos ir kompiuteriniuose žaidimuose, egzoskeletų bei įvairių robotų valdymui [5, 6].

Šiame darbe pateikiama neuroninės kompiuterio sąsajos sistema, suteikianti galimybę eksperimentuoti su skirtingais signalo apdorojimo ir klasifikavimo metodais. Ji nuskaitytų žmogaus smegenų elektroencefalogramos ir galvos raumenų elektromiogramos signalus. Sistemos pagalba galima valdyti vežimėlio tipo robotą „Arduino 4WD“ [7]. Šis robotas gali būti laikomas sumažinta išmaniojo invalido vežimėlio versija. Roboto valdymui taikomas paviršinio EMG signalo lygio metodas, kuris nereikalauja didelių resursų. Jį nesunku realizuoti mikroprocesorinėse sistemose ir programuojamos logikos įrenginiuose.

1.1. Dokumento paskirtis

Šiame dokumente pateikiama neuroninės kompiuterio sąsajos analizė, kurioje apžvelgiami neuroninės kompiuterio sąsajos įėjimo signalų tipai, sistemų tipai, taikomi metodai bei egzistuojančios sistemos. Taip pat pateikiamas sukurtos neuroninės kompiuterio sąsajos sistemos projektas (sistema kurta, kartu su bendraautoriumi K. Šidlausku). Darbe aprašomas nesudėtingas ir daug resursų nereikalaujantis metodas – valdymas per EMG signalo lygį. Pateikiami vežimėlio tipo roboto valdymo eksperimento rezultatai, gauti taikant šį metodą.

1.2. Darbo tikslas

Ištirti vežimėlio tipo roboto „Arduino 4WD“ valdymo tikslumą, taikant paviršinio EMG signalo lygo metodą bei įvertinti šio metodo priimtinumą vartotojui.

1.3. Mokslinis naujumas

1. Pasiūlytas ir aprašytas vežimėlio tipo roboto valdymo, naudojant tirs komandas, per paviršinio EMG signalo lygį metodas.
2. Suprojektuota ir sukurta neuroninės kompiuterio sąsajos sistema (kartu su bendraautoriumi K. Šidlausku).
3. Atlikti roboto valdymo tyrimai, kurių tikslas nustatyti vežimėlio tipo roboto valdymo tikslumą, valdymui naudojant paviršinio EMG signalo lygio metodą.

1.4. Uždaviniai

1. Išanalizuoti neuroninės kompiuterio sąsajos sistemas.
2. Išanalizuoti neuroninės kompiuterio sąsajos metodus.
3. Suprojektuoti ir sukurti neuroninės kompiuterio sąsajos sistemą.
4. Ištirinėti ir aprašyti paviršinio EMG signalo lygio valdymo metodą.
5. Atlikti vežimėlio tipo roboto valdymo eksperimentus su skirtingais žmonėmis, taikant šį metodą.

2. NEURONINĖS KOMPIUTERIO SĄSAJOS ANALIZĖ

2.1. Įėjimo signalai

Neuroninė kompiuterio sąsaja veikia su įvairiais žmogaus fiziologiniais signalais. Smegenų – kompiuterio sąsajoje kaip įėjimo signalas naudojama smegenų elektroencefalograma. Tuo tarpu neuroninėje kompiuterio sąsajoje įėjimo signalai gali būti įvairių rūšių:

- Elektroencefalograma – smegenų generuojami signalai.
- Elektromiograma – raumenų susitraukimų generuojami signalai.
- Elektrookulograma – akių judesių generuojami signalai.
- Elektrokardiograma – širdies generuojamas signalas.
- Galvaninis odos atsakas – odos laidumo parametrai.

2.1.1. Elektroencefalograma

Elektroencefalograma (EEG) – tai laike kintantys elektros potencialai, atsirandantys dėl smegenyse esančių neuronų ir jų junginių generuojamų biosrovių [8]. EEG signalai yra skirstomi į atskirus tipus pagal dažnio diapazoną: alfa1 bangos (8 – 10,5 Hz), alfa2 bangos (10,5 – 13 Hz), beta1 bangos (13 – 21 Hz), beta2 bangos (20 – 32 Hz), delta bangos (0,5 – 3,5 Hz), teta bangos (4 – 8 Hz), gama bangos (36 – 44 Hz). Pagal atskirų EEG bangų tipų aktyvumą galima nustatyti tam tikras subjekto būsenas. Pavyzdžiui, aukšto dažnio beta bangų aktyvumas yra susijęs su padidėjusiu budrumu, alfa bangų aktyvumas susijęs su mažu budrumu, tuo tarpu delta aktyvumas – su mieguistumu. EEG bangų interpretavimas gali priklausyti ir nuo skalpo vietos, nuo kurios nuskaitomas signalas. Pavyzdžiui, teta bangų, nuskaitytų nuo priekinės skalpo vietos, aktyvumas rodo, kad užduotis, kurią mintimis atlieka subjektas, reikalauja iš jo daug pastangų [9].

EEG duomenų klasifikavimą naudojančiose žmogaus – mašinos sistemose efektyvumas priklauso nuo subjekto generuojamų mentalinių būsenų. Mentalinės būsenos turi būti lengvai atkartojamos ir kiek įmanoma labiau skirtis viena nuo kitos. Tam tikslui dažniausiai taikomas motorikos įsivaizdavimo metodas (subjektui reikia įsivaizduoti, kad jis judina savo galūnes) [10, 11]. Kitas būdas yra taikyti su įvykiu susijusius potencialus. Su įvykiu susijęs potencialas – tai smegenų atsakas į konkretų jutiminį, kognityvinį ar su motorika susijusį įvykį [12]. Vienas iš labiausiai paplitusių su įvykiu susijusių potencialų yra P300 [13].


2.1.2. Elektromiograma

Elektromiograma (EMG) – tai nuo skeleto raumenų nuskaitytas signalas, kuris yra generuojamas raumenų ląstelių. Elektrinio signalo generavimo šaltinis yra konkretaus raumens membranos potencialas, kurio vertė yra ~90 mV. Elektromiogramos signalo amplitudės vertės gali svyruoti nuo mažiau nei 50 μ V iki 30 mV [14]. Bendras elektromiogramos dažnis gali svyruoti nuo 1 iki 2000 Hz. EMG yra bene geriausiai suprastas ir perspektyvus fiziologinio signalo šaltinis, kurį galima taikyti efektyviai žmogaus – mašinos sąveikai, nenaudojant rankų [9].

Egzistuoja du plačiai paplitę elektromiogramos nuskaitymo būdai: paviršinis ir invazinis. Paviršinė elektromiograma nuskaitoma naudojant paviršinius elektrodus, tvirtinamus prie odos paviršiaus. Invazinė elektromiograma nuskaitoma iš vidinių raumenų. Tam tikslui dažniausiai naudojami adatos tipo elektrodai, kurie yra įsmeigiami į konkretų raumenį. Neuroelektroninėje kompiuterio sąsajoje dažniausiai taikomas paviršinės elektromiogramos metodas, dėl savo paprastumo. Uždedant elektrodus ant norimos kūno vietos nereikalingos specifinės žinios ir nesukeliamas skausmas. Invazinis metodas dažniausiai taikomas medicininiuose tyrimuose.

2.1.3. Elektrookulograma

Elektrookulograma (EOG) – tai potencialas tarp akies ragenos ir Bruch'o membranos, esančios akies dugne [15]. EOG matavimas atliekamas montuojant du elektrodus virš ir žemiau akies arba kairėje ir dešinėje akies pusėse (žr. 1 pav.). Norint nuskaityti EOG reikia elektrodais apgaubti akį.



1 pav. Elektrookulogramos elektrodų montavimo vietos.

Akiai judant iš centrinės padėties link vieno iš elektrodo, šis elektrodas fiksuoja teigiamą įtampą. Priešingoje pusėje esantis elektrodas fiksuoja panašaus dydžio neigiamą įtampą. Tokiu būdu matuojant akies generuojamą elektrinį signalą galima matuoti ne tik akies poziciją, bet ir akies judėjimo greitį. Vienas didžiausių šio metodų trūkumų – priklausomybė nuo stabilios galvos padėties. Dėl šios priežasties populiareesnės yra video akies sekimo sistemos [9]. Nepaisant savo trūkumų EOG gali būti taikomas žmogaus – mašinos sąsajose [16].

2.1.4. Elektrokardiograma

Elektrokardiograma (ECG) – tai širdies elektrinio aktyvumo pokytis per laiko vienetą. ECG nuskaitymas vyksta prie krūtinės ląstos odos tvirtinant elektrodus. ECG nuskaitymas ir interpretavimas – tai vienas populiariausių medicininių tyrimų.

Iš ECG galima sužinoti širdies plakimo greitį (dūžiai per minutę). Pagal širdies plakimo greičio vertę galima nustatyti subjekto fiziologinę būseną. Jeigu subjektas patiria stresą ar pyktį, jo širdies plakimo greitis ženkliai padidėja. Tas pats gali atsitikti ir atliekant sudėtingą protinę užduotį su laiko suvaržymais ir neapibrėžtumu [17].

ECG gali būti taikomas kompiuteriniuose žaidimuose. Sistema gauna grįžtamąjį ryšį iš subjekto. Įvertinus jo širdies plakimo greitį galima, keisti žaidimų lygių sudėtingumą [18].

2.1.5. Galvaninis odos atsakas

Galvaninis odos atsakas (GSR) – tai odos laidumo įvertis, kuris svyruoja priklausomai nuo odos drėgnumo. Oda drėksta dėl odos paviršiuje išsiskiriančio prakaito. Kuo oda drėgesnė, tuo didesnis odos laidumas. Šis žmogaus fiziologinis signalas yra aktualus neuroniniai kompiuterio sąsajai, todėl, kad liaukos išskiriančios prakaitą odos paviršiuje yra kontroliuojamas nervų sistemos.

Odos laidumas matuojamas tarp dviejų odos taškų. Per šiuos taškus leidžiama labai silpna elektros srovė. Pagal Omo dėsnį matuojama varža tarp šių taškų ir apskaičiuojamas odos laidumas. Galvaninio odos laidumo signalas kinta priklausomai nuo veikiančių emocinių stimuliatorių, tokių kaip muzika, stebimas smurtas ir pan. [9].

2.2. Neuroninės kompiuterio sąsajos sistemų tipai

2.2.1. Smegenų – kompiuterio sąsaja

Smegenų – kompiuterio sąsaja – tai komunikavimo sistema, kuri smegenų generuojamas bangas verčia į kompiuterio ar kito skaitmeninio įrenginio komandas [19]. Smegenų generuojamos bangos vadinamos elektroencefalograma (EEG).

EEG signalas nuskaitomas įvairiais šių signalų skaitymo įrenginiais. Gali būti išskiriami 2 šių įrenginių tipai – moksliniai EEG nuskaitymo įrenginiai [20, 21] ir plačiajam vartotojui skirti EEG nuskaitymo įrenginiai [22, 23, 24]. Moksliniai EEG skaitymo įrenginiai pasižymi nuskaitomų duomenų tikslumu ir pilnumu (nuskaitomi visi arba dauguma EEG signalo kanalų), tačiau jų kaina yra ženkliai didesnė nei plačiajam vartotojui skirtų įrenginių. Moksliniai EEG skaitymo įrenginiai dažniausiai būna „kepurės“ su pritvirtintais elektrodais, be to naudojant šiuos įrenginius, dažnai reikia naudoti laidumą gerinantį gelį. Savo ruožtu paprastieji EEG nuskaitymo įrenginiai (skirti plačiajam vartotojui) turi mažiau elektrodų, juos patogiau užsidėti ir naudoti, nereikalingos papildomos priemonės, tačiau EEG duomenys mažiau tikslūs ir dažnai nepilni.


Smegenų – kompiuterio sąsajai ar kitai neuroelektroninei sąsajai taikytini plačiajam vartotojui skirti EEG nuskaitymo įrenginiai dėl mažesnės kainos ir paprastumo. Kainos faktorius svarbus kuriant komercines neuroninės kompiuterio sąsajos sistemas. Moksliniai EEG įrenginiai dažniau taikomi medicininiuose tyrimuose.

2 pav. pateiktas bazinis smegenų – kompiuterio sąsajos modelis. Šis modelis susideda iš trijų pagrindinių etapų: signalo apdorojimo, signalo klasifikavimo ir taikomosios programos. Signalų apdorojimo etape, iš smegenų nuskaitytam signalui atliekamas pirminis apdorojimas. Apdorojimui gali būti taikomi įvairūs skaitmeninio signalo apdorojimo metodai, tokie kaip Furje transformacija, DCT

transformacija. Taip pat aukšto dažnio filtrai, nes EEG signale naudinga informacija dažniausiai aptinkama žemuose dažniuose. Taip pat naudotini ir netiesiniai operatoriai, tokie kaip TKEO [25].

Kitas etapas po priminio signalo apdorojimo – signalo klasifikavimas. Signalų klasifikavimo etape iš apdoroto EEG signalo bandoma išgauti reikšmines ypatybes, kurios dar vadinamos duomenų klasėmis. Daugelis šiame etape taikomų metodų yra pasitelkti iš dirbtinio intelekto srities: įvairių tipų neuroniniai tinklai, atraminių vektorių metodas, principinių komponentų analizė, nepriklausomų komponentų analizė. Taip pat vis dažniau taikomas ir „Random Forest“ algoritmas [26]. Daugelis šiame etape taikomų metodų reikalauja apmokymo, todėl prieš klasifikavimo procedūrą dažnai atliekama apmokymo procedūra. Šios procedūros metu suformuojami duomenų šablonai pagal, kuriuos klasifikuojami duomenys.

Taikymo programa nusako konkretų uždavinį, kurį sprendžia smegenų – kompiuterio sąsajos sistema. Smegenų – kompiuterio sąsaja gali būti taikoma neįgaliesiems skirtiems įrenginiams, tokiems, kaip invalidų vežimėliai, galūnių protezai, robotizuotos rankos, virtualios klaviatūros ir pan. Taip pat šios sistemos taikomos įvairių robotų valdymui, sistemose, kuriose reikalinga „trečioji“ ranka bei kompiuteriniuose žaidimuose.



2 pav. Smegenų – kompiuterio sąsajos bazinis modelis.

Kai kuriuose smegenų – kompiuterio sąsajos realizacijos gali būti išskiriamos įvairios grįžtamojo ryšio ar įvertinimo procedūros, kurių paskirtis vertinti klasifikavimo kokybę. Taip pat šių procedūrų metu gali būti atliekama nuskaitomo signalo stebėseną ir vertinama jo kokybė. Nuskaitomo signalo ir klasifikavimo kokybę gali įtakoti įvairūs aplinkos elektromagnetiniai trukdžiai, nuovargis bei nuotaikų kaita.


Pastaruoju metu mokslininkai pradėjo vystyti hibridines smegenų – kompiuterio sąsajos sistemas. Tokio tipo smegenų – kompiuterio sąsajos yra apjungiamos su kito tipo neuroninėmis kompiuterio sąsajomis (pvz., EMG pagrindu veikiančiomis neuroninėmis kompiuterio sąsajomis). Kelios sistemos apjungtos į vieną gali ženkliai padidinti komandų skaičių ir padėti sprendžiant problemas susijusias su vartotojo nuovargiu bei sistemos panaudojamumu. Antrinė sistema gali įjungti ar išjungti pirminę sistemą, patvirtinti ar atšaukti pasirinkimus, taisyti klaidas, pagerinti apmokymo procedūras [53].

2.2.2. EMG naudojančios neuroninės kompiuterio sąsajos sistemos

EMG naudojančios neuroninės kompiuterio sąsajos nuo smegenų – kompiuterio sąsajų skiriasi įėjimo signalu. Smegenų – kompiuterio sąsajose naudojamas EEG signalas. Savo ruožtu EMG naudojančios neuroninės kompiuterio sąsajos, kaip matome iš pavadinimo, naudoja raumenų elektromiogramą. EMG naudojančios neuroninės kompiuterio sąsajos gali turėti ir daugiau skirtumų dėl to, kad EMG signalą galima nuskaityti nuo įvairių kūno vietų. Tuo tarpu EEG signalas nuskaityamas tik nuo žmogaus galvos (skalpo srities).

Medicinoje EMG grįžtamasis ryšys yra taikomas treniruoti pacientams po traumų ir ligų, kad šie atgautų raumenų valdymo įgūdžius [27]. Taip pat EMG pagalba galima valdyti elektroninius galūnių protezus [9, 28, 29]. EMG neuroninės kompiuterio sąsajos gali būti taikomos kompiuterio ir žmogaus sąveikai [30, 31, 32] bei vežimėlio tipo robotų bei egzoskeletų valdymui [2, 6].

Valdydamas konkretų skaitmeninį įrenginį žmogus turi tikslingai generuoti EMG signalus. Tai daryti žmogui nėra sudėtinga, nes daugelio raumenų valdymas yra įprastas ir sąmoningai kontroliuojamas veiksmas. Nuskaityti signalai yra apdorojami skaitmeninio signalo apdorojimo metodais. Pasirinktina gali būti taikoma apmokymo procedūra, kurios tikslas sukurti duomenų šablonus klasifikavimo algoritmams. Atlikus apmokymo procedūrą, galima atlikti klasifikavimo procedūrą (žr. 3 pav.). Signalų klasifikavimui taikomi įvairūs dirbtinio intelekto metodai: neuroniniai tinklai, atraminių vektorių metodas, pagrindinių komponentų analizė, „Random Forest“ algoritmas ir pan.




3 pav. EMG naudojančios neuroninės kompiuterio sąsajos sistemos principinė schema.

Tuo pačiu metu, kai atliekama apmokymo ar klasifikavimo procedūra, atliekama ir įvertinimo procedūra (žr. 3 pav.). Jos metu vartotojas gali stebėti apmokymo ir klasifikavimo kokybės parametrus ir atitinkamai reaguoti į gautą informaciją (pvz. atpalaiduoti arba labiau įtempti atitinkamus raumenis). Įvertinimo procedūra leidžia sistemos vartotojui gauti grįžtamąjį ryšį.

2.2.3. Biokibernetinės adaptyviosios sistemos

Biokibernetinės adaptyviosios sistemos geba keisti savo funkcionalumą ar išvaizdą priklausomai nuo žmogaus fiziologinės būsenos [9]. Šio sistemos veikia uždaro ciklo principu. Kiekvienos iteracijos pradžioje nuo žmogaus nuskaitoma fiziologinė informacija ir apdorojus nuskaitytą informaciją, nustatoma žmogaus fiziologinė būsena [33]. Biokibernetinės adaptyviosios sistemos veikimo ciklas pateiktas žemiau esančiame paveikslėlyje.



4 pav. Biokibernetinės adaptyviosios sistemos modelis.

Žmogui dirbant su biokibernetine adaptyviaja sistema, sistema realiame laike stebi jo fiziologinius parametrus. Iš apdorotos ir išanalizuotos fiziologinės informacijos nustatoma žmogaus fiziologinė būseną. Galima nustatyti, kada žmogus patiria stresą, ar jis yra atsipalaidavęs, sunerimęs, susikaupęs, susimąstęs, neatidus ir pan. Būsenų nustatymui gali būti nuskaitomi elektrokardiogramos, elektroencefalogramos, elektromiogramos, odos galvaninio laidumo, kraujospūdžio signalai.

Biokibernetinės adaptyviosios sistemos gali būti integruotos į kritines sistemas, ten, kur žmogaus klaidos gali sukelti labai didelę žalą. Taikymo sritys, tokios kaip skrydžių ir transporto valdymas [34], intelektualus vairuotojo pagalbininkas [35] ir valdymo stimulatoriai, yra pagrindinė erdvė, kurioje galėtų būti diegiamos panašios sistemos. Taip pat šios sistemos gali būti taikomos ir kompiuteriniuose žaidimuose [36].

2.3. Taikomi metodai

Analizuojami metodai pasirinkti, įvertinus BBCI EEG duomenų klasifikavimo konkursuose (<http://www.bbci.de/activities>) dažniausiai taikomus metodus.

2.3.1. Duomenų apdorojimo metodai

Greitoji Furje transformacija (FFT)

Greitoji Furje transformacija (FFT) vienas plačiausiai naudojamų algoritmų skaitmeninių signalų apdorojime. Greitoji Furje transformacija duoda tuos pačius rezultatus kaip ir diskrečioji Furje transformacija, tik veikia greičiau. Šis metodas leidžia išgauti dažnių spektrą. FFT transformacija palčiai

taikoma realaus laiko sistemose. Šis metodas gali būti taikomas smegenų – kompiuterio sąsajoje EEG signalų apdorojimui [37].

Diskrečioji kosinusinė transformacija (DCT)

Diskrečioji kosinusinė transformacija transformuoja signalą į baigtinę koeficientų seką. Tokiu būdu informacijos kiekis yra sumažinamas – atliekamas informacijos „suspaudimas“. DCT transformaciją galima išreikšti taip:

$$X_k = \frac{1}{2}(x_0 + (-1)^k x_{N-1}) + \sum_{n=1}^{N-2} \left(x_n \cos \frac{\pi}{N-1} nk \right), k = 0, \dots, N-1 \quad (1)$$

Čia N – signalo reikšmių skaičius, $x_0, \dots, x_{N-1}$ – signalo reikšmės, $X_0, \dots, X_{N-1}$ – transformuotos signalo reikšmės.

Egzistuoja įvairios DCT realizacijos [38]. Naudojant DCT metodą signalų apdorojimui, dalis informacijos yra prarandama. Todėl šiuo metodu tikslinga apdoroti aukšto diskretizavimo dažnio EMG, EEG, ECG signalus. Sumažinus signalų apimtį galima pasiekti didesnę signalų klasifikavimo greitį.

Netiesiniai operatoriai

Netiesiniai modeliai yra sistemos, kurios netenkina sumos ir homogeniškumo kriterijų:

$$H[f(t) + g(t)] \neq H[f(t)] + H[g(t)], H[\alpha \cdot f(t)] \neq \alpha \cdot H[f(t)] \quad (2)$$

Čia $f(t)$, $g(t)$ yra signalai, H yra netiesinis modelis arba operatorius, α yra konstanta.

Apdorojant EEG duomenis, klasifikavimo kokybę galima pagerinti naudojant Teager-Kaiser energijos operatorių (TKEO) [25, 39], klasifikavimui naudojant atraminių vektorių metodą.

Diskretiems laiko signalams TKEO apibrėžiamas taip:

$$\Psi[x(n)] = x^2(n) - x(n-1)x(n+1) \quad (3)$$

Vienas didžiausių šio metodų trūkumų, sudėtingas koeficientų matricos parametrų parinkimas.


2.3.2. Duomenų klasifikavimo metodai

Neuroniniai tinklai

Neuroninio tinklo veikimo pagrindas yra neuronas. Neuronas yra skaičiavimo mazgas, kuris gali turėti keletą įėjimo reikšmių. Kiekviena neurono įėjimo jungtis turi savo svorį, dar vadinamą perdavimo koeficientu. Kiekvienas neuronas turi savo slenkstinę reikšmę ir neurono sužadavimo reikšmę. Sužadavimo reikšmė apskaičiuojama, iš įėjimo signalų svorių sumos atimant slenkstinę reikšmę. Neurono

išėjimo reikšmė apskaičiuojama pagal neurono perdavimo koeficientą. Perdavimo koeficientas yra funkcija, kurios argumentas yra sužadinimo reikšmė. Galimos įvairios perdavimo koeficiento funkcijos.

Paprasčiausio tipo neuroniniai tinklai yra sudaryti tik iš vieno neuronų sluoksnio. Jų architektūros vaizdas pateiktas 5 pav. Tokio tipo neuroniniai tinklai vadinami „tiesioginio sklidimo“ neuroniniais tinklais. Šiuose tinkluose informacija sklinda tik į vieną pusę. Paprasčiausi „tiesioginio sklidimo“ neuroniniai tinklai dar vadinami perceptronais. 5 pav. matome, kad toks tinklas sudarytas iš p išėjimų ir n įėjimų.



5 pav. Viensluoksnis perceptronas.


Perceptrone kiekvienas išėjimas y_i yra įėjimo vektoriaus $X = (x_1, x_2, \dots, x_n)$ funkcija, kuri skaičiuojama pagal formulę:

$$y_i = f(a_i) = f\left(\sum_{k=1}^n w_{ik} x_k\right), \quad i = 1, \dots, p \quad (4)$$

čia w_{ik} jungties, iš k -tosios įėjimo vektoriaus komponentės į i -tąjį išėjimą, svoris.

Perceptronas pasižymi paprastumu ir greitu mokymo algoritmu. Jis yra nesunkiai realizuojamas, tačiau jo pagalba galima spęsti tik nesudėtingus atpažinimo uždavinius.

„Tiesioginio sklidimo“ tinklai, turintys daugiau nei vieną neuronų sluoksnį yra vadinami daugiasluoksniais perceptronais arba daugiasluoksniais tiesioginio sklidimo neuroniniais tinklais [40]. Kiekvienas toks tinklas yra sudarytas iš įėjimų aibės, paslėptąjo neuronų sluoksnio ir išėjimų neuronų sluoksnio (žr. 6 pav.).



6 pav. Tiesioginio sklaidimo neuroninis tinklas.

Rekurentiniai neuroniniai tinklai (RNN) – tai neuroniniai tinklai, kuriuose informacija gali sklisti dviem kryptimis, galimas grįžtamasis ryšys į prieš tai informaciją apdorojusį neuroną. Toks tinklas gali būti nestabilus, turi sudėtingą architektūrą ir nenuspėjamą dinamiką, dėl to realių uždavinių sprendimui dažniausiai naudojami vienkrypčiai tiesioginio sklaidimo neuroniniai tinklai.

Kitas neuroninių tinklų tipas – neuroninis miglotasis tinklas. Šis tinklas apjungia miglotąją logiką ir neuroninius tinklus. Miglotoji logika leidžia apdoroti neapibrėžtumus, o neuroninis tinklas suteikia algoritmo apmokymo galimybę. Neuroninį miglotąjį tinklą sudaro trys sluoksniai: įėjimų sluoksnis, miglotojų taisyklių sluoksnis ir išėjimų sluoksnis.

Neuroniniai miglotieji tinklai geba apdoroti žmogaus žinioms būdingus neapibrėžtumus. Geba apdoroti lingvistinius kintamuosius. Taip pat pasižymi lengvu žinių bazės praplėtimu, kai pridedamos naujos taisyklės.

Kitas neuroninių tinklų tipas yra tikimybiniai neuroniniai tinklai (žr. 7 pav.). Tikimybiniai neuroniniai tinklai yra tiesioginio sklaidimo keturių sluoksnių neuroniniai tinklai. Šie tinklai yra kilę iš Bayes'o tinklų ir statistinio algoritmo – Fisher'io diskriminantinės analizės. Šį tinklą sudaro keturi sluoksniai:

1. Įėjimų sluoksnis. Šiame sluoksnyje neatliekami jokie skaičiavimai.
2. Modelių sluoksnis. Šiame sluoksnyje skaičiuojama funkcija:

$$\phi_{ij}(x) = \frac{1}{(2\pi)^{\frac{d}{2}\sigma^2}} \exp \left[-\frac{(x - x_{ij})^T (x - x_{ij})}{2\sigma^2} \right] \quad (5)$$

čia d – modelio vektoriaus x dydis, σ – išlyginimo parametras, x_{ij} – neurono vektorius.


3. Sumavimo sluoksnis. Šiame sluoksnyje atliekamas visų tos pačios klasės neuronų sumavimas ir skaičiuojama tikimybė, kad modelis x bus klasifikuojamas pagal formulę:

$$p_i(x) = \frac{1}{(2\pi)^{\frac{d}{2}\sigma^d}} \frac{1}{N_i} \sum_{j=1}^{N_i} \exp \left[-\frac{(x - x_{ij})^T (x - x_{ij})}{2\sigma^2} \right] \quad (6)$$

čia N_i – pavyzdžių kiekis klasėje C_i .

4. Išėjimų sluoksnis. Šiame sluoksnyje įėjimo reikšmės yra sumavimo sluoksnio išėjimo reikšmės. Modeliai x šiame sluoksnyje klasifikuojami, remiantis Bayes'o taisykle:

$$C(x) = \arg \max \{ p_i(x) \} \quad , i = 1, 2, \dots, m \quad (7)$$



7 pav. Tikimybinis neuroninis tinklas.

Tikimybinis neuroninis tinklas pasižymi greitu apsimokymu. Šis tinklas turi iš prigimties lygiagrečią struktūrą. Taip pat neriekia iš naujo atlikti visos apmokymo procedūros pridedant ar išimant naują apmokymo pavyzdį. Pagrindiniai šio tipo tinklų trūkumai yra didelis atminties poreikis ir gana lėtas užduočių vykdymas [41].

Atraminų vektorių metodas

Atraminų vektorių metodas (SVM) – savaime apsimokančių metodų (algoritmų) grupė, kuri gali būti taikoma klasifikavimo ar regresijos uždavinių sprendimui [42]. Šie metodai sukurti remiantis ankstesnių statistinio mokymosi teorijų pasiekimais. Dėl plataus taikymo sričių spektro ir patenkinamo


našumo lygio, SVM metodai tampa vienais pagrindinių įrankių kompiuterių apmokymo ir naudingų duomenų išgavimo srityse.

SVM metodui apmokymo metu pateikiama aibė pradinių duomenų, kurių kiekvienas pažymimas kaip priklausantis vienai iš dviejų kategorijų (klasių). Remdamasis apmokymo duomenimis algoritmas konstruoja modelį, pagal kurį bus klasifikuojami kiti duomenys. Analizės etapo metu nagrinėjama aibė duomenų, kurie klasifikuojami pagal sudarytą modelį. Kiekvienas elementas yra priskiriamas vienai iš dviejų klasių. Tokiu principu veikiantis metodas gali būti apibūdintas kaip dvimatis arba binarinis klasifikatorius. SVM metodas pirmiausiai konstruoja sprendimų plokštumas daugiamatėje erdvėje, tam, kad atskirtų objektų klases ir vėliau pagal jas klasifikuotų analizuojamus objektus.

SVM algoritmai sprendžia šablonų atpažinimo uždavinius. Šablonų atpažinimas – procesas, kurio metu duomenų masyvuose ieškomi žinomų fragmentų atitikmenys, kurių duomenys surenkami apmokymo metu. Šis procesas taikomas vaizdų, simbolių, rašysenos atpažinimui, kalbos analizei, klinikiniais bei chemijos tyrimams [43].

SVM veikimas pagrįstas sprendimų priėmimo plokštumomis, kurios apibrėžia sprendimo ribas. Sprendimo plokštuma riboja (atskiria nuo kitų) tos pačios klasės narius. Skirtingų klasių atskyrimui naudojami įvairūs metodai, dar vadinami branduolio funkcijomis:

- Tiesinis klasifikavimas (tiesinė branduolio funkcija). Šį klasifikavimo būdą iliustruojantis pavyzdys pateiktas paveikslėlyje 8 pav. Jame pavaizduoti dviejų tipų objektai: šviesūs ir tamsūs, priklausantys skirtingoms klasėms. Skiriančioji linija nustato sprendimų plokštumų ribas, t.y. dešinėje pusėje yra tamsūs objektai, kairėje šviesūs. Bet koks analizuojamas objektas patenka į kažkurią plokštumos dalį ir gali būti traktuojamas kaip tos klasės objektas. Pvz: jeigu naujas taškas būtų kairiau linijos – jis būtų priskirtas šviesių objektų klasei.



8 pav. Tiesinio klasifikatoriaus sprendimo plokštumos.


Tiesinio klasifikavimo procesas paaiškėja analizuojant jo matematinį modelį. Sakykime, kad n -matis objektas $\mathbf{x}$ turi n koordinačių: $\mathbf{x} = (x_1, x_2, x_3, \dots, x_n)$, kur kiekvienas x_i yra realusis skaičius. Kiekvienas šablonas $\mathbf{x}_j$ priklauso klasei $y_j \in \{-1, +1\}$. Turime apmokymo duomenų aibę T , susidedančią iš m šablonų kartu su jų klasėmis: $T = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_m, y_m)\}$. Egzistuoja plokštuma S , su visais šablonais $\mathbf{x} : \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m \in S$. Bet kokia tiesė plokštumoje S gali būti užrašyta taip:

$$\{\mathbf{x} \in S | \mathbf{w} \cdot \mathbf{x} + b = 0\}, \mathbf{w} \in S, b \in R \quad (7)$$

Čia $\mathbf{w} \cdot \mathbf{x}$ yra:

$$\mathbf{w} \cdot \mathbf{x} = \sum_{i=1}^n w_i \cdot x_i \quad (8)$$

Apmokymo aibė yra tiesiškai atskiriama (egzistuoja būdas nubrėžti tiesę tarp dviejų skirtingų klasių objektų), jeigu egzistuoja bent vienas tiesinis klasifikatorius, apibrėžtas pora: $(\mathbf{w}, b)$, kuri teisingai atskiria visus apmokymo duomenų objektus (žr. 9 pav.). Šis tiesinis klasifikatorius pavyzdyje pavaizduotas kaip tiesė H ($\mathbf{w} \cdot \mathbf{x} + b = 0$) ir atskiria sritį su $+1$ klasės objektais ($\mathbf{w} \cdot \mathbf{x} + b > 0$), nuo srities su -1 klasės objektais ($\mathbf{w} \cdot \mathbf{x} + b < 0$).



9 pav. Atskirtos skirtingos klasės


Po apmokymo fazės, klasifikatorius pasirengęs analizuoti naujus objektus ir prognozuoti, kuriai klasei jie priklauso. Objekto $\mathbf{x}_k$ klasė nustatoma pagal tokią formulę:

$$klasė(\mathbf{x}_k) = \begin{cases} +1 & \text{jeigu } \mathbf{w} \cdot \mathbf{x}_k > 0 \\ -1 & \text{jeigu } \mathbf{w} \cdot \mathbf{x}_k < 0 \end{cases} \quad (9)$$

Iš aukščiau pateiktos formulės matyti, kad naujų objektų klasifikavimas (priskyrimas tam tikrai klasei) priklauso nuo išraiškos $\mathbf{w} \cdot \mathbf{x} + b$ ženklo.

Dauguma klasifikavimo užduočių nėra tokios trivalios kaip pateiktas pavyzdys. Sprendimų plokštumų išskyrimui dažnai prireikia daug sudėtingesnių kreivių nei paprasta tiesė, kad būtų įmanoma teisingai klasifikuoti naujus objektus pagal apmokymo duomenis.

- Netiesinis klasifikavimas (Netiesinė branduolio funkcija). Sudėtingesnis klasifikavimo pavyzdys, pateiktas 10 pav. Lyginant su tiesinio klasifikavimo pavyzdžiu yra aišku, kad sprendimo plokštumų atskyrimui reikalinga kreivė.



10 pav. Netiesinis klasifikatorius.

Yra daug įvairių SVM tipų. Skirtingų tipų metodai kombinuojami su skirtingomis branduolių funkcijomis, skirtingais parametrais ir pan., todėl konkrečių metodų, tinkamų naudojimui galima rasti labai įvairių. Trumpai apžvelgsime kelis populiarius SVM tipus:

- C-SVM. Šio tipo metodas nuo kitų skiriasi tuo, kad suteikia galimybę pasirinkti parametą C , kuris nustato tam tikrą paklaidą, kurią metodas gali gauti klasifikavimo metu. Apmokymo metu yra minimizuojama funkcija:

$$\frac{1}{2} w^T w + C \sum_{i=1}^N \alpha \quad (10)$$

Iki apribojimų:

$$y_i(w^T \phi(x_i) + b) \geq 1 - \alpha \text{ ir } \alpha \geq 0, i = 1, \dots, N \quad (11)$$

Kuo didesnė parametro C reikšmė – tuo mažesnė vienos klasės sritis (metodas siekia kuo tiksliau apibrėžti klasifikuojamą klasę). Kuo mažesnė parametro C reikšmė – tuo didesnė klasės sritis. Didinant parametą C – auga naujų objektų analizavimo funkcijos sudėtingumas ir taip pat jų analizės laikas [42]. Sprendžiant iš šio aprašymo, gali pasirodyti, kad esant didesnei C parametro reikšmei gaunami teisingesni rezultatai, tačiau pasiekus tam tikrą ribą rezultatai pradeda ženkliai prastėti dėl per daug ribotos sprendimų srities, į kurią

nebepatenka nauji objektai, kurie turėtų ten patekti. Todėl teisingas C parametro parinkimas yra nemenkas iššūkis naudojant C-SVM metodą [42].

- v-SVM. Ši SVM metodo versija turi intuityvesnį parametą nei C parametras, naudojamas C-SVM metode. v-SVM metodo naudojamas v parametras nustato apmokymo klaidų ribą ir klasifikavimo funkcijos sudėtingumą [42]. Tačiau tinkamos parametro v reikšmės parinkimas reikalauja bent šiek tiek žinių apie analizuojamus duomenis (atraminių vektorių skaičius ar pan.).

Pagrindinių komponentų analizė

Pagrindinių komponentų analizė (PCA) yra matematinė procedūra, kuri naudojama duomenų analizei įvairiose mokslo srityse – nuo mokslo apie neuronus iki kompiuterinės grafikos. PCA metodas leidžia efektyviai sumažinti kompleksinius duomenų rinkinius iki paprastesnių duomenų struktūrų.

Matematiškai PCA metodas apibrėžiamas kaip ortogonalinė tiesinė transformacija, kuri transformuoja duomenis į kitą koordinačių sistemą. Šioje koordinačių sistemoje pirma koordinatė yra didžiausia pradinių duomenų (signalų) dispersija, antra koordinatė – antra pagal dydį signalų dispersija ir t.t [44].

Signalų dispersija:

$$s^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{(n-1)} \quad (12)$$

Čia s^2 – signalų dispersija, X_i – i-sis duomenų rinkinio elementas, $\bar{X}$ – duomenų rinkinio elementų vidurkis, n – duomenų rinkinio elementų kiekis.


Atlikus signalų transformaciją gauname dispersijų matricą. Trumpai apibrėžti PCA metodą galima kaip Karhunen–Loève transformaciją. Tai reiškia, kad su pradiniais duomenimis reikia atlikti Karhunen–Loève transformaciją:

$$Y = KLT\{X\} \quad (13)$$

Čia X – pradininkų duomenų matrica, Y – transformuota matrica, KLT - Karhunen–Loève transformacija.

Nepriklausomų komponentų analizė

Nepriklausomų komponentų analizė (ICA) yra skaitinis metodas skirtas išskaidyti sudėtingą signalą (susidedantį iš kelių skirtingų signalų), kai nėra informacijos apie patį signalą ar jo suformavimo procesą. Ši metodas pirmiausiai buvo taikomas balso atpažinimui ir triukšmų šalinimui iš garsinio signalo [45].



11 pav. Nepriklausomų komponentų analizės metodas.

Pateiktojo ICA metodo iliustracijoje matome, kad ICA metodas geba iš sumaišytų signalų aibės išskirti šių signalų sudedamąsias komponentes (originalius signalus).

Kai turime n signalų šaltinių, kurie savo signalus siunčia vienu metu toje pačioje erdvėje, jie neišvengiamai susimaišo. Priimkime, kad šiuos signalus fiksuoja n jutiklių, iš kurių kiekvienas fiksuoja tik vieną signalą. Šiuo atveju atsiranda problema, nes kiekvienas iš n daviklių fiksuos signalus, sudarytus iš susimaišiusių pradinių signalų [46].

$$\begin{aligned}
 x_1(t) &= a_{11}s_1(t) + a_{12}s_2(t) + \dots + a_{1n}s_n(t) \\
 x_2(t) &= a_{21}s_1(t) + a_{22}s_2(t) + \dots + a_{2n}s_n(t) \\
 &\vdots \\
 x_n(t) &= a_{n1}s_1(t) + a_{n2}s_2(t) + \dots + a_{nn}s_n(t)
 \end{aligned} \tag{14}$$

Čia $x_i(t)$ – sumaišyti signalai, a_{ij} – maišymo koeficientai, $s_i(t)$ – pradiniai (nesumaišyti) signalai.

Šios lygtys užrašytos matrica:

$$\begin{pmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_n(t) \end{pmatrix} = A \begin{pmatrix} s_1(t) \\ s_2(t) \\ \vdots \\ s_n(t) \end{pmatrix} \tag{15}$$

Čia A – matrica sudaryta iš a_{ij} elementų.

Pagrindinė užduotis iš sumaišytų signalų $x_i(t)$ gauti originalius signalus $s_i(t)$. Šią užduotį reikia atlikti apie originalius signalus neturint jokios informacijos arba turint jos labai mažai. [46].

Koeficientai a_{ij} yra pakankamai skirtingi, kad būtų galima suformuoti matricą W sudarytą iš koeficientų w_{ij} , kurių pagalba būtų galima išskirti originalius signalus s_i :

$$\begin{aligned} s_1(t) &= w_{11}x_1(t) + w_{12}x_2(t) + \dots + w_{1n}x_n(t) \\ s_2(t) &= w_{21}x_1(t) + w_{22}x_2(t) + \dots + w_{2n}x_n(t) \\ &\vdots \\ s_n(t) &= w_{n1}x_1(t) + w_{n2}x_2(t) + \dots + w_{nn}x_n(t) \end{aligned} \quad (16)$$

Tą patį galima užrašyti matricomis:

$$\begin{pmatrix} s_1(t) \\ s_2(t) \\ \vdots \\ s_n(t) \end{pmatrix} = W \begin{pmatrix} x_1(t) \\ x_2(t) \\ \vdots \\ x_n(t) \end{pmatrix} \quad (17)$$

Matrica W galima gauti invertavus matricą A , susidedančią iš koeficientų a_{ij} .

Pagrindinė užduotis – turint tik sumaišytus signalus $x_1, x_2, \dots, x_n$, gauti originalius signalus $s_1, s_2, \dots, s_n$. Tačiau tai ne taip parasta padaryti neturint informacijos apie pačius signalus arba jų maišymo procesą t.y. nežinant koeficientų a_{ij} .

Keli populiariausi metodai nepriklausomų komponentų išskyrimui:

- Netiesinė dekoreliacija. Vienas pagrindinių ICA metodų. Šio metodo pagrindinis principas yra ieškoti matricos W taip, kad kiekvienas komponentas y_i ir y_j , kai $i \neq j$, nekoraliuoja tarpusavyje ir transformuoti komponentai $g(y_i)$ bei $h(y_j)$ taip pat nekoraliuoja tarpusavyje. Čia g ir h yra atitinkamos netiesinės funkcijos [46].
- Maksimalių ne-Gauso komponentų metodas. Šio metodo pagrindinis principas – rasti labiausiai ne-Gauso komponentą atitinkančią kombinaciją $y = \sum_i b_i x_i$. Kiekvienas toks lokalus komponentas duoda vieną nepriklausomą komponentę [46].

2.4. Egzistuojančios sistemos

Smegenų – kompiuterio sąsajų srityje vykdoma daug tyrimų bei bandymų. Sukurta įvairių programų sistemų darbui šioje srityje. Tačiau viena pagrindinių problemų yra ta, kad visos programų sistemos dažniausiai būna labai ribotos: pritaikytos konkrečiam akademiniam tyrimui arba realizuoja vieną metodą ar jų grupę. Dėl spartaus srities tobulėjimo ir nuolat atsirandančių naujų, geresnių metodų, tos ribotos programų sistemos tampa nebeaktualios. Kita nemažiau svarbi problema – labai mažai produktų vystoma iki pritaikymo realiame gyvenime, net jei technologiniu požiūriu

sistemą realizuoti nėra didelių problemų. Toliau apžvelgiame keletą populiariausių neuroninės kompiuterio sąsajos sistemų.

2.4.1. BCI2000 sistema

BCI2000 programinis paketas skirtas BCI tyrimams. Jis taip pat gali būti naudojamas duomenų kaupimui ir smegenų monitoringui atlikti. Šis produktas prieinamas nemokamai, jeigu yra naudojamas nekomerciniais tikslais. Veikia tik Windows aplinkoje [47].

2.4.2. OpenViBE sistema

OpenViBE - multiplatforminis BCI programinis paketas, palaikantis ir kai kurią apartinę įrangą. Šis programinis paketas suteikia ne tik duomenų analizės ir atvaizdavimo galimybę naudojant įvairius BCI metodus, bet ir leidžia prijungti aparatinę įrangą skirtą smegenų bangų išgavimui. Veikia daugelyje operacinių sistemų (yra skirtingos versijos atskirtoms OS). Nemokamai platinamas. Taip pat šis paketas turi galimybę gautus duomenis siųsti į serverį, kur analizę atlieka OpenViBE klientai [48].

2.4.3. BCILAB

BCILAB yra MATLAB programinių įrankių rinkinys ir EEGLAB programinis įskiepis skirtas prototipų darymui, testavimui ir eksperimentavimui su BCI [49].

2.4.4. BCI++ sistema

BCI++ skirtas greitam BCI sąsajos prototipų kūrimui ir kitoms BCI programoms. Ši programinė įranga teikia saugojimo ir vizualizavimo, algoritmų valdymo, realaus laiko signalų apdorojimo paslaugas. Patogi vartotojo sąsaja teikia daug privalumų. Šis produktas yra nemokamas [50].

2.4.5. xBCI sistema

xBCI platforma skirta BCI sistemų kūrimui. Programinė įranga turi duomenų analizės, darbo tinkle, eksperimento kontrolės galimybes. Patogi vartotojo sąsaja. Veikia Windows ir Linux aplinkose [51].

2.4.6. Sistemų palyginimas

Sistemos lyginamos pagal 4 kriterijus:

- Ar sistema yra atviro kodo?
- Ar gali dirbti skirtingose operacinėse sistemose?
- Ar naudojamos nepasenusios technologijos?
- Ar sistema yra prižiūrima?

1 lentelė. Sistemų palyginimas

Sistemos pavadinimas	Kriterijai			
	Atviras kodas	Prieinamumas skirtingose OS	Nepasenusios technologijos	Palaikymas
BCI2000	+	-	+	+
OpenViBE	+	+	+	+
BCILAB	+	-	+	-
BCI++	+	-	+	+
xBCI	+	+	+	-

Iš 1 lentelės matome, kad programinis paketas „OpenViBE“ geriausiai tenkina iškeltus kriterijus.

2.5. Analizės išvados

Buvo išanalizuoti neuroninės kompiuterio sąsajos įėjimo signalai: EEG, EMG, EOG, ECG ir GSR. Vienas perspektyviausių neuroninės kompiuterio sąsajos metodų yra EMG, nes raumenų signalo generavimas yra lengvai kontroliuojamas. Nesudėtinga kontroliuoti ir EOG signalą, tačiau jo nuskaitymo metu galva turi būti stabilioje padėtyje.

Apžvelgti neuroninės kompiuterio sąsajos tipai: smegenų – kompiuterio sąsajos, EMG naudojančios neuroninės sąsajos sistemos, biokibernetinės adaptyviosios sistemos. Šiame darbe realizuojama EMG naudojanti neuroninės kompiuterio sąsajos sistema. Taip pat buvo apžvelgti neuroninėje kompiuterio sąsajoje taikomi metodai. Šioje analizėje nebuvo apžvelgti visi įmanomi metodai, buvo pasirinkti populiariausi metodai, taikomi BBCI EEG duomenų klasifikavimo konkursuose (<http://www.bbci.de/activities>).

Buvo apžvelgtos egzistuojančios panašios sistemos pagal kriterijus pateiktus 2.4.6 skyriuje. Vertinant pagal išsikeltus kriterijus, geriausia sistema yra OpenViBE. Realizuojant savo sistemą, patartina atsižvelgti į gerąsias šios sistemos savybes.

3. NEURONINĖS KOMPIUTERIO SĄSAJOS SISTEMOS PROJEKTINĖ DALIS

3.1. Sistemos paskirtis


Neuroninės kompiuterio sąsajos sistema leidžia nuskaityti žmogaus smegenų ir galvos raumenų generuojamas bangas. Šie signalai yra apdorojami ir paverčiami valdymo komandomis.

Valdymo komandomis galima valdyti arba „Arduino 4WD“, arba virtualų įrenginį, tokį, kaip kompiuterio pelė ar klaviatūra. Sistemos vartotojas gali rinktis, kokį signalo apdorojimo ir klasifikavimo metodą pasirinkti. Signalų apdorojimui yra realizuoti FFT ir DCT metodai. Signalų klasifikavimui sistemoje yra realizuotas atraminių vektorių analizės metodas ir dviejų tipų neuroniniai tinklai: daugiasluoksnis perceptronas ir balsuojantis neuroninis tinklas. Vartotojas turi galimybę pasirinkti klasifikavimo algoritmo parametrus. Taip pat sistemoje yra realizuota funkcija, kuri leidžia vartotojui valdyti įrenginius naudojant signalo lygio reikšmę (plačiau apie šią funkciją parašyta tyrimų skiltyje).

Ši sistema skirta eksperimentuoti su signalų apdorojimo ir klasifikavimo metodais. Vartotojas turi galimybę eksperimentuoti realiame laike arba generuoti duomenų rinkinius ir juos apdoroti vėliau (realizuota duomenų išsaugojimo funkcija). Pagalbinės priemonės, tokios, kaip signalų vizualizacija ir duomenų klasifikavimo kokybės vertinimas, palengvina eksperimentavimo darbus.

3.2. Sistemos panaudos atvejų diagrama

Žemiau esančiame paveikslėlyje pateikta neuroninės kompiuterio sąsajos sistemos panaudos atvejų diagrama.



12 pav. Neuroninės kompiuterio sąsajos sistemos panaudos atvejų diagrama.

3.3. Funkciniai reikalavimai

Svarbiausios sistemos funkcijos yra:

- *Pasirinkti EEG nuskaitymo įrenginį.* Vartotojas turi galimybę valdyti dviejų tipų žmogaus fiziologinių signalų nuskaitymo įrenginius: „OCZ NIA“ ir „NeuroSky MindSet“.
- *Pasirinkti duomenų apdorojimo metodą.* Vartotojas turi galimybę pasirinkti FFT, DCT signalo apdorojimo metodus arba nesirinkti signalo apdorojimo metodo.
- *Pasirinkti klasifikavimo metodą.* Vartotojas turi galimybę pasirinkti SVM, neuroninių tinklų arba valdymo pagal signalo lygį metodus. Pasirinkdamas konkretų klasifikavimo algoritmą, sistemos vartotojas taip pat gali pasirinkti jo parametrus. SVM algoritmo atveju – branduolio funkciją. Daugiasluoksnio perceptrono atveju – neuronų skaičius skirtinguose sluoksniuose. Balsuojančio neuroninio tinklo atveju – barjero reikšmę. Valdymo per signalo lygį atveju – komandų intervalų lygius.
- *Irašyti duomenis į failą.* Vartotojas turi galimybę nuskaitytus duomenis išsaugoti faile.
- *Įkelti duomenis iš failo.* Vartotojas turi galimybę nuskaityti išsaugotus duomenis iš failo.
- *Nuskaityti duomenų masyvą.* Apibūdinamas procesas, kada vartotojas inicijuoja žmogaus fiziologinių signalų (EEG ir EMG) skaitymą. Šis procesas taip pat apima duomenų apdorojimą, klasifikavimą ir įrenginio valdymą. Pradėjus veikti šiai funkcijai, vartotojas turi galimybę ją sustabdyti (žr. 12 pav. 14. *Nutraukti procesą*).
- *Žiūrėti signalo vaizdą.* Vartotojas turi galimybę stebėti signalo vaizdą realiaame laike, kai vyksta signalo skaitymo, klasifikavimo ir įrenginio valdymo procesai.
- *Stebėti signalo klasifikavimo kokybės parametrus.* Vartotojas turi galimybę stebėti klasifikavimo tikslumo įverčius. Ši funkcija veikia tik su išsaugotais signalais.

3.4. Nefunkciniai reikalavimai

3.4.1. Reikalavimai sistemos išvaizdai

Bendri reikalavimai neuroninės kompiuterio sąsajos sistemos vartotojo sąsajai:

- lengvai skaitoma sąsaja;
- neįkyri sąsaja (pavyzdžiui, nereikalaujanti, ką nors kelis kartus patvirtinti);
- profesionali (imituojanti realią aplinką) išvaizda;
- sąveikaujanti sąsaja;
- informuojanti vartotoją apie atliktus veiksmus sąsaja;

3.4.2. Reikalavimai panaudojamumui

Panaudojimo paprastumo (lengvumo) neuroninės kompiuterio sąsajos sistemai kriterijai:

- paprastas naudotis mokslininkams (įprasti žymėjimai);
- klaidos kainos sumažinimas;
- galimybė nutraukti bet kokią vykstantį procesą;
- procesų ir duomenų vizualizacija;

3.4.3. Reikalavimai vykdymo charakteristikoms

Užduočių vykdymo greičio apribojimai:

- Maksimalus signalo surinkimo laikas: 5s
- Maksimalus apmokymo proceso laikas: 1s
- Maksimalus klasifikavimo proceso laikas: 1s

Viršijant nustatytus apribojimus procesas nutraukiamas ir tolimesni procesai vykdomi su duomenimis, kurie buvo apdoroti per duotąjį laiką.

Maksimalus buferio dydis duomenų nuskaitymui yra 5 MB. Jeigu susiklosto tam tikra situacija, kurios metu generuojama daugiau duomenų nei maksimalus buferio dydis, tai pertekliniai duomenys yra ignoruojami.

3.4.4. Reikalavimai veikimo sąlygoms

Sistema turi veikti *windows* 32 bitų operacinėse sistemose: *windows xp*, *windows vista*, *windows 7*.

Norint pilnai panaudoti sistemą, ji turi veikti kartu su prie kompiuterio prijungtu robotu ir EEG signalų skaitytuvu. Sistema turi veikti tiek nešiojamuose, tiek stacionariuose kompiuteriuose.

3.4.5. Reikalavimai saugumui

Žemiau pateikti neuroninės kompiuterio sąsajos saugumo aspektai:


- Konfidencialumas. Sistemoje saugomi tik nuskanuoti asmens fiziologiniai duomenys, nesaugoma jokia kita su asmeniu susijusi ir jo tapatybę galinti atskleisti informacija;
- Vientisumas. Sistemoje nebus saugoma jokia informacija apie testuojamus asmenis, išskyrus asmenų nuskanuotus EEG duomenis, kurie patys neteikia jokios informacijos apie testuojamus asmenis. Sistema nebus jungiama prie interneto ir sistemos naudotojai nebus skirstomi į atskirtas kategorijas.

- Pasiekiamumas. Pagrindiniai sistemos duomenys su kuriais operuoja sistema yra fiziologiniai žmogaus duomenys, jie saugomi duomenų failuose. Sistemos vartotojai nėra skirstomi į atskiras grupes ir turi vienodą prieigą prie visų duomenų ir funkcijų.

3.5. Sistemos architektūros modelis

3.5.1. Sistemos skirstymas į paketus

Paveikslėlyje žemiau pateiktas neuroninės kompiuterio sąsajos sistemos, suskirstytos į paketus, vaizdas.



13 pav. Sistemos suskirstytos į paketus vaizdas.


Sistemą sudaro 7 paketai:

- *Duomenų nuskaitymo modulis*. Šis paketas atsakingas už duomenų nuskaitymą iš EEG ir EMG skaitytuvų.
- *Duomenų apdorojimo modulis*. Šiame pakete realizuotos duomenų apdorojimo funkcijos (FFT, DCT).
- *Apmokymo modulis*. Šiame pakete realizuota sistemos apmokymo procedūra, kurios metu sukuriama duomenų šablonai klasifikavimo algoritmams.
- *Duomenų klasifikavimo modulis*. Šiame modulyje realizuoti klasifikavimo algoritmai: neuroniniai tinklai (balsuojantis neuroninis tinklas, daugiasluksnis perceptronas), atraminių vektorių metodas, valdymas per signalo lygį.

- *Įrenginio valdymo modulis*. Šiame pakete realizuota „Arduino 4WD“ roboto valdymo sąsaja ir virtualių įrenginių valdymo sąsaja.
- *Tiesioginio valdymo modulis*. Šiame pakete yra realizuotas alternatyvus roboto valdymo būdas – naudojant kompiuterio klaviatūrą.
- *Grafinės vartotojo sąsajos modulis*. Šiame modulyje realizuota sistemos grafinė vartotojo sąsaja.

Kituose skyriuose detaliau panagrinėsime kiekvieną iš šių paketų.


3.5.2. Duomenų nuskaitymo modulis



14 pav. Duomenų nuskaitymo modulio klasių diagrama.

Duomenų nuskaitymo modulis realizuoja kompiuterio ir EEG nuskaitymo įrenginio komunikaciją per USB sąsają. Klasė *USBskaitytuvas* yra realizuojama kaip gija. *Skaitytuvo* klasėje naudojamos kelios lygiagrečios gijos, kad būtų užtikrintas nenutrūkstamas duomenų gavimas, nenutraukiant kitų procesų.


3.5.3. Duomenų apdorojimo modulis



15 pav. Duomenų apdorojimo modulio klasių diagrama.

Duomenų apdorojimo modulis realizuoja duomenų apdorojimo metodus, reikalingus EEG signalo apdorojimui. Klasė *Apdorojimas* yra pagrindinė. Klasės *Glotninimas*, *Regresija*, *DCT* ir *Furje* realizuoja atitinkamus signalų apdorojimo metodus. *DCT* klasėje realizuojama diskrečioji kosinusinė transformacija.

3.5.4. Apmokymo modulis




16 pav. Apmokymo modulio klasių diagrama.

Apmokymo modulio pagalba realizuojami duomenų rinkiniai reikalingi apmokyti klasifikavimo metodus. Klasė *Apmokymas* yra pagrindinė. Klasės: *Pirmyn*, *Atgal*, *Kairen*, *Desinen*, *Sustoti* realizuoja

atitinkamus komandų identifikatorius. Šios komandos realizuotos kaip atskiros klasės todėl, kad architektūrai suteiktų lankstumo ir eitų lengvai pridėti papildomų komandų pridedant naujas klases.


3.5.5. Duomenų klasifikavimo modulis



17 pav. Duomenų klasifikavimo modulio klasių diagrama.

Duomenų klasifikavimo modulis realizuoja EEG duomenų klasifikavimo metodus. Šiame modulyje realizuojami trys klasifikavimo metodai: SVM, neuroniniai tinklai ir valdymas pagal signalo lygį. Kiekvienas metodas turi savo apmokymo klasę (atitinkamai *SVMMapmokymas*, *NeuronApmokymas*, *SingnaloLygis*). Šiuos klases naudoja apmokymo modulyje sugeneruotus duomenis. Taip pat kiekvienas metodas turi savo klasifikavimo klasę (atitinkamai *SVMklasifikavimas* ir *NeuronKlasifikavimas*). Šiuose klasėse atliekami duomenų klasifikavimas, remiantis apmokymo klasėse sudarytais duomenų modeliais. Klasėje *SingnaloLygis* realizuojamas valdymo pagal signalo lygį metodas. Šiam metodui, priešingai nei SVM ir neuroniniams tinklams, nereikia apmokymo.


3.5.6. Įrenginio valdymo modulis



18 pav. Įrenginio valdymo modulis klasių diagrama.

Įrenginio valdymo modulis realizuoja roboto valdymą naudojant duomenų klasifikavimą. Klasė *Komunikacija* realizuoja komunikaciją su robotu naudojant COM portus. Klasė *Valdymas* realizuoja roboto valdymo komandas. Klasė *ĮrenginioValdymas* yra pagrindinė klasė. Įrenginio valdymo modulyje esančios klasės yra labai panašios į klases, esančias tiesioginio valdymo modulyje. Pagrindinis skirtumas yra tas, kad įrenginio valdymo modulyje komandos vykdymo laikas yra ribojamas ir komandos vykdymo trukmę galima nustatyti, o tiesioginio valdymo modulyje valdymo komanda, vykdoma pagal klaviatūros mygtuko paspaudimus.

3.5.7. Tiesioginio valdymo modulis




19 pav. Tiesioginio valdymo modulis klasių diagrama.

Tiesioginio valdymo modulis realizuoja roboto valdymą naudojantis klaviatūra. Šio modulis klasių panašios kaip ir įrenginio valdymo modulyje, tačiau šis modulis turi papildomą klasę *Klaviatura*, kurioje

realizuojami klaviatūros valdymo metodai: *Nuspausti()*, *Atleisti()* ir *Bakstelti()*. Naudojantis šiais metodais realizuojamas robotinio įtaiso valdymas naudojant klaviatūros rodyklių klavišus.

3.5.8. Grafinės vartotojo sąsajos modulis



20 pav. Grafinės vartotojo sąsajos modulio klasių diagrama.

Grafinės vartotojo sąsajos modulyje realizuojamas sąsajos su kiekvienu sistemos moduliui bei papildomas funkcionalumas, numatytas panaudos atvejų modelyje (pav. grafikų braižymą realizuoja klasė *Grafikai*). Kaip matosi iš klasių diagramos, atskiros klasės realizuoja atskirus panaudos atvejus, esančius panaudos atvejų diagramoje. Klasė *ApmokymoLangas* – sąsaja su apmokymo moduliui. Klasė *Grafikai* – realizuojamos grafikų braižymo funkcijos. Klasė *TiesioginioValdymoLangas* – sąsaja su tiesioginio valdymo moduliui. Klasė *IssaugotiFailą* – realizuojamas duomenų išsaugojimas faile. Klasė *NuskaitytiIsFailo* – realizuojamas duomenų nuskaitymas iš failo. Klasė *KlasifikavimoLangas* – sąsaja su klasifikavimo moduliui, taip šios klasės pagalba nustatomi atskirų metodų klasifikavimo parametrai. Klasė *DuomenųApdorojimoLangas* – sąsaja su duomenų apdorojimo moduliui, taip šios klasės pagalba nustatomi atitinkamų apdorojimo metodų parametrai.

3.6. Naudojami trečiųjų šalių komponentai

Realizuojant sistemą numatoma panaudoti šiuos trečiųjų šalių komponentus:

- JavaRobots 2.0 (<http://sourceforge.net/projects/javarobots/>) – roboto ir sistemos tarpusavio komunikacijai realizuoti, panaudojant SSC-32 protokolą.
- USBReader.CLibrary – EEG skaitytuvo ir sistemos aukštos spartos komunikacijai realizuoti.
- Weka 3 (<http://www.cs.waikato.ac.nz/ml/weka/>) – dirbtinio intelekto metodų (atraminių vektorių metodas, neuroniniai tinklai) realizacijai.
- JTransforms (<https://sites.google.com/site/piotrwendykier/software/jtransforms>) – signalų apdorojimui realizuoti (FFT ir DCT transformacijos).
- JFreeChart (<http://www.jfree.org/jfreechart/>) – grafikų braižymui.

3.7. Naudojama aparatūrinė įranga

Neuroninė kompiuterio sąsajos sistema veikia su dviejų rūšių EEG ir EMG signalo skaitytuvais: „OCZ NIA“ [24] ir „NeuroSky MindSet“ [23]. Sistema valdo „Arduino 4WD“ robotą [7].

3.7.1. „OCZ NIA“ įrenginys

„OCZ NIA“ – tai EEG ir EMG skaitytuvas, su kompiuteriu komunikuojantis per USB sąsają. Šio įrenginio lankelis dedamas žmogui ant kaktos. Lankelyje yra 3 elektrodai. Kairysis ir dešinysis elektrodai skirti signalų nuskaitymui, o vidurinis – įžeminimas. Šio skaitytuvo diskretizavimo dažnis 3906 Hz.



21 pav. „OCZ NIA“ įrenginys [24].

3.7.2. „NeuroSky MindSet“ įrenginys

„NeuroSky MindSet“ – tai EEG signalo nuskaitymo įrenginys, su kompiuteriu komunikuojantis „Bluetooth“ ryšiu. Šis įrenginys nuskaitymo alfa, beta, gama, teta smegenų bangas ir fiksuoja akių mirksnius. „MindSet“ net tik skaito EEG signalus, bet leidžia vartotojui klausytis muzikos – veikia kaip įprastos ausinės. Gamintojas kartu su šiuo įrenginiu teikia ir API JAVA, C/C++ programavimo kalboms.



22 pav. „NeuroSky MindSet“ įrenginys [23].

3.7.3. „Arduino 4WD“ įrenginys

„Arduino 4WD“ – tai vežimėlio tipo robotas, su kompiuteriu komunikuojantis bevielio ryšio pagalba. Robotas turi keturis ratus, kiekvienas ratas turi atskirą elektrinį variklį. Varikliai maitinami nuolatine srove, 3 – 12 V įtampa. Išvystomas greitis – 90 cm/s. Kiti parametrai: svoris – 660 g, ilgis – 200 mm, plotis – 170 mm, aukštis – 105 mm.



23 pav. „Arduino 4WD“ robotas [7].

4. NEURONINĖS KOMPIUTERIO SĄSAJOS TYRIMAI

4.1. Valdymas per paviršinį EMG signalą


Valdymas naudojant paviršinės elektromiogramos signalo lygį yra nesudėtingas, kadangi operuojama tik su momentine signalo lygio reikšme. Signalo pokytis laike nėra svarbus. Pagrindinė efektyvaus valdymo šiuo principu sąlyga yra pakankamai aukšta signalo amplitudė. Signalio nuskaitymo būdas turėtų leisti generuoti pakankamai aukštas amplitudes, tuomet signalo amplitudę galima suskirstyti į intervalus, žyminčius atitinkamas valdymo komandas.

Savo sistemoje taikome metodą, pagal kurį išskiriamos keturios valdymo komandos: „judėti pirmyn“, „judėti kairėn“, „judėti dešinėn“ ir „stovėti“. Kuo didesnis valdymo komandų skaičius, tuo mažesnis sistemos valdymo tikslumas. Siekdami didesnio valdymo tikslumo, atsisakėme komandos „judėti atgal“. Norint su robotu judėti atgal, galima apsisukti ir judėti pirmyn.

Signalų amplitudė skaidoma į penkis intervalus (žr. 26 pav.). Intervalų ilgiai yra individualūs kiekvienam žmogui, todėl sistema leidžia reguliuoti signalo amplitudės intervalų ilgį. Intervalų ilgį gali tekti pakeisti net ir tam pačiam vartotojui skirtingais laiko momentais, nes valdymas remiasi veido raumenų elektromiogramos nuskaitymu. Šiuos signalus gali labai paveikti nuovargis.

Sistemoje naudojamas OCZ NIA EEG ir EMG signalų skaitytuvas, su kompiuteriu komunikuojantis per USB sąsają. Šis skaitytuvas yra tvirtinamas prie vartotojo kaktos ir yra labai jautrus akių mirksniams bei kaktos raumenų įtempimui. Vartotojo inicijuotas komandas vykdo „Arduino“ 4WD įrenginys. Tai – vežimėlio tipo robotas, su kompiuteriu komunikojantis bevieliu ryšiu.


Sistemos principinė schema pateikta 24 pav. Kaip joje matyti, skiriami trys pagrindiniai etapai: signalo apdorojimas, valdymo komandos nustatymas ir valdymo parametrų nustatymas bei signalo stebėseną.



24 pav. Valdymo per signalo lygį principinė schema.

Apdorojant signalą jo reikšmių skaičius yra sumažinamas. Taip pat signalo reikšmė kiekvieno laiko momento metu yra suvidurkinama su prieš tai buvusią signalo reikšmę.

Valdymo parametrų nustatymas ir signalo stebėseną yra sujungti, kad būtų patogiau valdyti sistemą. Šį etapą iliustruoja sistemos valdymo sąsaja, pateikta 25 pav. Signalų žymeklis nurodo momentinę signalo reikšmę. Kai šis žymeklis yra vidurinėje padėtyje, tai signalo reikšmė lygi nuliui. Į kairę nuo nulinės vertės yra neigiamos signalo reikšmės, o dešinėje – teigiamos reikšmės. „Ramybės“ intervalas žymi intervalą, kai jokie veiksmai neatliekami. Kai signalo žymeklis atsiduria šiame intervale, robotas stovi vietoje. Kai žymeklis atsiduria komandos „kairėn“ intervale, robotas juda kairėn. Žymekliui atsidūrus komandos „dešinėn“ intervale, robotas juda dešinėn. Judėjimui į priekį yra skirti 2 intervalai (žr. 25 pav. komandos „pirmyn“ intervalus). Signalų žymekliui atsidūrus viename iš šių intervalų, robotas juda pirmyn.




25 pav. Valdymo per signalo lygį vartotojo sąsaja

Sistemos valdymo parametrai yra komandų intervalų ilgiai. Šie ilgiai gali būti keičiami kompiuterio pelyte tempiant intervalų ribų taškus (25 pav. pateiktoje vartotojo sąsajoje jie skiria atskirus intervalus).

Valdymo komandos nustatymo etape užfiksuojama momentinė roboto valdymo komanda. Užfiksuota komanda siunčiama robotui. Robotas vykdo gautą komandą tol, kol negauna kitos valdymo komandos.

26 pav. pateiktas pavyzdys, kuriame matyti, kaip signalo amplitudė sudalijama į atskirus intervalus. Konkretus intervalas žymi konkrečią valdymo komandą (žr. 26 pav.). Kad signalo reikšmė būtų viename ar kitame intervale, sistemos vartotojas turi ritmiškai įtempinėti savo kaktos raumenis ir mirksėti akimis. Merkiant kairę akį signalas įgauna teigiamą reikšmę (atsiduria komandos „kairėn“ intervale), o merkiant dešinę – neigiamą (atsiduria komandos „dešinėn“ intervale). Viduriniame intervale signalas būna tada, kai nėra įtempiami jokie raumenys, todėl šis intervalas žymi ramybės būseną. Komandos „pirmyn“ intervalai yra išsidėstę tarp komandos „kairėn“ intervalo ir ramybės intervalo bei tarp komandos „dešinėn“ intervalo ir ramybės intervalo (žr. 26 pav.). Bandymai parodė, kad lengviausiai į šiuos intervalus patenkama įtempiant kaktos raumenis. Tuo metu generuojama vidutinio dydžio signalo amplitudė. Priklausomai nuo žmogaus, ji gali būti teigiama arba neigiama, todėl judėjimui pirmyn ir buvo išskirti 2 intervalai – teigiamas ir neigiamas (žr. 26 pav.).



26 pav. Signalų lygio dalinimas į atskirus intervalus.

Veiksmai, kuriuos reikia atlikti norint įvykdyti konkrečią valdymo komandą, yra sąlyginiai. Jie labai priklauso nuo konkretaus žmogaus dominuojančių veido raumenų, todėl galimi ir kiti komandų iniciavimo būdai (pvz., lėtas ir greitas akies primerkimas ir pan.).

5. NEURONINĖS KOMPIUTERIO SĄSAJOS EKSPERIMENTINĖ DALIS

5.1. Roboto valdymo eksperimentai

5.1.1. Tyrimo eiga

Eksperimentas buvo atliekamas su 5 sveikais asmenimis, kurių amžius – tarp 20 ir 30 metų. Buvo sugeneruotas 120 užduočių sąrašas. 40 sąrašo punktų buvo skirta komandai „kairėn“, 40 punktų – komandai „dešinėn“, 40 punktų – komandai „pirmyn“. Komanda „stovėti“ eksperimento metu nebuvo registruojama, nes ji vykdoma subjektui esant ramybės būsenoje (neįtemptiant jokių veido raumenų). Ši

būsena yra natūrali daugumai žmonių, todėl jos generuojamos komandos tikslumas būtų beveik 100 %. Komandos „kairėn“, „dešinėn“ ir „pirmyn“ sąrašė buvo išmėtytos atsitiktine tvarka. Prieš atliekant eksperimentą buvo atliekamas sistemos kalibravimas – sistemos pritaikymas eksperimento dalyviui. Tada subjektui buvo liepiama atlikti iš eilės einančias komandas iš sąrašo, tarp atskirų komandų vykdymo darant 5 sekundžių pertrauką. Šis eksperimentas buvo kartojamas 5 kartus. Tarp kiekvieno bandymo buvo daroma 15–30 min. pertrauka. Subjektui inicijavus nurodytą komandą, buvo stebima, ar „Arduino“ 4WD robotas elgiasi taip, kaip numatyta (ar vykdo tinkamą komandą). Stebėjimo duomenys buvo registruojami, ir pagal šiuos stebėjimus buvo apskaičiuotos roboto valdymo tikslumo metrikos.



27 pav. „OCZ NIA“ įrenginio montavimo pavyzdys.

27 pav. parodyta, kokių būdų eksperimento metu buvo uždėtas paviršinės elektromiogramos skaitymo įrenginys OCZ NIA.

Eksperimento metu subjektui buvo siūloma atlikti tokius veiksmus:

- Komanda „kairėn“ – mirksėti kaire akimi.
- Komanda „dešinėn“ – mirksėti dešine akimi.
- Komanda „pirmyn“ – ritmiškai įtempti kaktos raumenis.

Roboto valdymo tikslumas buvo skaičiuojamas pagal tokią formulę:

$$N = \frac{n-f}{n} \cdot 100 \%. \quad (18)$$

Čia N – valdymo tikslumas, n – sąrašė esančių komandų skaičius, f – neteisingai atliktų komandų skaičius.

5.1.2. Tyrimo rezultatai

2, 3, 4, 5, 6 lentelėse pateikti kiekvieno iš penkių eksperimento subjektų valdymo tikslumai.

2 lentelė. Pirmojo subjekto eksperimento rezultatai

Bandymo numeris	Komandos „kairėn“ tikslumas	Komandos „dešinėn“ tikslumas	Komandos „pirmyn“ tikslumas	Bendras tikslumas
1.	95 %	100 %	95 %	96,67 %
2.	95 %	95%	97,5 %	95, 83 %
3.	90 %	100 %	97,5 %	95,83 %
4.	80 %	97,5 %	97,5 %	91,67 %
5.	70 %	95 %	90 %	85 %
Bendras komandos tikslumas	86 %	97,5 %	95,5 %	93 %

3 lentelė. Antrojo subjekto eksperimento rezultatai

Bandymo numeris	Komandos „kairėn“ tikslumas	Komandos „dešinėn“ tikslumas	Komandos „pirmyn“ tikslumas	Bendras tikslumas
1.	100 %	95 %	87,5 %	94,17 %
2.	100 %	97,5%	70 %	89,17 %
3.	100 %	95 %	77,5 %	90,83 %
4.	95 %	97,5 %	87,5 %	93,33 %
5.	100 %	97,5 %	90 %	95,83 %
Bendras komandos tikslumas	99 %	96,5 %	82,5 %	92,67 %

4 lentelė. Trečiojo subjekto eksperimento rezultatai


Bandymo numeris	Komandos „kairėn“ tikslumas	Komandos „dešinėn“ tikslumas	Komandos „pirmyn“ tikslumas	Bendras tikslumas
1.	97,5 %	95 %	80 %	90,83 %
2.	100 %	82,5%	87,5 %	90 %
3.	90 %	100 %	92,5 %	94,17 %
4.	92,5 %	97,5 %	97,5 %	95,83 %
5.	92,5 %	100 %	85 %	92,5 %
Bendras komandos tikslumas	94,5 %	95 %	88,5 %	92,67 %

5 lentelė. Ketvirtojo subjekto eksperimento rezultatai

Bandymo numeris	Komandos „kairėn“ tikslumas	Komandos „dešinėn“ tikslumas	Komandos „pirmyn“ tikslumas	Bendras tikslumas
1.	97,5 %	82,5 %	75 %	85 %
2.	100 %	82,5 %	75 %	85,83 %
3.	97,5 %	90 %	72,5 %	86,87 %
4.	100 %	77,5 %	95 %	90,83 %
5.	100 %	80 %	85 %	88,33 %
Bendras komandos tikslumas	99 %	82,5 %	80,5 %	87,37 %


6 lentelė. Penktojo subjekto eksperimento rezultatai

Bandymo numeris	Komandos „kairėn“ tikslumas	Komandos „dešinėn“ tikslumas	Komandos „pirmyn“ tikslumas	Bendras tikslumas
1.	100 %	70 %	85 %	85 %
2.	100 %	72,5 %	87,5 %	86,67 %
3.	100 %	77,5 %	90 %	89,16 %
4.	97,5 %	75 %	90 %	87,5 %
5.	100 %	55 %	95 %	83,33 %
Bendras komandos tikslumas	99,5 %	70 %	89,5 %	86,33 %




28 pav. Pirmojo subjekto valdymo tikslumas.

28 pav. pateiktas pirmojo subjekto valdymo tikslumas kiekvieno bandymo metu. Grafike pateiktas kiekvienos valdymo komandos tikslumo kitimas kiekvieno bandymo metu. Matome, kad pirmajam subjektui tiksliausiai sekėsi atlikti komandas „kairėn“ ir „dešinėn“ – jų tikslumas didesnis arba lygus 90%. Komandos „kairėn“ tikslumas yra mažesnis, kiekvieno bandymo metu jis mažėja.




29 pav. Antrojo subjekto valdymo tikslumas.

29 pav. pateiktas antrojo subjekto valdymo tikslumas kiekvieno bandymo metu. Grafike pateiktas kiekvienos valdymo komandos tikslumo kitimas kiekvieno bandymo metu. Matome, kad antrajam subjektui tiksliausiai sekėsi atlikti komandas „kairėn“ ir „dešinėn“ – jų tikslumas didesnis arba lygus 95%. Komandos „pirmyn“ tikslumas svyruoja tarp 70 % ir 90 %. Antrojo bandymo metu jis pasiekia žemiausią ribą, tolesnių bandymų metu tikslumas tolygiai auga, kol penktojo bandymo metu pasiekia 90%.




30 pav. Trečiojo subjekto valdymo tikslumas.

30 pav. pateiktas trečiojo subjekto valdymo tikslumas kiekvieno bandymo metu. Grafike pateiktas kiekvienos valdymo komandos tikslumo kitimas kiekvieno bandymo metu. Matome, kad trečiajam subjektui tiksliausiai sekėsi atlikti komandas „kairėn“ ir „dešinėn“ – šių komandų bendras tikslumas, atitinkamai – 94,5% ir 95 %. Komandos „dešinėn“ tikslumas atėjo bandymo metu nukrenta iki 82,5%. Tolimesniuose bandymuose jis yra didesnis už 95%. Komandos „pirmyn“ tikslumas yra žemiausias lyginant su kitomis dviem komandomis, tačiau jos tikslumas stabiliai auga iki ketvirtojo bandymo. Penktajame bandyme šios komandos tikslumas ženkliai krenta žemyn (85%). Tai gali įtakoti nuovargis.




31 pav. Ketvirtojo subjekto valdymo tikslumas.

31 pav. pateiktas ketvirtojo subjekto valdymo tikslumas kiekvieno bandymo metu. Grafike pateiktas kiekvienos valdymo komandos tikslumo kitimas kiekvieno bandymo metu. Matome, kad ketvirtajam subjektui tiksliausiai sekėsi vykdyti komandą „kairėn“ – tikslumas kiekvieno bandymo metu yra didesnis nei 95%. Komandų „dešinėn“ ir „pirmyn“ tikslumas šiek tiek žemesnis – svyruoja tarp 72,5% ir 95%. Iš grafiko galima pastebėti, kad padidėjus komandos „dešinėn“ tikslumui, sumažėja komandos „pirmyn“ tikslumas ir atvirkščiai.




32 pav. Penktojo subjekto valdymo tikslumas

32 pav. pateiktas penktojo subjekto valdymo tikslumas kiekvieno bandymo metu. Grafike pateiktas kiekvienos valdymo komandos tikslumo kitimas, kiekvieno bandymo metu. Matome, kad penktajam subjektui tiksliausiai sekėsi atlikti komandas „kairėn“ ir „pirmyn“ – komandų tikslumai svyruoja nuo 85% iki 100%. Ypatingai tiksliai buvo vykdoma komanda „kairėn“, kurios bendras tikslumas visų bandymų metu – 99,5%. Komandos „pirmyn“ tikslumas nuosekliai auga nuo 85% iki 95%. Žemiausias tikslumas stebimas vykdant komandą „dešinėn“. Jos tikslumas didėja iki trečiojo bandymo, po to pradeda kristi, penktojo bandymo metu nukrenta iki 55%. Tai gali įtakoti nuovargis.




33 pav. Bandymų tikslumų pokytis kiekvienam subjektui

33 pav. pateiktas kiekvieno subjekto roboto valdymo progresas. Matome, kad pirmojo subjekto valdymo tikslumas pirmo etapo metu buvo aukščiausias iš visų. Kitų bandymų metu tikslumas mažėja. Tai gali įtakoti nuovargis. Trečiasis, ketvirtasis ir penktasis subjektai gerina savo valdymo tikslumo rezultatus iki tam tikros ribos, po to jų tikslumas taip pat pradeda kristi – galima nuovargio įtaka. Antrajam subjektui negalioja šis dėsnis. Antrojo bandymo metu jo valdymo tikslumas krenta, tačiau kitų bandymų metu tolygiai kyla aukštyn iki pat penktojo bandymo (žr. 33 pav.).



34 pav. Bendras kiekvieno subjekto valdymo tikslumas.

34 pav. pateikti kiekvieno subjekto bendri (suvidurkinti) roboto valdymo tikslumai.



35 pav. Atskirų komandų tikslumo grafikas.

35 pav. pateikti atskirų komandų tikslumai, gauti suvidurkinus visų subjektų valdymo rezultatus. Matome, kad didžiausias tikslumas yra komandos „kairėn“ – 95,6%. Komandų „dešinėn“ ir „pirmyn“ tikslumai siekia, atitinkamai – 88,3% ir 87,3%.

5.2. EEG duomenų apdorojimo ICA metodu tyrimas

5.2.1. Tyrimo aprašymas

Tyrimui buvo naudojami EEG duomenys iš BBCI EEG duomenų bibliotekos (<http://www.bbc.de/competition/iii/>). Duomenys buvo nuskaityti nuo sveiko žmogaus pagal metodiką pateiktą [52]. Duomenų apdorojimui buvo taikomas *fastICA* MATLAB funkcijų programinis paketas (<http://research.ics.aalto.fi/ica/fastica/>). Duomenys buvo apdorojami keičiant *fastICA* algoritmo iteracijų skaičių. Bandymai buvo atliekami su 100, 1000, 10000 iteracijų. Duomenų klasifikavimui buvo taikomas SVM metodas su tiesine branduolio funkcija.

5.2.2. Tyrimo rezultatai

7 lentelė. EEG duomenų apdorojimo ICA metodu tyrimo rezultatai

Apdorojimo metodas	“Precision” metrika	“Recall” metrika	Tikslumas (%)	F-metrika
Nenaudojamas	0.9315	0.8608	89.0785	0.8947
ICA (iteracijų sk. 100)	0.4658	0.4964	49.8294	0.4806
ICA (iteracijų sk. 1000)	0.5479	0.5063	50.8532	0.5263
ICA (iteracijų sk. 10000)	0.4589	0.4621	46.4164	0.4605

Iš 7 lentelės matome, kad apdorojant EEG duomenis ICA metodas nepasiteisino. Naudojant ICA metodą klasifikavimo rezultatai gerokai pablogėjo, nei netaikant jokio metodo. Toks rezultatas galėjo atsirasti, todėl, kad buvo apdorojamas vienas signalas. ICA metodas geriausiai veikia, kai apdorojama aibė vienas kitą įtakančių signalų (aibė tarpusavyje susimaišiusių signalų).

Naudojamo duomenų rinkinio signalo tikslumas netaikant jokio apdorojimo yra aukštas – siekia 89,079 %. Tai rodo, kad triukšmo lygis šiuose duomenyse yra gana žemas ir sudėtinga išskirti nepriklausomas komponentes.

6. IŠVADOS

Šiame darbe buvo:

1. Išanalizuota neuroninės kompiuterio sąsajos sritis – apžvelgti taikomi metodai, įėjimo signalai, neuroninės kompiuterio sąsajos tipai, egzistuojančios sistemos.
2. Suprojektuota ir realizuota neuroninės kompiuterio sąsajos sistema, kurios pagalba galima nuskaityti EEG ir EMG duomenis, šiuos duomenis apdoroti FFT ir DCT metodais ir klasifikuoti neuroniniais tinklais, SVM arba panaudojant signalo lygį. Klasifikavimo rezultatas – vežimėlio tipo roboto arba virtualaus įrenginio valdymo komandos.
3. Pasiūlytas ir aprašytas trijų komandų vežimėlio tipo roboto valdymo panaudojant paviršinio EMG signalo lygį metodas.
4. Atlikti roboto valdymo eksperimentai naudojant pasiūlytą metodą.

Atlikus eksperimentus galima teigti, kad:

1. Valdymas panaudojant paviršinio EMG signalo lygį yra gana efektyvus metodas vežimėlio tipo robotų valdymui – bendras penkių eksperimento dalyvių (kiekvienas iš penkių subjektų atliko po 5 bandymus) valdymo tikslumas siekia 90,41 %. Žemiausias valdymo tikslumas siekia 86,33 %, o aukščiausias – 93 %.
2. Iš 33, 34, 35, 36 ir 37 pav. matome, kad kiekvienas žmogus, kai kurias komandas atlieka geriau nei kitas. Vieną (žr. 35, 36 pav.) arba dvi (žr. 33, 34, 37 pav.) komandas parastai sekasi atlikti geriau už likusias. Tai gali priklausyti nuo konkretaus žmogaus dominuojančių galvos raumenų.
3. Dauguma silpniau pradėjusių eksperimento subjektų sugebėjo pagerinti savo valdymo rezultatus tolesniais bandymais (žr. 38 pav.). Tačiau ties 4-5 bandymu galima pastebėti valdymo tikslumo kritimą, tai gali įtakoti atsirandantis nuovargis. Išimtis būtų antrasis subjektas, kuriam nepasireiškė valdymo tikslumo sumažėjimas paskutiniuose bandymuose (žr. 38 pav.).
4. Išvedus bendrus valdymo komandų tikslumų vidurkius, matome, kad tiksliausiai sekasi atlikti komandą „kairėn“ – 95,6 % tikslumas (žr. 40 pav.). Komandos „dešinėn“ bendras tikslumas siekia 88,3 %, o komandos „pirmyn“ – 87,3 %.
5. Šiame straipsnyje aprašyti eksperimentai buvo atliekami su 5 sek. pertrauka tarp valdymo komandų. Taikant sistemą praktikoje, pavyzdžiui, valdant invalido vežimėlį, šis intervalas tarp valdymo komandų sukeltų nepatogumų. Eksperimento metu toks laiko intervalas buvo naudojamas todėl, kad priešingu atveju susiduriama su problema: jeigu komandos yra vykdomos iš karto viena po kitos, signalo lygis pradeda smarkiai svyruoti į priešingą pusę. Pasireiškia signalo „drebjimo“ efektas. Tam gali turėti įtakos mūsų naudota EMG nuskaitymo įranga. Šį efektą galima būti mėginti sumažinti taikant įvairias glotninimo funkcijas ar netiesinius operatorius ir tokiu būdu trumpinti laiko intervalą tarp valdymo komandų.
6. Įvertinus aukščiau išvardintus punktus galima teigti, kad valdymas panaudojant paviršinio EMG signalo lygį yra vertas dėmesio ir tolimesnių tyrimų bei taikymų.

7. LITERATŪRA

- [1] Chambayil, B., Singla, R., Jha, R. Virtual keyboard BCI using Eye blinks in EEG. *Wireless and Mobile Computing, Networking and Communications (WiMob), 2010 IEEE 6th International Conference*, 466 – 470, 2010

- [2] Zhang, Y., Dai, L., Luo, Y., Hu, H. Design of a Surface EMG – Based Human – Machine Interface for an Intelligent Wheelchair. *Electronic Measurement & Instruments (ICEMI), 2011 10th International Conference*, 3, 132-136, 2011
- [3] Wei, L., Hu, H., Yuan, K. Use of Forehead Bio-Signals for Controlling an Intelligent Wheelchair. *Robotics and Biomimetics, 2008. ROBIO 2008. IEEE International Conference*, 108-113, 2009.
- [4] Hashimoto, M., Takahashi, K., Shimada, M. Wheelchair Control Using an EOG- and EMG-Based Gesture Interface. *Advanced Intelligent Mechatronics, 2009. AIM 2009. IEEE/ASME International Conference*, 1212-1217, 2009.
- [5] Martisius, I., Vasiljevas, M., Sidlauskas, K., Turcinas, R., Plauska, I., Damasevicius, R. Design of a Neural Interface Based System for Control of Robotic Devices. *Information and software technologies : 18th International Conference, ICIST 2012, Kaunas, Lithuania*, 297-311, 2012.
- [6] Vasiljevas, M., Šidlauskas, K. Roboto valdymo sistemos neuroninės kompiuterio sąsajos tyrimas. *Informacinės technologijos : 18-oji tarpuniversitetinės tarptautinės magistrantų ir doktorantų konferencijos "Informacinė visuomenė ir universitetinės studijos" (IVUS 2013) medžiaga*, 181-184, 2013
- [7] Arduino 4 WD robotas. [Žiūrėta 2013-04-04]. Prieiga internete: <<http://www.robotshop.com/dfrobot-4wd-arduino-mobile-platform-3.html>>
- [8] Zhou, W. Nonlinear feature comparison of EEG using Correlation Dimension and Approximate Entropy. *Biomedical Engineering and Informatics (BMEI), 2010 3rd International Conference*, 978-981, 2010
- [9] Allanson, J., Fairclough, S. H. A research agenda for physiological computing. *Interacting with Computers*, 16, 857 – 878, 2004
- [10] Wolpaw, J.R., Birbaumer, N., McFarland, D.J., Pfurtscheller, G., Vaughan, T.M. Brain–Computer Interfaces for Communication and Control. *Clinical Neurophysiology* 113, 767–791, 2002
- [11] Pfurtscheller, G., Neuper, C., Edlinger, A.G. Foot and Hand Area Mu Rhythms. *International Journal of Psychophysiology*, 26, 121–135, 1997
- [12] Luck, S. J. An Introduction to the Event-Related Potential Technique. *The MIT Press*, 2005, ISBN 0-262-12277-4
- [13] Kramer, A.F. Event-related brain potentials. *Psychophysiology and the Electronic Workplace*. Wiley, London, 197–222, 1987
- [14] Nigg, B.M., Herzog W. Biomechanics of the Musculo-Skeletal system. Wiley. 349, 1999

- [15] Creel, D. J. The Electroretinogram and Electro-oculogram: Clinical Applications. [Žiūrėta 2013-05-09]. Prieiga internete: <<http://webvision.med.utah.edu/book/electrophysiology/the-electroretinogram-clinical-applications/>>
- [16] Swami, P., Singh, R., Gandhi, T., Anand, S. A Novel Embedded Approach for the Development of Wireless Electro-oculogram Based Human-Computer Interface. *2012 2nd IEEE International Conference on Parallel, Distributed and Grid Computing*, 252-255, 2012.
- [17] Boutcher, S.H., Nugent, F.W., McLaren, P.F., Weltman, A.L. Heart Period Variability of Trained and Untrained Men at Rest and during Mental Challenge. *Psychophysiology*, 35, 16–22, 1998
- [18] Gilleade, K., Allanson, J. A Toolkit for Exploring Affective Interface Adaptation in Videogames. *Proceedings of the Human-Computer Interaction International (HCHI03)*, Crete, Greece, 2003.
- [19] Hoffmann, U., Vesin, J.M. Ebrahimi, T. Recent advances in brain-computer interfaces. *IEEE 9th Workshop on Multimedia Signal Processing, MMSP 2007*, 17, 2007.
- [20] „Biomedical“ EEG kepurės. [Žiūrėta 2013-05-16] Prieiga internete: <<http://bio-medical.com/products/eeg-caps.html>>
- [21] „NeXus“ EEG skaitymo įrenginiai. [Žiūrėta 2013-05-16] Prieiga internete: <<http://www.mindmedia.nl/CMS/en/products.html>>
- [22] „Emotiv“ EEG skaitymo įrenginiai. [Žiūrėta 2013-05-16] Prieiga internete: <<http://www.emotiv.com/>>
- [23] „NeuroSky MindSet“ EEG skaitymo įrenginys. [Žiūrėta 2013-05-16] Prieiga internete: <<http://www.neurosky.com/>>
- [24] „OCZ NIA“ EEG ir EMG skaitymo įrenginys. [Žiūrėta 2013-05-16] Prieiga internete: <<http://www.bcinet.com/products/>>
- [25] Vasiljevas, M., Turčinai, R., Martišius I. Netiesinių operatorių taikymas EEG duomenų apdorojimui. *Informacinės technologijos: 17-oji tarpuniversitetinė magistrantų ir doktorantų konferencija: konferencijos pranešimų medžiaga*, 23-26, 2012
- [26] Shen, K. Q., Ong, C. J., Li, X. P., Hui, Z., Wilder-Smith E. P. A Feature Selection Method for Multilevel Mental Fatigue EEG Classification. *Biomedical Engineering, IEEE Transactions*, 54 (7), 1231-1237, 2007
- [27] Bowman, T. VR meets Physical Therapy. *Communications of the ACM*, 40 (8), 59–60, 1997
- [28] Saridis, G.N., Gootie, T.P. EMG Pattern Analysis and Classification for a Prosthetic Arm. *IEEE Engineering in Medicine and Biology* 29, 403–411, 1982

- [29] Kelly, M.F., Parker, P.A., Scott, R.N. The application of neural networks to myoelectric signal analysis: a preliminary study. *IEEE Engineering in Medicine and Biology*, 37, 221–229, 1990
- [30] Knapp, R.B., Lusted, H.S. Bioelectric Controller for Computer Music Applications. *Computer Music Journal* 14 (1), 42–47, 1990
- [31] Rosenberg, R. Computing without Mice and Keyboards: Text and Graphic Input Devices for Mobile Computing. PhD Thesis, UCL, London, 1998
- [32] Lusted, H.S., Knapp, R.B., Benjamin, R. Controlling Computers with Neural Signals. *Scientific American*, 58–63, 1996
- [33] Fairclough, S.H., Fundamentals of Physiological Computing, *Interact. Comput.* 2008
- [34] Prinzel, L.J. Research in Hazardous States of Awareness and Physiological Factors in Aerospace Operations (No. NASA/TM-2002-211444): NASA, 2002
- [35] Schroeder, A., & Wirsing, M. Developing Physiological Computing Systems: Challenges and Solutions. [Žiūrėta: 2013-05-09] Prieiga internete: <http://pmi.pst.ifi.lmu.de/text_files/0000/0006/se2012.pdf>
- [36] Chanel, G., Rebetez, C., Bétrancourt, M., Pun, T. Emotion Assessment From Physiological Signals for Adaptation of Game Difficulty. *Systems, Man and Cybernetics, Part A: Systems and Humans, IEEE Transactions*, 41 (6), 1052 – 1063, 2011
- [37] Nakayama, K., Kaneda, Y., Hirano, A. A Brain Computer Interface Based on FFT and multilayer neural network - feature extraction and generalization. *Intelligent Signal Processing and Communication Systems, 2007. ISPACS 2007. International Symposium*, 826 – 829, 2007
- [38] Rao, K., Yip, P. Discrete Cosine Transform: Algorithms, Advantages, Applications, *Boston: Academic Press*, ISBN 0-12-580203-X, 1990
- [39] Martišius, I., Damaševičius, R., Jusas, V., Birvinskas, D. Using Higher Order Nonlinear Operators for SVM Classification of EEG Data. *Electronics and Electrical Engineering. – Kaunas: Technologija*, 3(119), 99–102, 2012.
- [40] Haykin, S. Neural Networks: A Comprehensive Foundation. *Prentice Hall*, 1998
- [41] Freund, Y., Schapire R. E. Large Margin Classification using The Perceptron Algorithm. *Machine Learning*, 37 (3), 277-269, 1999
- [42] Karatzoglou, A., Meyer, D., Hornik, K. Support Vector Machines in R. *Journal of Statistical Software*, 15 (9), 2006
- [43] Bishop, Ch. M. Pattern Recognition and Machine Learning. ISBN-10: 0-387-31073-8, 2006
- [44] Shlens, J. A Tutorial on Principal Component Analysis. New York, 2009

- [45] Hyvärinen, A., Oja, E. Independent Component Analysis: Algorithms and Application. *Neural Networks*, 13(4-5), 411-430, 2000
- [46] Hyvärinen, A., Karhunen, J., Oja, E. Independent Component Analysis, New York: Wiley, 2001
- [47] BCI2000 programinis paketas. [Žiūrėta 2011-11-13] Prieiga internete: <<http://bci2000.org/BCI2000/Home.html>>
- [48] OpenViBE programinis paketas. [Žiūrėta 2011-11-13] Prieiga internete: <<http://openvibe.inria.fr/>>
- [49] BCILAB programinis paketas. [Žiūrėta 2011-11-13] Prieiga internete: <<http://sccn.ucsd.edu/wiki/BCILAB>>
- [50] BCI++ programinis paketas. [Žiūrėta 2011-11-13] prieiga internete: <http://www.sensibilab.campuspoint.polimi.it/index.php?option=com_content&view=section&layout=blog&id=18&Itemid=144>
- [51] xBCI programinis paketas. [Žiūrėta 2011-11-13] prieiga internete: <<http://xbci.sourceforge.net/>>
- [52] Lal, T. N., Hinterberger, T., Widman, G., Schroeder, M., Hill, J., Rosenstiel, W., Elger, C., Schölkopf, B., Birbaumer, N. Methods Towards Invasive Human Brain Computer Interfaces. *Advances in Neural Information Processing System*, 17, 737-744, 2005.
- [53] Allison, B. Z., Leeb, R., Brunner, C., Muller-Putz G. R., Bauernfeind, G., Kelly J. W., Neuper, C. Toward Smarter BCIs: Extending BCIs Through Hybridization and Intelligent Control. *Journal of neural engineering*, 9(1), 2012