



KAUNO TECHNOLOGIJOS UNIVERSITETAS
ELEKTROS IR ELEKTRONIKOS FAKULTETAS

Vytenis Gavelis

**MELŲ SKALĖS KEPSTRO KOEFICIENTŲ PANAUDOJIMO
ELEKTROMIOGRAMOS SIGNALO ANALIZEI IR JUDESIŲ
ATPAŽINIMUI TYRIMAS**

Baigiamasis magistro projektas

Vadovas
prof. dr. Arūnas Lipnickas

KAUNAS, 2016

KAUNO TECHNOLOGIJOS UNIVERSITETAS
ELEKTROS IR ELEKTRONIKOS FAKULTETAS
AUTOMATIKOS KATEDRA

MELŲ SKALĖS KEPSTRO KOEFICIENTŲ PANAUDOJIMO
ELEKTROMIOGRAMOS SIGNALO ANALIZEI IR JUDESIŲ
ATPAŽINIMUI TYRIMAS

Baigiamasis magistro projektas
Valdymo technologijos 621H66001

Vadovas

(parašas) **prof. dr. Arūnas Lipnickas**
(data)

Recenzentas

(parašas) **doc. dr. Kastytis Ratkevičius**
(data)

Projektą atliko

(parašas) **Vytenis Gavelis**
(data)

KAUNAS, 2016



KAUNO TECHNOLOGIJOS UNIVERSITETAS
ELEKTROS IR ELEKTRONIKOS FAKULTETAS

(Fakultetas)

Vytenis Gavelis

(Studento vardas, pavardė)

Valdymo technologijos 621H66001

(Studijų programos pavadinimas, kodas)

Baigiamojo projekto „Melų skalės kepstro koeficientų panaudojimo elektromiogramos signalo analizei ir judesių atpažinimui tyrimas“

AKADEMINIO SAŽININGUMO DEKLARACIJA

20 16 . Gegužės 23 .
Kaunas

Patvirtinu, kad mano **Vytenio Gavelio** baigiamasis projektas tema „Melų skalės kepstro koeficientų panaudojimo elektromiogramos signalo analizei ir judesių atpažinimui tyrimas“ yra parašytas visiškai savarankiškai, o visi pateikti duomenys ar tyrimų rezultatai yra teisingi ir gauti sąžiningai. Šiame darbe nei viena dalis nėra plagijuota nuo jokių spausdintinių ar internetinių šaltinių, visos kitų šaltinių tiesioginės ir netiesioginės citatos nurodytos literatūros nuorodose. Įstatymų nenumatytų piniginių sumų už šį darbą niekam nesu mokėjęs.

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

(vardą ir pavardę įrašyti ranka)

(parašas)

Turinys

Santrumpų ir ženklų aiškinimo žodynas	7
Įvadas	8
1. Literatūros apžvalga	10
1.1. Elektromiografija	10
1.2. Melų skalės kepstro koeficientai	13
1.3. Klasifikatoriai	16
1.3.1. Diskriminanto analizės klasifikatorius	16
1.3.2. Artimiausių kaimynų klasifikatorius	18
1.3.3. Dirbtinis neuroninis tinklas	20
1.3.4. Radialinių bazinių funkcijų klasifikatorius	21
1.3.5. Medžio tipo klasifikatorius.....	23
1.3.6. Miško tipo klasifikatorius.....	24
1.4. Klasifikatorių lyginimas	25
2. Tiriamoji dalis:	27
2.1. Duomenų rinkimas	27
2.2. Melų skalės kepstro koeficientų išskyrimas.....	28
2.3. Penkių klasių klasifikatoriaus atpažinimo sistema.....	30
2.4. Šešių klasių klasifikatoriaus atpažinimo sistema	32
2.5. Hierarchinė dviejų pakopų atpažinimo sistema	37
2.6. Atpažinimo sistemų struktūrų palyginimas.....	43
Išvados	46
Informacijos šaltinių sąrašas	48

Gavelio V. Melų skalės kepstro koeficientų panaudojimo elektromiogramos signalo analizei ir judesių atpažinimui tyrimas. Valdymo sistemų magistro baigiamasis projektas / vadovas prof. dr. Arūnas Lipnickas; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas, Automatikos katedra.

Kaunas, 2016. 50 psl.

SANTRAUKA

Žmogaus ir mašinos sąsaja yra greitai besivystanti tyrimų sritis, reikalaujanti naujų analizės metodų. Elektromiograma yra vienas iš būdų, leidžiančių valdyti įrenginius žmogaus kūnu.

Darbe supažindinama su elektromiogramos signalo specifika, analize, galimybe ją panaudoti prietaisų valdymui pasitelkiant melų skalės kepstro koeficientus, dažniausiai mokslininkų ir inžinierių naudojamus garso (kalbos, muzikos) analizei.

Darbo eksperimentinėje dalyje nuskaitomi penki fiksuoti atskirų plaštakos pirštų judesiai (nykščio, rodomojo, didžiojo, bevardžio ir mažyljo), kuriuos fiksuoja elektromiogramos registratorius. Įvairių tipų klasifikatoriai (diskriminanto analizės, artimiausių kaimynų, dirbtinio neuroninio tinklo, radialinių bazinių funkcijų, medžio ir miško) apmokomi su gautaisiais duomenimis, siekiant išsiaiškinti, kokios struktūros ir tipo klasifikatoriai geriausiai atpažįsta judesius pagal melų skalės kepstro koeficientus, atsižvelgiant į sistemos greitaveiką (mokymo bei testavimo laikus). Taip pat palyginamos dvi atpažinimo sistemos struktūros – tai šešių klasių klasifikatoriaus ir hierarchinio. Taip pat ištirta, kokius melų skalės kepstro koeficientų radimo algoritmo parametrus nustačius klasifikatoriai pasiekia geriausią rezultatą.

Reikšminiai žodžiai:

Elektromiograma, melų skalės kepstro koeficientai, mašininis mokymas, žmogaus ir mašinos sąsaja, klasifikatoriaus

Gavelis, V. Research of Mel-Frequency Cepstrum Coefficients Application for Electromyogram Signal Analysis and Motion Recognition. Master project of control systems / supervisor prof. dr. Arūnas Lipnickas; Kaunas University of Technology, Faculty of Electrical and Electronics Engineering, department of Automation

Kaunas, 2016. 50p.

SUMMARY

Human-machine interface is a rapidly growing research topic which requires new analysis methods. Electromyogram is one such way to control devices using human body.

Electromyogram signal specifics, analysis and potentiality to use it to control devices using mel-frequency cepstrum coefficients (which is generally used in sound such as music and voice recognition) are presented in this work.

The recording of all five hand fingers (thumb, index, middle, ring and little) movements using a logger is presented in the experimental part of this work. Various types of classifiers (discriminant analysis, nearest neighbours, artificial neural network, radial basis function, decision tree and tree ensemble) are trained with mel-frequency cepstrum coefficients extracted from finger movement recording and then recognize those using separate testing data. This is done in order to investigate which classifiers are best suited for classification using mel-frequency cepstrum of electromyogram signal. Training and testing time is also kept in mind. It is also investigated which recognition system structure (one classifier with 6 classes and two serial hierarchical classifiers) is the best for the task. Best parameters for mel-frequency cepstrum coefficient extraction are found in this work.

Keywords:

Electromyogram, mel-frequency cepstrum coefficients, machine learning, HMI, classifier

Santrumpų ir ženklų aiškinimo žodynas

MSKK–melų skalės kepstro koeficientai.

DNT – dirbtinis neuroninis tinklas.

AKK – artimiausių kaimynų klasifikatorius.

RBFK – radialinių bazinių funkcijų klasifikatorius.

DAK – diskriminanto analizės klasifikatorius.

MeTK – medžio tipo klasifikatorius.

MiTK – miško tipo klasifikatorius.

Kl. – klasifikatorius.


Įvadas

Vystantis technologijoms ir augant žmonijos lūkesčiams apjungti elektromechanines ir biologines sistemas, žmogaus ir mašinos sąsajos vystymas tampa prioritetine sritimi. Naujovių laukiama bionikos, karinių įrenginių (egzoskeletų, naikintuvų) ir pramogų srityse [1]. Vienas iš būdų susieti biologinę ir elektromechaninę sistemą yra elektromiograma.

Elektromiogramos veikimo principas yra elektros potencialo pokytis raumens paviršiuje jam susitraukiant. Šiuos pokyčius galima nuskaityti (1 pav.) ir analizuoti. Tačiau neapdorotą signalą naudoti judesių atpažinimui yra nepatogu, tad reikalingas būdas išskirti svarbiausius požymius, leidžiančius efektyviai klasifikuoti naudotojo veiksmus. Vienas iš galimų požymių išskyrimo metodų yra melų skalės kepstro koeficientų (MSKK) radimas. MSKK daugiausiai yra naudojami garso (balso, muzikos) atpažinimui bei analizei [2], todėl svarbu yra išsiaiškinti, ar tai tinka judesių atpažinimui ir kokių patikimumu galima naudotis šiuo metodu.

Dėl šio tikslo darbe iš plaštakos pirštų (nykščio, rodomojo, didžiojo, bevardžio ir mažylis) judesių įrašų (matuojama ant rankos) yra išskiriami MSKK, kuriais apmokomi šešių tipų klasifikatoriai (diskriminanto analizės, artimiausių kaimynų, dirbtinio neuroninio tinklo, radialinių bazinių funkcijų, medžio ir miško) ir atliekamas klasifikatorių testavimas bei rezultatų lyginimas. Eigoje randami parametrai, kuriuos nustačius klasifikatoriai pasiekia geriausius rezultatus.

Taip pat yra tikrinama, kuri atpažinimo sistemos struktūra yra geresnė – šešių klasių (visų rankos pirštų ir pauzės) klasifikatoriaus ar hierarchinė dviejų klasifikatorių (vienas klasifikatorius fiksuoja, ar buvo įvykdytas judesys, ar buvo pauzė, o kitas – koks judesys buvo atliktas) struktūra.



1 pav. Elektromiogramos registravimo principas

Darbo tikslas:

Sukurti atskirų plaštakos pirštų judesių atpažinimo sistemą, naudojant elektromiogramos signalus bei melų skalės kepstro koeficientus ir ištirti skirtingų klasifikatorių efektyvumą judesių identifikavimui.

Darbo uždaviniai:


1. Apžvelgti elektromiogramos veikimo principus.
2. Išsiaiškinti melų skalės kepstro koeficientų išskyrimo iš signalo algoritmą.
3. Apžvelgti, kokie klasifikatoriai gali būti naudojami judesių atpažinimui ir kaip jie veikia.
4. Įrašyti pirštų judesius ir išskirti melų skalės kepstro koeficientus.
5. Rasti geriausius parametrus melų skalės kepstro koeficientų išskyrimui.
6. Apmokyti ir išbandyti pasirinktus klasifikatorių tipus, juos palyginti.
7. Išsiaiškinti, kuri atpažinimo sistemos struktūra yra geresnė.
8. Suformuluoti rezultatus ir pateikti darbo išvadas.

1. Literatūros apžvalga

1.1. Elektromiografija

Remiantis šaltiniu [3], elektromiografija yra raumenų darbo stebėseną analizuojant elektrinius signalus, kurie sukuriama raumeniui valingai arba nevalingai susitraukiant.

Valingas raumens susitraukimas vadinamas įtempimu. Funkcinis raumens įtempimo vienetas vadinamas motoriniu vienetu, kuris sudarytas iš vieno alfa motorinio neurono (1.1 pav.) ir visų skaidulų, kurias tas neuronas veikia. Skaidulos susitraukia, kai motorinio nervo impulso potencialas pasiekia depoliarizacijos slenkstį. Depoliarizacija generuoja elektromagnetinį lauką ir potencialas išmatuojamas kaip įtampa. Esant stipresniam raumens sutraukimui, elektromiogramos signalo amplitudė yra didesnė. Depoliarizacija, kuri driekiasi per raumens membraną, yra veiksmo potencialas. Elektromiogramos signalas yra algebrinė suma visų motorinių vienetų veiksmo potencialų, esančių elektrodo pritvirtinimo vietoje. Taigi, visuomet vienu elektrodu yra nuskaitomi potencialai iš daugiau kaip vieno motorinio vieneto, kadangi raumenų skaidulos, priklausančios skirtingiems motoriniams vienetams, yra išdėstytos netvarkingai vienos tarp kitų.



1.1 pav. Persipynę motoriniai neuroni, veikiantys atskiras to paties raumens skaidulas (pav. iš [4])

Kiekvienas neuronas gali būti prijungtas prie nuo 3 iki 2000 skaidulų. Raumenys, valdantys preciziškesnius judesius, turi mažesnę raumeninių skaidulų kiekį, tenkantį vienam motoriniam neuronui (paprastai mažiau nei 10), negu grubesnius judesius valdančius (paprastai po 100-1000 skaidulų). Sutraukiant raumenį pirmiausia aktyvuojami tie neuroni, kurie turi mažesnę kiekį raumeninių skaidulų.

Elektromiogramos signalo amplitudę gali veikti šie faktoriai:

- Raumens susitraukimo stiprumas.
- Raumens skaidulos skersmuo.
- Atstumas tarp aktyvios raumens skaidulos ir matavimo vietos (riebalinio sluoksnio storio).
- Elektrodo filtravimo savybės.

Taigi, svarbu yra pašalinti visus įmanomus trikdžių šaltinius, pasirinkti adekvatų elektrodo tipą ir stiprintuvą.

Yra dviejų tipų elektrodai: paviršiniai (1.2 pav.) ir vieliniai (1.3 pav.).



1.2 pav. Paviršiniai elektromiogramos elektrodai (pav. iš [5])



1.3 pav. Vielinis elektromiogramos elektrodas (pav. iš [6])

Paviršiniai elektrodai yra skirstomi į dvi grupes: aktyviusius (su įtaisytu stiprintuvu, be to, nereikalingas gelis) ir pasyviuosius. Pasyvieji elektrodai neturi stiprintuvo ir papildomos filtracijos, todėl

privalu sumažinti odos ekranavimą geliu. Taip pat, nesant vidinio stiprintuvo ir pirminės filtracijos, išorinis stiprintuvas (1.4 pav.) stiprina ne tik naudingą signalą, bet ir pašalinius triukšmus.

Pagrindiniai paviršinių elektrodų privalumai [7]:

- Lengvai paruošiami pakartotiniam naudojimui;
- Lengvai pritvirtinami prie subjekto;
- Neskausmingi;
- Naidotini subjektui judant.

Trūkumai:

- Didelė matavimo zona (patenka daugiau motorinių neuronų aprėpiamų skaidulų);
- Naidotini tik paviršiniams raumenims.

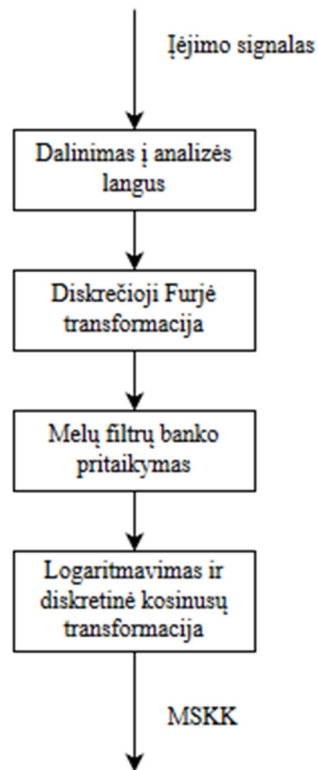


1.4 pav. Pramoninis elektromiografijos aparatas „Nu-Tek MaxiPlus2“ [8]

1.2. Melų skalės kepstro koeficientai

Melų skalės kepstro koeficientai (MSKK) dažniausiai yra naudojami balso (ar kokio nors kito garsinės prigimties signalo, pavyzdžiui muzikos) analizei ir atpažinimui [9]. Jų dėka iš signalo yra išskiriami naudingą informaciją nešantys požymiai, o triukšmai ir kiti nereikalingi komponentai atmetami.

MSKK išskyrimas (1.5 pav.) yra pradedamas signalo suskaidymu į nuo signalo tipo priklausančio dydžio analizės langus. Garsiniam signalui labiausiai tinkami yra 20-40 ms ilgio langai [10]. Jam esant per trumpam negaunamas reikiamas bandinių kiekis, reikalingas patikimam spektriniam įverčiui, o esant per dideliame – signalas per daug kinta lango metu, taigi prarandama informacija.



1.5 pav. MSKK išskyrimas iš signalo

Toliau reikalinga suskaičiuoti energijos spektrą kiekvienam analizės langui. Energijos spektras skaičiuojamas įėjimo signalui taikant diskretingą Furjė transformaciją:

$$\tilde{x}(k) = \sum_{n=0}^{N_w-1} x(n)W(n)e^{-\frac{j2\pi nk}{N_w}}; \quad 0 \leq k < N_w. \quad (1)$$

čia $x(n)$ – įėjimo signalas;
 $W(n)$ – Hanning'o lango funkcija;
 N_w – laiko intervalas [ms].

Hanning'o lango funkcija:

$$W(n) = \beta_w \left(0,5 - 0,5 \cos \left(\frac{2\pi n}{N_w - 1} \right) \right); \quad 0 \leq n < N_w. \quad (2)$$

čia β_w – normalizacijos faktorius.

Imamos tik teigiamos vertės:


$$X_k = |\tilde{x}(k)|^2; \quad 0 \leq k < K. \quad (3)$$

čia $K = \frac{1}{2} N_w$.

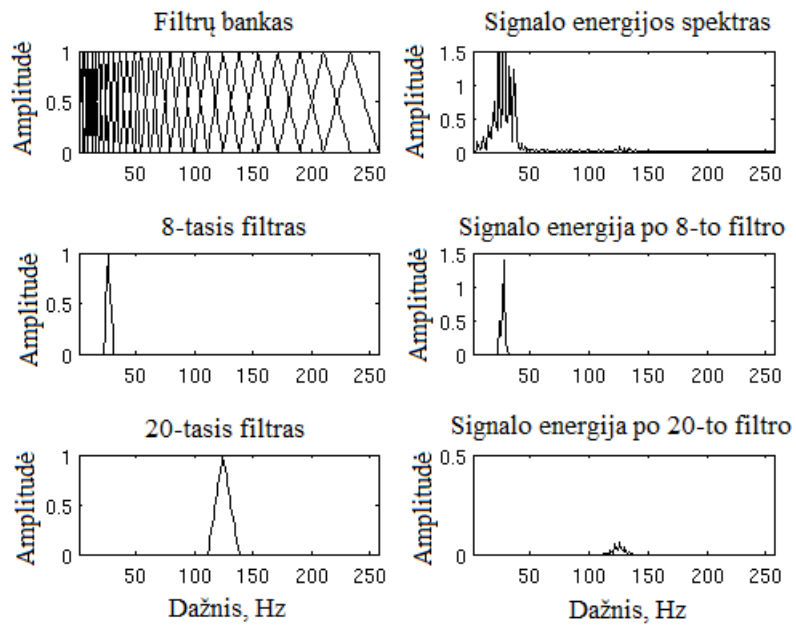
Melų filtrų bankais (1.6 pav.) signalo dažnis yra suskirstomas į fiksuoto pločio sritis, kurioms priskiriamos dažnių juostas atitinkančių energijų sumos (1.7 pav.). Energija kiekvienam kanalui yra apskaičiuojama taip:

$$E_j = \sum_{k=0}^{K-1} \phi_j(k) X_k; \quad 0 \leq j < J. \quad (4)$$

čia J – filtrų skaičius melų filtrų banke;
 $\phi_j(k)$ – filtro funkcija.



1.6 pav. Melų filtrų bankai (pav. iš [11])



1.7 pav. Atskirų melų filtrų bankų įtaka bendrai signalo energijos spektrui (pav. iš [11])

Visų filtrų maksimali vertė lygi vienetui dėl normalizacijos:

$$\sum_{k=0}^{K-1} \phi_j(k) = 1; \quad \forall j. \quad (5)$$

Kitame žingsnyje melų filtrų bankų energijoms yra pritaikoma logaritmo funkcija (su pagrindu 10). Logaritmas suteikia galimybę naudoti kepstro vidurkio atimtį, kuri naudojama kanalo normalizavimui.

Galiausiai melų filtrų bankų energijų logaritmui yra pritaikoma diskretinė kosinusų transformacija. Tai yra daroma todėl, kad norima sumažinti filtrų bankų energijų koreliaciją, kuri atsiranda dėl filtrų bankų persidengimo [12]. Gautosios spektro amplitudės yra MSKK.

MSKK gaunami taip:

$$c_m = \beta_c \sum_{j=0}^{J-1} \cos\left(m \frac{\pi}{J}(j + 0,5)\right) \log_{10}(E_j). \quad (6)$$

čia β_c – stiprinimo faktorius, priklausantis nuo normalizacijos faktoriaus β_w .

1.3. Klasifikatoriai

1.3.1. Diskriminanto analizės klasifikatorius

Diskriminanto analizės klasifikatorius gali būti dviejų pagrindinių rūšių – tiesinis ir kvadratinis [13]. Egzistuoja hibridinių šių rūšių klasifikatorių. Šie klasifikatoriai yra patrauklūs tuo, jog skaičiavimai yra patogūs ir paprastai apibrėžiami, palaiko daugiau negu dvi klases bei nereikalauja jų parametrų skaičiavimo [14].

Tiek tiesinė, tiek kvadratinė diskriminanto analizė gali būti išvestos iš paprastų tikimybių modelių, kurie modeliuoja sąlyginį klasių pasiskirstymą duomenų $P(X|y = k)$ kiekvienai klasei k . Klasifikavimas išvedamas iš Bayes'o taisyklės:

$$P(y = k | X) = \frac{P(X | y = k)P(y = k)}{P(X)} = \frac{P(X | y = k)P(y = k)}{\sum_l P(X | y = l) \cdot P(y = l)}. \quad (7)$$


Pasirenkama klasė k , kuri maksimizuoja sąlyginę tikimybę.

Tiesinei ir kvadratinei diskriminanto analizei $P(X|y)$ modeliuojamas kaip daugiamatis Gauso pasiskirstymas su tankiu:


$$P(X | y = k) = \frac{1}{(2\pi)^n |\Sigma_k|^{1/2}} \exp\left(-\frac{1}{2}(X - \mu_k)^T \Sigma_k^{-1} (X - \mu_k)\right). \quad (8)$$

Norint šį modelį naudoti kaip klasifikatorių, iš mokymo duomenų reikia nustatyti klasių vidurkius μ_k ir kovariacijos matricas. Tiesinės diskriminanto analizės atveju, visoms klasėms kovariacijos matricos yra vienodos [15].

1.8 pav. pavaizduotas tiesinės diskriminanto analizės paviršius, o 1.9 pav. – kvadratinės.



1.8 pav. Tiesinės diskriminanto analizės klasifikavimo paviršius



1.9 pav. Kvadratinės diskriminanto analizės klasifikavimo paviršius

1.3.2. Artimiausių kaimynų klasifikatorius

Artimiausių kaimynų metodas yra nesudėtingai realizuojamas ir vizualizuojamas, pritaikomas daugelyje sričių [16]. Tai yra neparimetrinis algoritmas, nereikalaujantis iš duomenų jokių pirminių prielaidų [17]. Kadangi metodas neatlieka apibendrinimo, mokymo fazė yra ypatingai greitai, tačiau atliekant testavimą reikalinga tebeturėti visus mokymo duomenis (todėl esant dideliame duomenų kiekiui gali reikalauti daug atminties testavimo metu).

Duomenys gali būti skaliarai arba daugiamačiai vektoriai. AKK priima, jog duomenys yra požymių erdvėje, todėl egzistuoja atstumo tarp duomenų taškų koncepcija. Tai nebūtinai turi būti euklidinis atstumas, tačiau jis naudojamas dažniausiai [18].


Duomenis sudaro vektorių rinkinys ir klasės pavadinimas, susijęs su tais vektoriais. Metodas gali dirbti su dideliu skaičiumi klasių [19].

Naudojant šį metodą reikia nustatyti dydį k – tai skaičių, kiek kaimynų (pagal atstumą požymių erdvėje) daro įtaką klasifikavimui. Tai dažniausiai yra nelyginis skaičius, jeigu klasių yra dvi.

Kai $k = 1$, testavimo taškui ieškomas atstumas iki artimiausio mokymo metu priskirto taško. Kai $k > 1$, testavimo duomenų taškui priskiriama ta klasė, kurios dauguma taškų yra išsidėstę atstumu, lygiu atstumui iki k -tojo taško (1.10 pav.). Galimas svorių priskyrimas klasėms, taip padidinant tikslumą. Didinant k tikslumas didėja, tačiau nukenčia sistemos greitaveika. Rekomenduojama rinktis k pagal šią taisyklę:

$$k = \sqrt{n}. \quad (9)$$

čia n – duomenų kiekis.




1.10 pav. AKK veikimo pavyzdys, kai $k = 8$.

1.3.3. Dirbtinis neuroninis tinklas

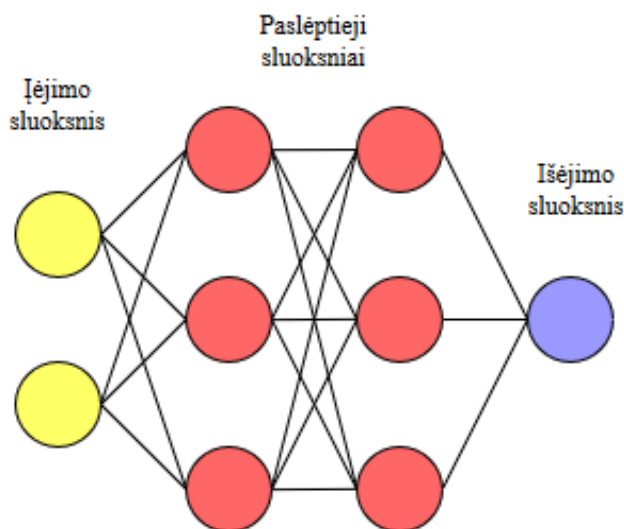
Dirbtinis neuroninis tinklas (DNT) yra sistema, sudaryta iš grupės dirbtinių neuronų, paremta žinduolių smegenų žievės nervinių tinklų veikimu [20], tačiau yra žymiai mažesnio dydžio. Dideli DNT turi šimtų arba tūkstančių eilės neuronų skaičių, o žinduoliai jų turi milijardus.

Dirbinį neuroną sudaro (1.11 pav.) įėjimai su jiems priskirtais svoriais W . Neuronas sudeda visų įėjimų I signalus padauginęs juos iš atitinkamų svorių ir lygina, ar suma peržengia slenkstinę vertę T . Jeigu ši sąlyga tenkinama, neuronas aktyvuojasi ir išduoda išėjimo signalą S [21].



1.11 pav. Dirbtinio neurono struktūra (pav. iš [22])

Neuroninius tinklus paprastai sudaro (1.12 pav.) atskiri sluoksniai, kuriuose yra tarpusavyje tarp sluoksnių susijungę mazgai. Pirmasis sluoksnis yra vadinamas įėjimo sluoksniu. Klasifikuojamieji modeliai DNT yra pateikiami per įėjimo sluoksnį. Pastarasis yra susijęs su giliau esančiais, vadinamais paslėptaisiais sluoksniais, kuriuose vykdomas apdorojimas. Ryšiai tarp paslėptų sluoksnių neuronų turi tam tikrus priskirtus svorius (svoriai priskiriami mokymo metu). Už paslėptųjų sluoksnių yra paskutinis, išėjimo sluoksnis.



1.12 pav. Supaprastinta DNT struktūra

Kiekvienos mokymo iteracijos metu svoriai tarp mazgų yra keičiami, todėl sulig kiekviena iteracija tinklas geriau įsimena klasifikuojamąjį modelį. DNT mokantis pasiekiamas toks etapas, kai klasifikavimo rezultatas nustoja gerėjęs. Tokia būseną vadinama stabilia. DNT gali turėti daugiau negu vieną stabilią būseną, jų kiekis priklauso nuo jungčių svorių bei neuronų slenkstinių verčių.

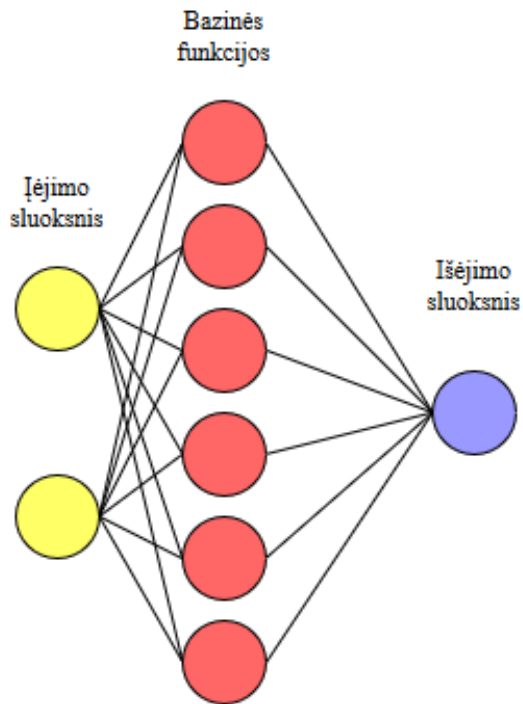
Egzistuoja skirtingų neuroninių tinklų rūšių, keli pavyzdžiai:

1. Radialinių bazinių funkcijų tinklai.
2. Kohoneno save organizuojantys tinklai.
3. Besimokančių vektorių kvantizacijos tinklai.
4. Rekurentinis neuroninis tinklas.
5. Modulinis neuroninis tinklas.

1.3.4. Radialinių bazinių funkcijų klasifikatorius


Radialinių bazinių funkcijų (RBF) klasifikatorius yra DNT, naudojantis radialines bazines funkcijas kaip aktyvacijos funkcijas. Tinklo išėjimas yra radialinių bazinių funkcijų kombinacija, sudaryta iš įėjimų signalų ir neuronų parametrų [23].

RBFK sudaro (1.13 pav.) įėjimo sluoksnis, bazinių funkcijų sluoksnis iš išėjimo sluoksnis. Įėjimo sluoksnis gali būti modeliuojamas kaip realiųjų skaičių vektorius. Išėjimo sluoksnis yra skaliarinė įėjimo vektoriaus funkcija [24].



1.13 pav. Supaprastinta RBF klasifikatoriaus struktūra

RBFK neuronas turi prototipinį vektorių, kuris yra vienas iš mokymo duomenų vektorių. Kiekvienas neuronas lygina įėjimo vektorių su savo prototipu ir išduoda vertę nuo 0 iki 1, priklausomai nuo panašumo. Jeigu įėjimas lygus prototipui, išduodamas vienetas. Didėjant netikslumams vertė eksponentiškai artėja link nulio. RBFK neurono atsakas yra Gauso varpo formos (1.14 pav.).



1.14 pav. RBFK neurono atsako kreivė

Išėjimo sluoksnį sudaro tiek išėjimo mazgų, kiek klasių klasifikatorius turi atpažinti. Kiekvienas mazgas apskaičiuoja kiekvienotestavimo duomenų taško rezultatą, kiek pastarasis atitinka išėjimo klasę, tad klasė priskiriama mazgui su didžiausiu rezultatu. Rezultatas apskaičiuojamas imant visų neuronų aktyvacijos vertes, padaugintas iš atitinkamų svorių ir susumavus[25].

RBFK neuronui skaičiuojant panašumą tarp įėjimo ir prototipo vektoriaus, rezultatas gaunamas pagal šią funkciją Gauso varpo funkcija:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}. \quad (10)$$

čia x – įėjimas;
 μ – vidurkis;
 σ – standartinis nuokrypis.

RBFK neurono aktyvacijos funkcija yra ši:

$$\phi(x) = e^{-\beta|x-\mu|^2}. \quad (11)$$

1.3.5. Medžio tipo klasifikatorius

MeTK yra nparametrinis supervizorinio tipo klasifikatorius. Medžio tipo klasifikatorių yra sudarytas iš didelio kiekio pasirinkimų „taip/ne“, skirstančių įėjimo duomenis į skiriamas klases [26]. Medį sudaro:

1. Šaknies mazgas – įėjimo mazgas, turi išėjimą į vidinius mazgus.
2. Vidiniai mazgai – turi vieną įėjimą ir išėjimą į tolimesnius vidinius mazgus arba lapus.
3. Lapai – turintys vieną įėjimą ir neturintys išėjimų, jie atspindi skiriamas klases.

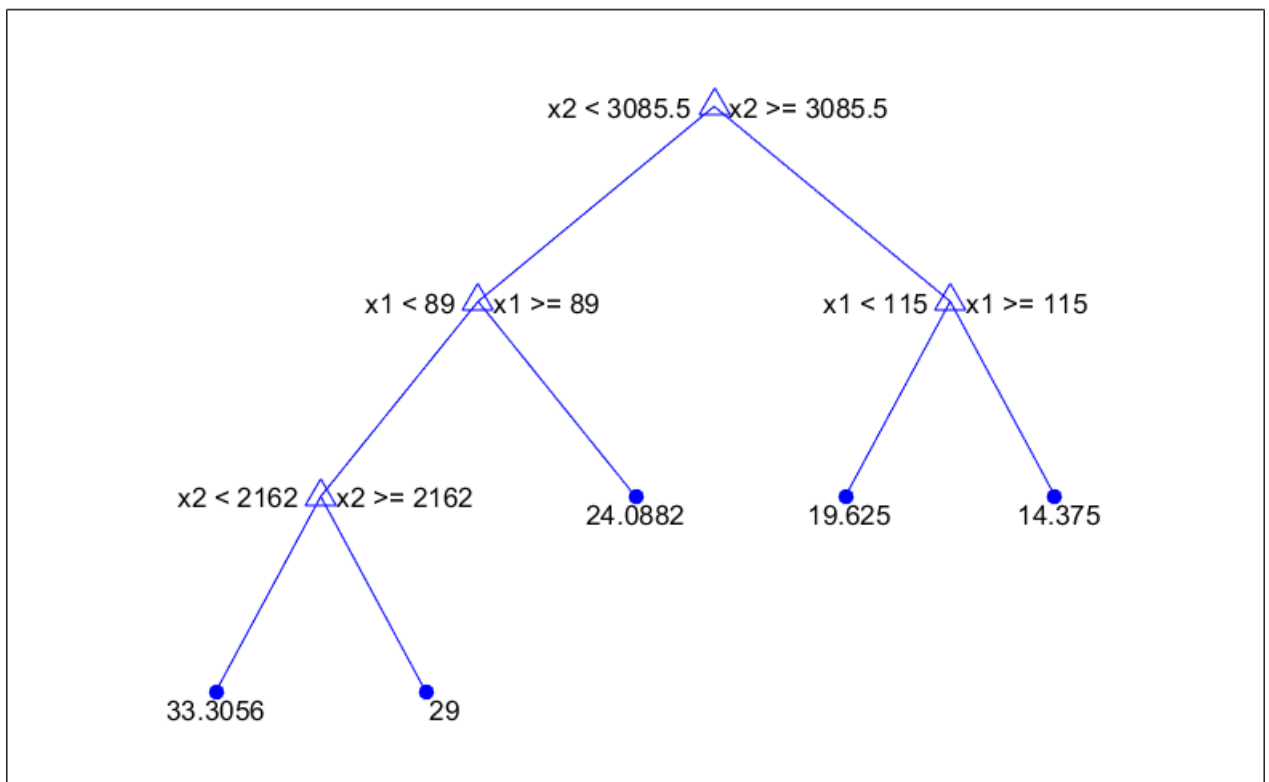
MeTK yra nesudėtingai interpretuojamas ir vizualizuojamas. Jam nereikia duomenų paruošimo – tai normalizacijos ir pagalbinių kintamųjų [27]. Gali naudoti tiek skaitinius, tiek kategorinius duomenis, tai yra gali dirbti su keliais duomenų tipais. Yra galimybė validuoti modelį naudojant statistinius testus, pagerinant modelio patikimumą.

Išaugus modelio dydžiui ir sudėtingumui klasifikavimo kokybė gali nukentėti. Tai vyksta dėl to, jog atrinkimo taisyklės tampa pernelyg griežtos. Tokiu atveju naudojamas genėjimu vadinamas metodas. Jis sumažina mazgų kiekį.

MeTK gali būti nestabilūs, nes esant mažiems pokyčiams duomenyse gali būti sukuriama visiškai kitoks medis. Ši problema išsprendžiama naudojant miško tipo klasifikatorių (MeTK rinkinį) [28].

Taip pat, kai kurias koncepcijas medžiui išmokti yra sudėtinga, pvz. loginio elemento „išskirtinis arba“, lyginumo arba multipleksoriaus. Gali būti sukuriami šališki medžiai, jeigu kai kurios klasės dominuoja. Dėl to patartina duomenis apmokant klasifikatorių paskirstyti tolygiai.

MeTK pavyzdys pavaizduotas 1.15 pav.



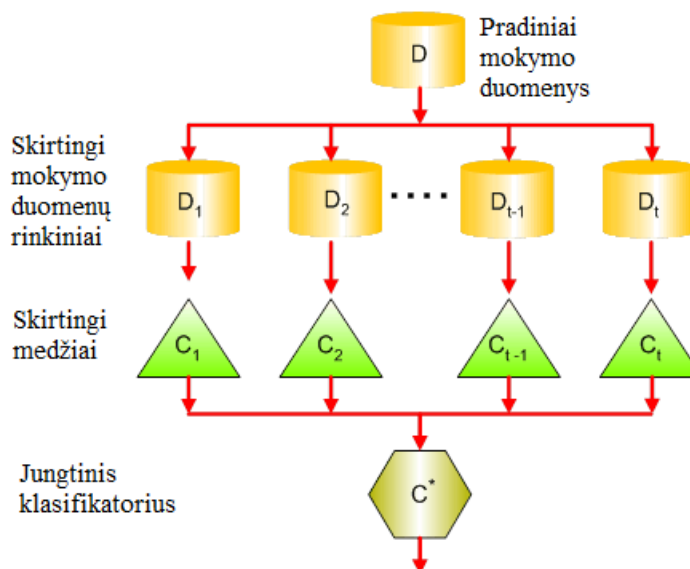
1.15 pav. Medžio tipo klasifikatorius

1.3.6. Miško tipo klasifikatorius

Miško tipo klasifikatorius yra naudojamas medžio tipo klasifikatoriaus kokybės pagerinimui. Metodo esmę (1.16 pav.) sudaro skirtingų mokymo duomenų rinkinių atrinkimas iš pradinio mokymo

duomenų bloko [29]. Tai leidžia sukurti skirtingus medžius iš panašaus tipo (bet ne identiškų) duomenų, iš principo turinčių veikti panašiai vienas į kitą. Galiausiai iš jų sukuriamas jungtinis klasifikatorius, tai yra atsakymas renkamas pagal daugumos medžių sutampančius atsakymus.

Savaime suprantama, naudojant MiTK žymiai išauga klasifikatoriaus apmokymo laikas [30]. Taip pat sistema tampa mažiau suprantama, priešingai, negu MeTK atveju.



1.16 pav. Miško tipo klasifikatoriaus veikimo principas (pav. iš [31])

1.4. Klasifikatorių lyginimas

Norint lyginti klasifikatorių atpažinimo kokybės rodiklius, klasifikatoriai turi būti tinkamai apmokyti [32]. Kelios svarbios sąlygos:

1. Klasifikatoriai turi būti apmokomi tais pačiais baigtinio dydžio duomenimis.
2. Klasifikatorius turi būti testuojamas kitais duomenimis, negu buvo apmokytas (tam naudojama kryžminė validacija).
3. Duomenų kiekis turi būti pakankamai didelis (priklauso nuo klasifikatorių tipų).
4. Klasifikatorių tikrinimas turi būti atliekamas kaip hipotezės tikrinimas statistikoje (pavyzdžiui, naudoti t-testą).

Renkantis duomenų paskirstymo santykį tarp mokymo ir testavimo duomenų svarbu atsižvelgti į šiuos punktus [33]:

1. Daugiau mokymo duomenų teikia geresnį apibendrinimą.
2. Daugiau testavimo duomenų teikia geresnį klasifikavimo tikslumo įvertį.

Rekomenduojama rinktis šiuos klasifikatorių lyginimo kriterijus [34]:

1. Klasifikavimo taiklumas (procentais nuo teisingai atpažintų klasių).
2. Klasifikavimo klaidingumas (atvirkščias dydis tikslumui).
3. Tikėtina Bajeso rizika.
4. Grafiškai pagal ROC kreivę.
5. Kitus išvestinius dydžius iš sumaišymo matricos (1.1 lentelė).

1.1 lentelė. Sumaišymo matrica. Nariai, esantys įstrižainėje atitinka teisingai atspėtas klases procentais. Kiti skaičiai rodo neteisingai atspėtas klases

	Atpažintos klasės				
Tikros klasės	0	1	2	3	4
0	78	10	13	0	0
1	19	58	23	0	0
2	10	21	70	0	0
3	7	5	7	59	22
4	4	3	4	39	50

2. Tiriamoji dalis:


2.1. Duomenų rinkimas

Elektromiogramos duomenų surinkimas buvo atliktas laboratorijoje esančiu specializuotu įrenginiu „BIOPAC Systems Inc. MP36“ (2.1 pav.), prijungus elektrodus paveikslėlyje matomose vietose (2.2 pav.) pagal nuskaitymo įrenginio metodinę medžiagą [35]. Įrenginio programinėje įrangoje buvo nustatytas elektromiogramos signalo nuskaitymo nustatymas, esant 1000 Hz dažnio diskretizavimui bei 5-1000 Hz praleidžiamai dažnių juostai.

Tyrimui skirti penki judesiai – tai kairės rankos kiekvieno iš pirštų staigūs sulenkimai ir atlenkimai (vieną judesį sudaro abu šie veiksmai), pakartoti po 50 kartų su trumpomis pauzėmis. Taip vėliau gaunamos penkios judesių klasės. Šie signalai įrašomi į penkis atskirus failus.



2.1 pav. Laboratorijoje naudotas nuskaitymo įrenginys „BIOPAC Systems Inc. MP36“ (pav. iš [36])



2.2 pav. Elektrodo išdėstymas bandymo metu

2.2. Melų skalės kepsro koeficientų išskyrimas

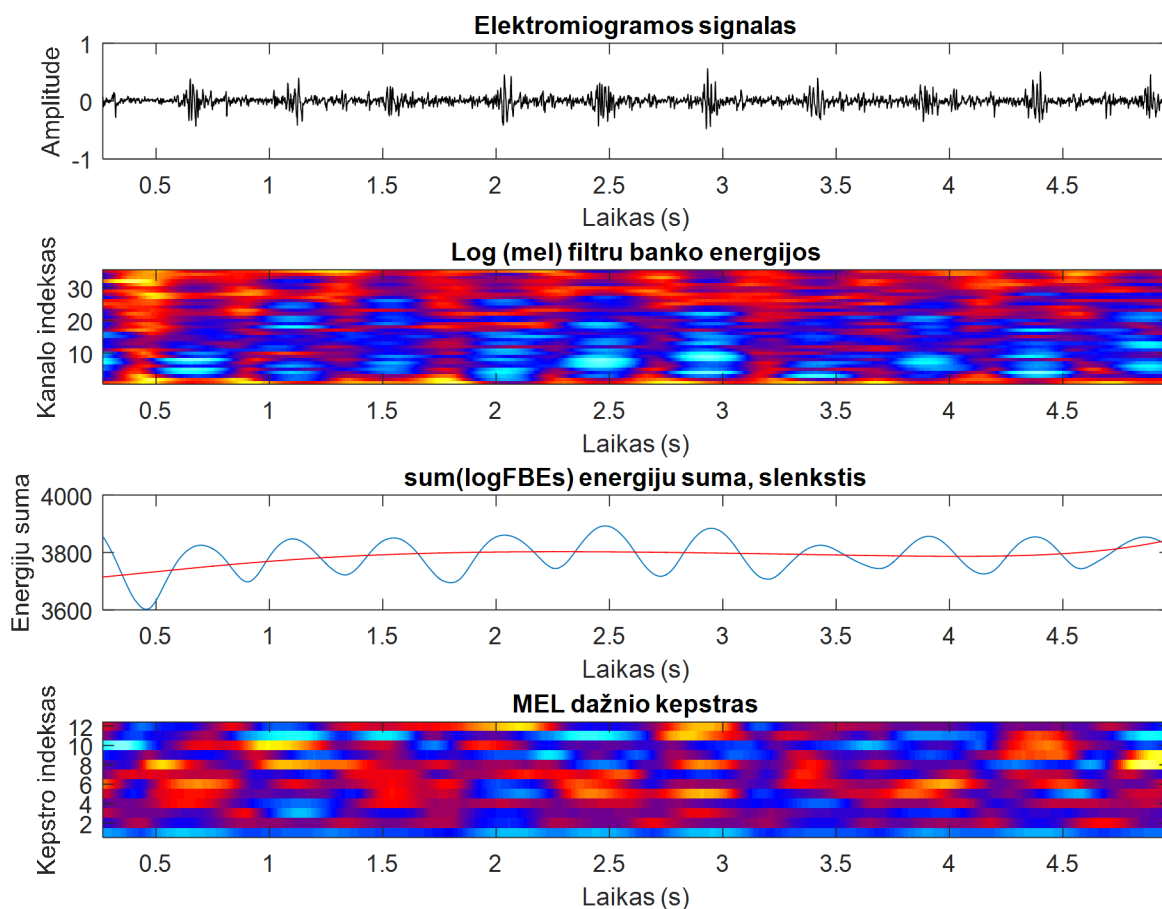
Analizei pasitelkiama MATLAB programinė įranga. Panaudotas jai skirtas specialus melų skalės kepsro koeficientų išskyrimo iš garso failo įrankis [37]. Pagal elektromiogramos signalo specifiką filtravimas buvo pakeistas į praleidžiantį 20-500 Hz dažnį. Nustatymus taip pat sudaro didžiojo ir mažojo analizės langų pločiai, filtro bankų kanalų kiekis, kepsro koeficientų kiekis, išankstinio išryškavimo koeficientas ir kepsro sinusoidės pakėlimo koeficientas.

Įrankis apskaičiuoja melų skalės kepsro koeficientus signalą padalinęs į nustatyto dydžio langus, apskaičiavęs energijų sumas. Naudojamas slenkstis energijų sumai konkrečiam diskretizavimo momentui, kuris apsprendžia, jog po juo esantis signalas yra pauzė (triukšmai), o virš jo – naudingas signalas. Pasirinktas šešto laipsnio interpoliuojantis polinomas. Pateikiamas tiek pirminis elektromiogramos signalas,


ties melų filtrų banko energijų grafinė reprezentacija, energijų sumos grafikas ir melų dažnių grafinė reprezentacija (2.3 pav.).

Išsaugomi duomenų masyvai su kepstro koeficientais bei informacija, kurį judesį konkretus signalas atitinka (priskiriamos klasės). Tai pakartojama su likusiais keturiais judesiais.

Tyrimo metu siekiama nuspręsti, kuri atpažinimo sistemos struktūra bei kuris klasifikatoriaus metodas geriausiai susidoroja su uždaviniu atskirti judesį (2.4 pav.).



2.3 pav. MEL kepstro koeficientų skaičiavimo grafiniai rezultatai bevardžio piršto lenkimui



2.4 pav. Judesių vykdymo ir atpažinimo algoritmas


Kompiuterio, kuriuo naudojantis buvo atliktas tyrimas, aparatiniai ir programiniai parametrai yra pateikti 2.1 lentelėje.

2.1 lentelė. Tyrime naudoto kompiuterio aparatiniai ir programiniai parametrai

Operacinė sistema	„Windows 10 Home 64-bit (10.0 Build 10586)“
„Matlab“ versija	„R2015b (8.6.0.267246) win64“
Platforma	„Lenovo Y50-70“
Procesorius	„Intel® Core™ i7-4710HQ CPU @ 2.50GHz (8 CPUs)“
Laisvosios kreipties atmintis	DDR3L 8 GB

2.3. Penkių klasių klasifikatoriaus atpažinimo sistema

Šio klasifikatoriaus struktūra (2.5 pav.) yra primityvi, jis skirsto į penkias jau minėtas judesių (pirštų staigių atlenkimų ir sulenkimų) klases – nykščio (1), rodomojo (2), ilgojo (3), bevardžio (4) ir mažylis (5).



2.5 pav. penkių klasių klasifikatoriaus struktūra. Pirštų judesių klasės: 1 – „nykštys“, 2 – „rodomasis“, 3 – „ilgasis“, 4 – „bevardis“, 5 – „mažylis“

Šiame darbe naudojami šie klasifikatorių tipai:

- Radialinių bazinių funkcijų;
- Dirbtinio neuroninio tinklo;
- Medžio tipo;
- Miško tipo;
- Diskriminanto analizės;
- Artimiausių kaimynų.


Apmokymo ir testavimo metu nuskaityti duomenys apie visų tiriamų judesių melūskalės kepstro koeficientus ir yra sujungiami.

Klasifikatoriaus apmokymui ir testavimui naudojama kryžminė validacija, apmokymui skiriant 80% duomenų, o testavimui – 20%. Taip išvengiama problemos, jog testuojant naudojami tie patys duomenys, kaip ir apmokant.

Tyrimas kartojamas 30 kartų, norint patikrinti skirtingų tipų klasifikatorių veikimą ir tinkamumą, kaip duomenis naudojant melū skalės kepstro koeficientus. Kadangi šiuo atveju siekiama tik susipažinti su klasifikatorių veikimu, jų parametrai nėra optimalūs. Atpažinimo tikslumas įvertinamas išvedus visų atskirų klasių atpažinimo tikslumo vidurkį. Rezultatai pateikiami 2.2 lentelėje.

2.2 lentelė. Klasifikatorių kokybės palyginimas

Klasifikatoriaus tipas	Klasifikatoriaus tikslumo vidurkis, %	Klasifikatoriaus tikslumo standartinis nuokrypis, %
DAK	88,77	1,86
AKK	98,70	0,70
DNT	85,73	2,87
RBFK	90,56	1,82
MeTK	83,00	2,17
MiTK	94,80	1,75

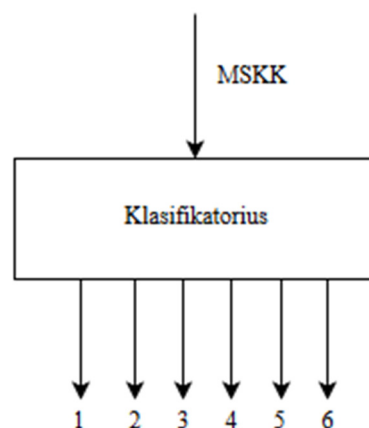


2.6 pav. penkių klasių klasifikatorių tikslumo vidurkiai

Matome (2.6 pav.), jog šiuo atveju vizualiai matoma (statistinis pagrįstumas netikrintas), jog artimiausių kaimynų metodas leido gauti geriausią klasifikavimo kokybės rezultatą (98,7%) ir mažiausią standartinę nuokrypį (0,7%). Melųskalės kepstro koeficientų radimo ir klasifikatorių parametru optimizavimas bei rezultatų statistinis įvertinimas atliekamas kitose tyrimo dalyse.

2.4.Šešių klasių klasifikatoriaus atpažinimo sistema

Klasifikatorius su penkiomis judesių klasėmis atpažįsta tik tiriamuosius 5 judesius, taigi esant pauzei jis laikas nuo laiko fiksuotą trikdžius ir laikytų juos judesiais, jam panašiausiais į išmoktuosius. Todėl nuspręsta įvesti klasifikatorių su šešiomis judesių klasėmis, šeštąja laikant pauzę (2.7 pav.).



27 pav. Šešių klasių klasifikatoriaus struktūra. Pirštų judesių klasės: 1 – „nykštys“, 2 – „rodomasis“, 3 – „ilgasis“, 4 – „bevardis“, 5 – „mažylis“, 6 – „pauzė“.

Pauze laikomas toks signalas, kurio energijų suma yra žemesnė už anksčiau minėtą nustatytą slenkstį, papildomai padaugintą iš eksperimentiniu būdu rasto koeficiento, leidžiančio padidinti klasifikatoriaus kokybę, kai bandoma nustatyti, ar buvo atliktas judesys, ar vyko pauzė. Taip sukuriama nejautrumo zona, padedanti išvengti neteisingo klasifikatoriaus išmokymo ribinėse situacijose.

Šio klasifikatoriaus atveju, naudojant kryžminę validaciją, klasifikatoriaus mokymui priskiriama 65% duomenų, o testavimui – 35%.

Išbandžius klasifikatorių su tais pačiais neoptimaliais melūskalės kepstro koeficientų radimo parametrais buvo gauti rezultatai apie 10-čia procentinių punktų mažesni, negu penkių klasių klasifikatoriaus atveju. Todėl buvo nuspręsta ieškoti tokių parametru, kurie galėtų užtikrinti ir gerą klasifikatoriaus darbo kokybę, ir jo greitaveiką.

Kadangi tikslo funkcija nėra žinoma, tiesinio ir netiesinio programavimo paieškos algoritmai optimizavimui negalėjo būti naudojami. Atsitiktinės paieškos metodai nenaudoti dėl didelio iteracijų skaičiaus. Pasirinktas Gauso-Zaidelio metodas, kurio vykdymo metu ieškomas funkcijos maksimumas tik pagal vieną parametru. Radus optimalią to parametro vertę, pastaroji vertė priskiriama paieškos algoritmui ir ieškoma kito parametro optimalios vertės.

T-testo pagalba papildomai patikrinama, ar klasifikatorių rezultatai vienas nuo kito statistiškai reikšmingai skiriasi. Visais atvejais, imant 2% patikimumo koeficientą, rezultatai reikšmingai skyrėsi.

Dėl to, kad programa kiekvieną kartą ją vykdant atsitiktinai pasirenka mokymo ir testavimo duomenis, kiekvieną kartą ją leidžiant nustačius tuos pačius parametrus gaunamas rezultatas varijuoja tam tikrame dispersijos diapazone. Taigi, tais pačiais parametrais melūskalės kepstro koeficientų vertė yra apskaičiuojama po 5 kartus.


Keičiamieji parametrai buvo šie:

1. Didžiojo analizės lango trukmė T_w (ms);
2. Mažojo analizės lango poslinkis T_s (ms);
3. Melų filtrų banko kanalų skaičius M ;
4. Nejautrumo zonos slenksčiui koeficientas L .

Parametrų kitimo ribos buvo pasirinktos pagal ekspertinę patirtį ir eksperimentais gautus buvusius rezultatus.

Pavyzdžiui, atlikus šį melųskalės kepstro koeficientų radimo parametrų paieškos bandymą gautos optimalios parametrų vertės bei išsiaiškinta, kad klasifikavimo kokybė labiausiai priklauso nuo mažojo analizės lango poslinkio laiko (2.8 pav.). Kuo jis arčiau nulio, tuo kokybė yra geresnė, tačiau duomenų kiekis tampa labai didelis, taigi nukenčia sistemos greitaveika.

Geriausi rezultatai buvo gauti, kai $T_w = 530$ ms, $T_s = 10$ ms, $M = 35$, $L = 22$.



2.8 pav. Artimiausių kaimynų metodo klasifikatoriaus tikslumo priklausomybė nuo mažojo analizės lango poslinkio T_s


Tokiu pačiu būdu, atsižvelgiant į greitaveiką, rasti optimalūs parametrai klasifikatoriams, pvz. neuronų skaičius paslėptajame dirbtinio neuroninio tinklo tipo klasifikatoriuje.

Radus optimalius parametrus, toliau buvo tęsiamas klasifikatoriaus su šešiomis klasėmis tyrimas. Siekiant tiksliau įvertinti klasifikavimo kokybę, tyrimas pakartotas 100 kartų, rezultatai vidurkiais pateikti 2.3 lentelėje.


2.3 lentelė. Klasifikatoriaus su Šešiomis klasėmis rezultatų vidurkiai

Klasifikatoriaus tipas	Klasifikatoriaus tikslumo vidurkis, %	Klasifikatoriaus mokymo laiko vidurkis, s	Klasifikatoriaus testavimo laiko vidurkis, s	Klasifikatoriaus testavimo laiko vienam taškui vidurkis, ms
DAK	88,82	0,47	0,04	0,11
AKK	99,60	0,19	0,26	0,73
DNT	95,30	4,46	0,02	0,06
RBFK	90,42	77,09	0,51	1,47
MeTK	94,21	0,96	0,05	0,14
MiTK	98,91	19,80	0,90	2,58


2.9 pav. grafiškai pateikiami skirtingų metodų dėka gautų klasifikavimo kokybės vidurkių rezultatai. Visuose grafikuose rezultatai pateikiami atvaizduojant taikomą 98 % reikšmingumo lygmenį. 2.10 pav. pavaizduoti kiekvieno klasifikatorių tipų apmokymo ir pilno testavimo laikai. 2.11 pav. pateikiamas kiekvieno klasifikatorių tipų testavimo laikų vienam testavimo duomenų vienetui palyginimas.



2.9 pav. Šešių klasių klasifikatoriaus klasifikavimo kokybės vidurčio priklausomybė nuo klasifikatoriaus tipo (100 bandymų, 98% reikšmingumo lygis)



2.10 pav. Šešių klasių klasifikatoriaus mokymo ir testavimo laiko vidurčio priklausomybė nuo klasifikatoriaus tipo (100 bandymų, 98% reikšmingumo lygis)



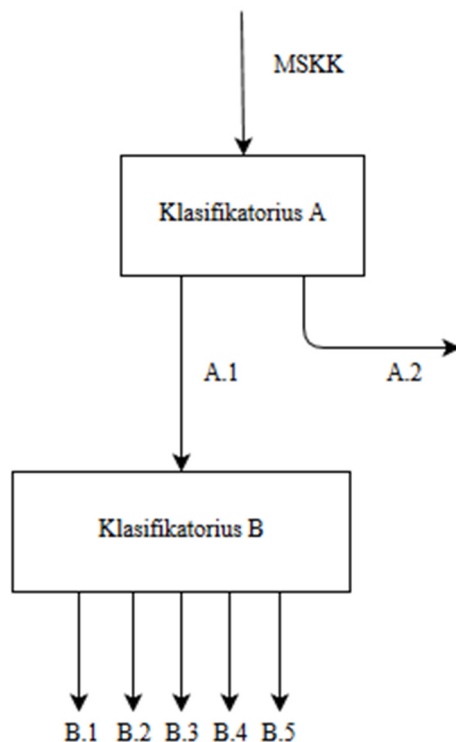
2.11 pav. Šešių klasių klasifikatoriaus testavimo laiko vienam matavimo taškui vidurkio priklausomybė nuo klasifikatoriaus tipo (100 bandymų, 98% reikšmingumo lygis)

Kokybės rodiklių atžvilgiu matoma, jog prasčiausi rezultatai gauti iš neuroninio tinklo ($95,3\% \pm 0,46$, didžiausia dispersija), radialinių bazinių funkcijų ($90,42\% \pm 0,16$) ir diskriminanto analizės ($88,82\% \pm 0,13$, mažiausia klasifikavimo kokybė) tipų klasifikatorių. Geriausiai užduotį įvykdė artimiausių kaimynų ($99,60\% \pm 0,02$, didžiausia klasifikavimo kokybė ir mažiausia dispersija) ir miško ($98,91\% \pm 0,06$) tipų klasifikatoriai.

Darbo greičio atžvilgiu prasčiausi buvo radialinių bazinių funkcijų (mokymo laikas - 77,09 s, testavimo laikas vienam taškui - 0,147 ms) ir miško (mokymo laikas - 19,80 s, testavimo laikas vienam taškui - 0,258 ms). Geriausias mokymo laikas buvo AKK (0,19 s), o testavimo laikas vienam testavimo duomenų taškui – DNT (0,006 ms).

2.5. Hierarchinė dviejų pakopų atpažinimo sistema

Klasifikavimo kokybei padidinti buvo sugalvota sukurti hierarchinį klasifikatorių (2.12 pav.), kurį sudaro du sujungti klasifikatoriai: pirmasis, klasifikatorius „A“, skiriantis dvi klases, tai – judesį ir pauzę, o antrasis, „B“ – penkias (visi kairės rankos pirštų sulenkimai). Iš klasifikatoriaus „A“ atrinkti judesio melų skalės kepstro koeficientai perduodami į klasifikatorių „B“, o pauzės koeficientai – atmetami. Šiuo būdu siekiama anksčiau eliminuoti pauzės (triukšmo) signalus, todėl geresne klasifikavimo kokybe skirti judesio klases.



2.12 pav. Hierarchinio klasifikatoriaus struktūra. Pirštų judesių klasės: A.1 – „judesys“, A.2 – „pauzė“, B.1 – „nykštys“, B.2 – „rodomasis“, B.3 – „ilgasis“, B.4 – „bevardis“, B.5 – „mažylis“

Šio klasifikatoriaus atveju mokymui taip pat priskiriama 65% duomenų, o testavimui – 35%. Tyrimas pakartotas 100 kartų, taikomas 98% reikšmingumo lygis.

2.4 lentelėje pateikiami klasifikatoriaus „A“ rezultatai. Pagal tikslumo vidurkį geriausias buvo artimiausių kaimynų ($99,18 \% \pm 0,049$, taip pat mažiausia dispersija), o prasčiausias – diskriminanto analizės ($84,75 \% \pm 0,140$) klasifikatoriaus tipas. Taip pat pastebėta, jog dirbtinio neuroninio tinklo tipo klasifikatorius esant dvejoms klasėms kartais neišmoksta vienos jų, todėl bendra klasifikavimo kokybė gaunama ne didesnė už 50%.

Pagal mokymo laiką geriausias buvo diskriminanto analizės (0,42 s), o prasčiausias – radialinių bazinių funkcijų (83,69 s) tipo klasifikatorius. Lyginant pagal testavimo laiką vienam taškui, geriausias pasirodė besąs dirbtinio neuroninio tinklo tipo klasifikatorius (0,006 ms), o prasčiausias – radialinių bazinių funkcijų (0,243 ms).

2.4 lentelė. Hierarchinio klasifikatoriaus „A“ dalies su dvejomis klasėmis rezultatų vidurkiai:

Klasifikatoriaus tipas	Klasifikatoriaus A tikslumo vidurkis, %	Klasifikatoriaus A mokymo laiko vidurkis, s	Klasifikatoriaus A testavimo laiko vidurkis, s	Klasifikatoriaus A testavimo laiko vienam taškui vidurkis, ms
DAK	84,75	0,42	0,04	0,010
AKK	99,18	0,62	0,30	0,087
DNT	91,53	9,01	0,02	0,006
RBFK	96,85	83,69	0,85	0,243
MeTK	97,23	0,88	0,05	0,013
MiTK	98,70	15,83	0,76	0,217

2.5 lentelėje pateikiami klasifikatoriaus „B“ rezultatai. Pagal tikslumo vidurkį geriausias buvo artimiausių kaimynų ($99,996\% \pm 0,003$), o prasčiausias – diskriminanto analizės ($91,94\% \pm 0,129$) klasifikatoriaus tipas.

Pagal mokymo laiką geriausias buvo artimiausių kaimynų (0,03 s), o prasčiausias – radialinių bazinių funkcijų (42,88 s) tipo klasifikatorius. Lyginant pagal testavimo laiką vienam taškui, geriausias buvo medžio tipo klasifikatorius (0,003 ms), o prasčiausias – miško tipo klasifikatorius (0,298 ms).

2.5 lentelė. Hierarchinio klasifikatoriaus „B“ dalies su penkiomis klasėmis rezultatų vidurkiai:

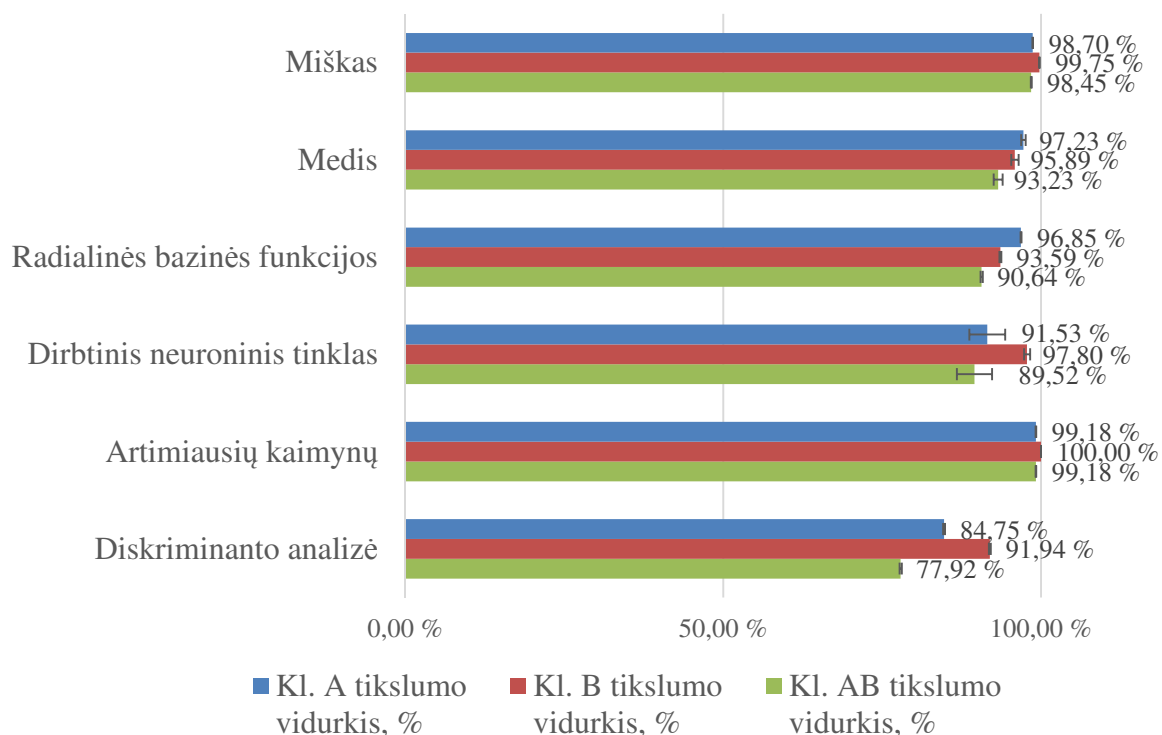
Klasifikatoriaus tipas	Klasifikatoriaus B tikslumo vidurkis, %	Klasifikatoriaus B mokymo laiko vidurkis, s	Klasifikatoriaus B testavimo laiko vidurkis, s	Klasifikatoriaus B testavimo laiko vienam taškui vidurkis, ms
DAK	91,94	0,08	0,01	0,005
AKK	99,996	0,03	0,09	0,038
DNT	97,80	3,10	0,02	0,008
RBFK	93,59	42,88	0,03	0,012
MeTK	95,89	0,08	0,01	0,003
MiTK	99,75	14,62	0,71	0,298

2.6 lentelėje pateikiami bendri klasifikatoriaus „AB“ rezultatai (2.13 pav.). Pagal tikslumo vidurkį geriausias buvo artimiausių kaimynų ($99,18 \% \pm 0,049$), o prasčiausias – diskriminanto analizės ($77,92 \% \pm 0,159$) klasifikatoriaus tipas.

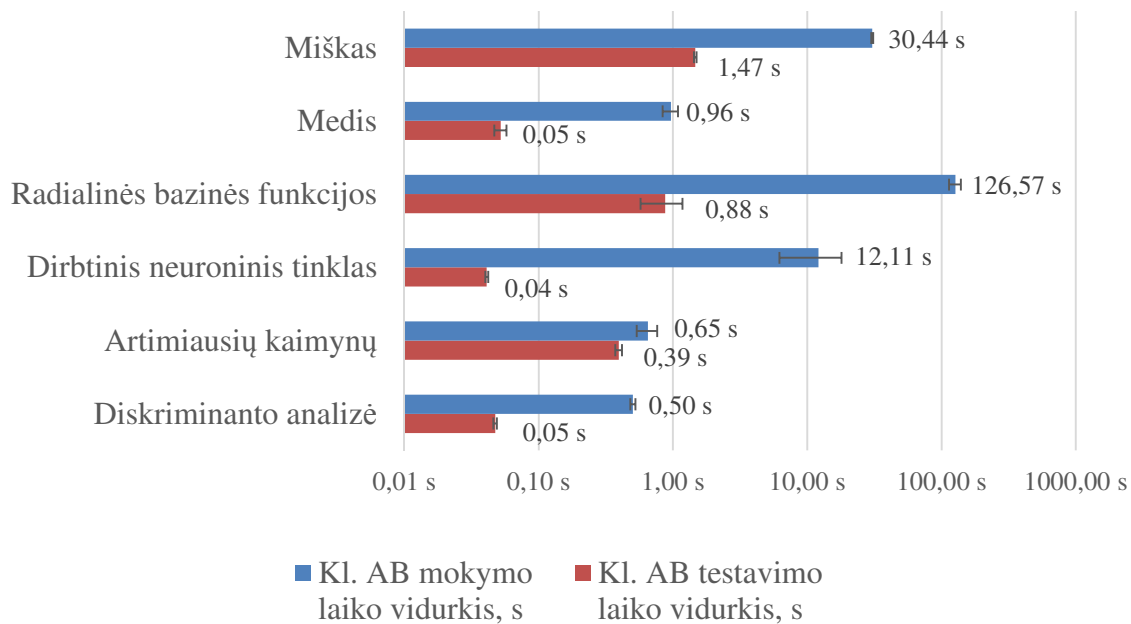
Pagal mokymo laiką (2.14 pav.) geriausias buvo diskriminanto analizės (0,50 s), o prasčiausias – radialinių bazinių funkcijų (126,57 s) tipo klasifikatorius. Lyginant pagal testavimo laiką vienam duomenų taškui (2.15 pav.), geriausias buvo dirbtinio neuroninio tinklo tipo klasifikatorius (0,014 ms), o prasčiausias – miško tipo klasifikatorius (0,515 ms).

2.6 lentelė. Hierarchinio klasifikatoriaus „AB“ bendrų rezultatų vidurkiai:

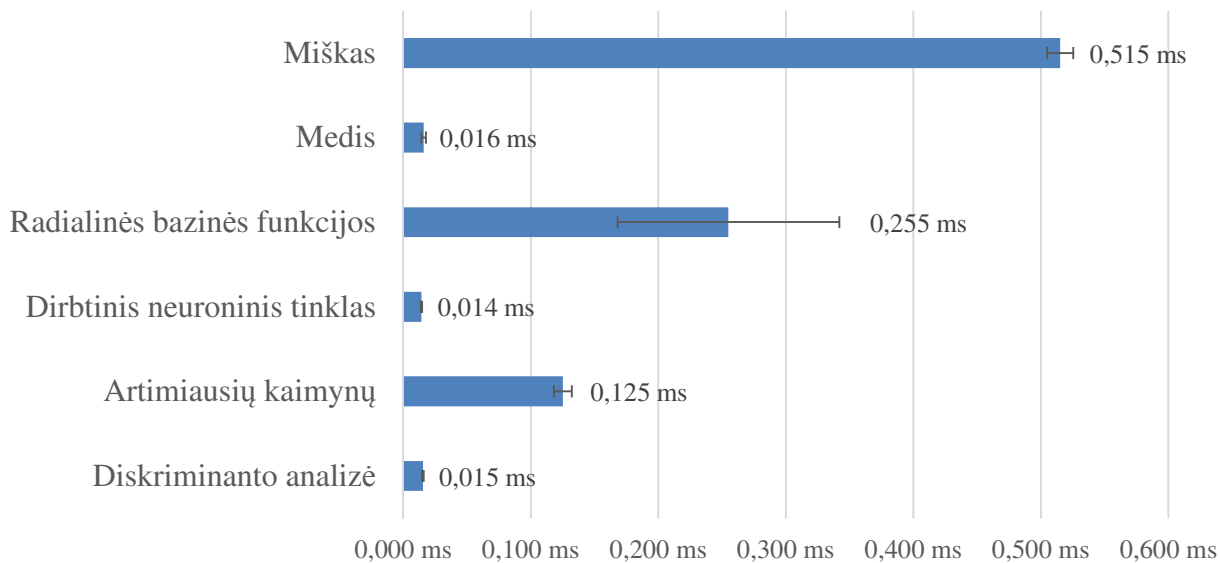
Klasifikatoriaus tipas	Klasifikatoriaus AB tikslumo vidurkis, %	Klasifikatoriaus AB mokymo laiko vidurkis, s	Klasifikatoriaus AB testavimo laiko vidurkis, s	Klasifikatoriaus AB testavimo laiko vienam taškui vidurkis, ms
DAK	77,92	0,50	0,05	0,015
AKK	99,18	0,65	0,39	0,125
DNT	89,52	12,11	0,04	0,014
RBFK	90,64	126,57	0,88	0,255
MeTK	93,23	0,96	0,05	0,016
MiTK	98,45	30,44	1,47	0,515



2.13 pav. Hierarchinio klasifikatoriaus klasifikavimo kokybės vidurkio priklausomybė nuo klasifikatoriaus tipo (100 bandymų, 98% reikšmingumo lygis)



2.14 pav. Hierarchinio klasifikatoriaus mokymo ir testavimo laiko vidurkio priklausomybė nuo klasifikatoriaus tipo (100 bandymų, 98% reikšmingumo lygis)




2.15 pav. Hierarchinio klasifikatoriaus testavimo laiko vienam matavimo taškui vidurkio priklausomybė nuo klasifikatoriaus tipo (100 bandymų, 98% reikšmingumo lygis)

2.6. Atpažinimo sistemų struktūrų palyginimas

Kaip matome 2.16 pav., visais klasifikatorių tipais, išskyrus RBFK (tikslumo vidurkių skirtumas nežymus, šešių klasių klasifikatoriaus atveju $90,42\% \pm 0,16$ ir atitinkamai hierarchinio atveju $90,64\% \pm 0,168$), geriausias buvo šešių klasių klasifikatorius.


Didžiausias skirtumas matomas tarp DAK ($88,82\% \pm 0,13$ ir $77,92\% \pm 0,159$) ir DNT ($95,30\% \pm 0,46$ ir $89,52\% \pm 2,769$). DNT taip pat turėjo didžiausią išsibarstymą.

Pagal tikslumo vidurkį geriausias buvo AKK (šešių klasių klasifikatoriuje $99,60\% \pm 0,02$ ir hierarchiniame $99,18\% \pm 0,049$), taip pat turėdamas patį mažiausią išsibarstymą iš visų metodų.



2.16 pav. Šešių klasių klasifikatoriaus ir hierarchinio klasifikatoriaus klasifikavimo kokybės vidurkio priklausomybių nuo klasifikatoriaus tipo palyginimas (100 bandymų, 98% reikšmingumo lygis)


Daroma išvada, jog hierarchinė atpažinimo struktūra tikslumo atžvilgiu rezultato nepagerino ir pailgino tiek mokymo, tiek testavimo trukmes.



2.17 pav. Šešių klasių klasifikatoriaus ir hierarchinio klasifikatoriaus mokymo trukmės vidurkio priklausomybės nuo klasifikatoriaus tipo palyginimas (100 bandymų, 98% reikšmingumo lygis)

2.17 pav. matome mokymo trukmių skirtumus naudojant skirtingas atpažinimo sistemų struktūras. Visais atvejais gauta didesnė mokymo trukmė, kai naudota hierarchinė struktūra. Taip yra todėl, kad reikėjo apmokyti du klasifikatorius, o šešių klasių klasifikatoriaus atveju – tik vieną.

Didžiausias santykinis skirtumas matomas AKK atveju (0,19 s ir 0,65s). MeTKtikslumui įtakos struktūros pakeitimas neturėjo, tačiau išaugo išsibarstymas. Kadangi AKK leidžia pasiekti geriausią tikslumą, hierarchinė atpažinimo sistemos struktūra mokymo greitimeikos atžvilgiu smarkiai pablogina rezultata.



2.18 pav. Šešių klasių klasifikatoriaus ir hierarchinio klasifikatoriaus testo trukmės vienam bandymo taškui vidurkio priklausomybės nuo klasifikatoriaus tipo palyginimas (100 bandymų, 98% reikšmingumo lygis)

2.18 pav. Pavaizduotas testavimo trukmių palyginimas tarp atpažinimo sistemų struktūrų. Matome, jog testavimo laikas beveik visų klasifikatorių, išskyrus MeTK, įvedus hierarchinę atpažinimo struktūrą išauga dvigubai. Taip pat išauga išsibarstymas.

Išvados

1. Elektromiograma yra laiko atžvilgiu kintantis ir jo analizei gali būti taikomas garso signalų analizės metodas. Šis metodas apskaičiuoja melų skalės kepstro koeficientus, iš kurių galima nuspręsti signalo būseną. Šiame darbe elektromiogramos signalai naudoti plaštakos pirštų judesių registravimui, melų skalės kepstro koeficientų radimui, o klasifikatoriai (diskriminanto analizės, artimiausių kaimynų, dirbtinio neuroninio tinklo, radialinių bazinių funkcijų, medžio tipo ir miško tipo) judesių atpažinimui. Geriausias judesių atpažinimas gautas 99,6 % tikslumu (98 % reikšmingumo lygmeniu).
2. Iteraciniu būdu buvo rasti melų skalės kepstrų koeficientų sistemos parametrai ir nustatyti geriausiai tinkantys (leidžiantys pasiekti geriausių atpažinimo tikslumą): didžiojo analizės lango trukmė $T_w = 530$ ms, mažojo analizės lango poslinkis $T_s = 10$ ms, melų filtrų banko kanalų skaičius $M = 35$, neįtakos zonos slenksčiui koeficientas $L = 22$. Neteisingai pasirinkus parametrus padidėja rezultatų išsibarstymas.
3. Naudojant šešių klasių (5 pirštų judesiai ir pauzė) klasifikatoriaus atpažinimo sistemą pagal tikslumą (99,60 % \pm 0,02) ir mokymo greitaveiką (mokymo trukmė - 77,09 s, tačiau testavimo trukmė vienam taškui - 0,147 ms) geriausias yra artimiausių kaimynų klasifikatorius. Dirbtinio neuroninio tinklo klasifikatoriaus testavimo laikas vienam duomenų taško vienetui buvo geriausias (0,006 ms, tačiau tikslumas tik 95,30% \pm 0,46). Prasčiausias pagal atpažinimo tikslumą yra DAK (88,82 % \pm 0,13), pagal mokymo trukmę – radialinių bazinių funkcijų klasifikatorius (77,09 s) ir pagal mokymo trukmę vienam testavimo duomenų vienetui – miško tipo klasifikatorius (0,258 ms). Taigi, geriausiu klasifikatoriumi pasirenkamas artimiausių kaimynų klasifikatorius.
4. Naudojant hierarchinę dviejų pakopų (vienas klasifikatorius skiria judesį ir pauzę, o kitas – 5 pirštų judesius) atpažinimo sistemą didžiausią tikslumo vidurkį turėjo artimiausių kaimynų klasifikatorius (99,18 % \pm 0,049), trumpiausią mokymo trukmę – diskriminanto analizės klasifikatorius (0,50 s), o testavimo laiką vienam duomenų taškui – dirbtinio neuroninio tinklo klasifikatorius (0,014 ms). Prasčiausias pagal tikslumo vidurkį buvo diskriminanto analizės klasifikatorius (77,92 % \pm 0,159), pagal mokymo laiką–radialinių bazinių funkcijų klasifikatorius (126,57 s), o pagal testavimo laiką vienam duomenų vienetui –miško tipo klasifikatorius (0,515 ms).Kadangi artimiausių kaimynų klasifikatoriaus mokymo ir testavimo vienam duomenų taškui trukmės yra santykinai trumpos (0,65 s ir 0,125 ms), jis pasirenkamas

kaip geriausias klasifikatorius. Hierarchinė atpažinimo struktūra tikslumo atžvilgiu rezultato nepagerino ir pailgino tiek mokymo, tiek testavimo trukmes, todėl taikyti šią sistemą nėra pagrindo.

Informacijos šaltinių sąrašas

1. BOGUE, R. Exoskeletons and robotic prosthetics: a review of recent developments. *Industrial Robot: An International Journal*. 2009, vol. 36, no. 5, p. 421-427.
2. TZANETAKIS, G. and P. COOK. Musical Genre Classification of Audio Signal. *IEEE Transactions on Speech and Audio Processing*. July 2002, vol. 10, no. 5, p. 293-302.
3. NILSSON, J., M. PANIZZA, and M. HALLETT. *Principles of digital sampling of a physiologic signal. Electroencephalography and clinical Neurophysiology*. 1993, vol. 89, p. 349-358.
4. Exam 3 Review: Chapter 09: Motor Unit and Neuromuscular Junction. [žiūrėta 2016 m. gegužės 22 d.]. Prieiga per internetą:
http://www.apsubiology.org/anatomy/2010/2010_Exam_Reviews/Exam_3_Review/CH_09_Motor_Unit_and_Neuromuscular_Junction.htm
5. Kendall/Tyco Arbo Disposable Surface EMG/ECG Electrodes 1” (24mm) 50pkg. [žiūrėta 2016 m. gegužės 22 d.]. Prieiga per internetą: <http://warren-mi.all.biz/kendall-tyco-arbo-disposable-surface-emgecg-g167750#.V0GCY77V6t2>
6. DTM-1.00F: Disposable Monopolar Needle Electrodes. [žiūrėta 2016 m. gegužės 22 d.]. Prieiga per internetą: <http://electrodestore.com/products/dtm-1-00f-disposable-monopolar-needle-electrodes>
7. KONRAD, P. The ABC of EMG. Scottsdale: Noraxon U.S.A., Inc., 2006, p. 16-19.
8. Nu-Tek Maxi Plus2 EMG ETS STIM. [žiūrėta 2016 m. gegužės 22 d.]. Prieiga per internetą: <https://www.win-health.com/nu-tek-maxi-plus2-emg-ets-stim-muscle-rehabilitation.html>
9. CHU, S., S. NARAYANAN, and KUO J. Environmental Sound Recognition With Time-Frequency Audio Features. *IEEE Transactions on Audio, Speech, And Language Processing*. August 2009, vol. 17, no. 6, p. 1142-1158.
10. DAVIS, S. and P. MERMELSTEIN. Comparison of Parametric Representations for Monosyllabic Word Recognition in Continuously Spoken Sentences. *IEEE Transactions on Audio, Speech, And Language Processing*. August 1980, vol. 28, no. 4, p. 357-366.
11. Mel Frequency Cepstral Coefficient (MFCC) tutorial. [žiūrėta 2016 m. gegužės 22 d.]. Prieiga per internetą: <http://practicalcryptography.com/miscellaneous/machine-learning/guide-mel-frequency-cepstral-coefficients-mfccs/#computing-the-mel-filterbank>
12. HOSSAN A., S. MEMON, and M. GREGORY. A Novel Approach for MFCC Feature Extraction. *Signal processing and Communication systems (ICSPCS)*. December 2010, p. 1-5.

13. SRIVASTAVA S., M. GUPTA, and B. FRIGYIK. Bayesian Quadratic Discriminant Analysis. *Journal of Machine Learning Research*. 2007, vol. 8, p. 1277-1305.
14. KIM K., et al. Comparison of k-nearest neighbor, quadratic discriminant and linear discriminant analysis in classification of electromyogram signals based on the wrist-motion directions. *Current Applied Physics*. 2011, vol. 11, p. 740-745.
15. RYBACK, R., et al. Quadratic Discriminant Analysis as an Aid to Interpretive Reporting of Clinical Laboratory Tests. *The Journal of the American Medical Association*. November 1982, vol. 248, no. 18, p. 2342-2345.
16. FUKUNAGA, K. and P. NARENDRA. A Branch of Bound Algorithm for Computing k-Nearest Neighbors. *IEEE Transactions on Computers*. July 1975, vol. 24, no. 7, p. 750-753.
17. KELLER, J., M. GRAY, and J. GIVENS. A Fuzzy K-Nearest Neighbor Algorithm. *IEEE Transactions on Systems, Man, And Cybernetics*. July 1985, vol. 15, no. 4, p. 580-585.
18. HO, T. Nearest Neighbors in Random Subspaces. *Joint IAPR International Workshops SSPR'98 and SPR'98*. August 1998, p. 640-648.
19. BAYER, K., et al. When is "Nearest Neighbor" Meaningful? *7th International Conference Jerusalem, Israel, January 10-12, 1999 Proceedings*, p. 217-235.
20. DAYHOFF, J. and J. DELEO. Artificial Neural Network: Opening the Black Box. *Conference on Prognostic Factors and Staging in Cancer Management: Contributions for Artificial Neural Networks and Other Statistical Methods*. 2001, p. 1615-1635.
21. HOPFIELD, J. Artificial Neural Networks. *IEEE Circuits and Devices Magazine*. September 1988, vol. 4, no. 5, p. 3-10.
22. GALKIN, I. Crash Introduction to Artificial Neural Networks. [žiūrēta 2016 m. gegužēs 22 d.]. Prieiga per internetu: <http://ulcar.uml.edu/~iag/CS/Intro-to-ANN.html>
23. PARK, J. and I. SANDBERG. Universal Approximation Using Radial-Basis-Function Networks. *Neural Computation*. 1991, vol. 3, no. 2, p. 246-257.
24. MUSAVI, M., et al. On the Training of Radial Basis Function Classifiers. *Neural Networks*. 1992, vol. 5, p. 595-603.
25. PARK, J. and I. SANDBERG. Approximation and Radial-Basis-Function Networks. *Neural Computation*. 1993, vol. 5, no. 2, p. 305-316.
26. SAFAVIAN, S. and D. LANDGREBE. A Survey of Decision Tree Classifier Methodology. West Lafayette: Purdue University. September 1990, p. 2-10.

27. STEIN, G., et al. Decision Tree Classifier For Network Intrusion Detection With GA-based Feature Selection. *43rd ACM Southeast Conference*. March 2005, p.136-141.
28. POLAT, K. and S. GUNES. A novel hybrid intelligent method based on C4.5 decision tree classifier and one-against-all approach for multi-class classification problems. *Expert Systems with Applications*. Amsterdam: Elsevier, 2009, p. 1-6.
29. DIETTERICH, T. An Experimental Comparison of Three Methods for Constructing Ensembles of Decision Trees: Bagging, Boosting, and Randomization. *Machine Learning*. 2000, vol. 40, p. 139-157.
30. DIETTERICH, T. Ensemble Methods in Machine Learning. *Multiple Classifier Systems*. December 2000, vol. 1857, p. 1-15.
31. SARASWAT, M. A Complete Tutorial on Tree Based Modeling from Scratch (in R &Python). [žiūrēta 2016 m. gegužēs 22 d.]. Prieiga per internetu:
<http://www.analyticsvidhya.com/blog/2016/04/complete-tutorial-tree-based-modeling-scratch-in-python/#seven>
32. PROVOST, F. and T. FAWCETT. Analysis and Visualization of Classifier Performance: Comparison under Imprecise Class and Cost Distributions. *KDD-97 Proceedings*. 1997, p. 43-48.
33. BOTTOU, L., et al. Comparison of Classifier Methods: A Case Study in Handwritten Digit Recognition. *Pattern Recognition*. 1994, vol. 2, p. 1-11.
34. MARCHANT, J. and C. ONYANGO. Comparison of a Bayesian classifier with a multilayer feed-forward neural network using the example of plant/weed/soil discrimination. *Computers and Electronics in Agriculture*. 2003, vol. 39, p. 3-22.
35. PFLANZER, R., et al. Electromyography (EMG) Laboratory. [žiūrēta 2016 m. gegužēs 22 d.]. Prieiga per internetu: <http://webs.wofford.edu/pittmandw/psy230/lab/EMGInstructs.pdf>
36. UpgradeToday; GreaterDiscoveryTomorrow. [žiūrēta 2016 m. gegužēs 22 d.]. Prieiga per internetu: <http://www.biopac.com/product/upgrade-to-mp36-system/>
37. HTK MFCC MATLAB. [žiūrēta 2016 m. gegužēs 22 d.]. Prieiga per internetu: <http://www.mathworks.com/matlabcentral/fileexchange/32849-htk-mfcc-matlab>