



**KAUNO TECHNOLOGIJOS UNIVERSITETAS
ELEKTROS IR ELEKTRONIKOS FAKULTETAS**

DOMAS JONAITIS

Embriono skilimo stadijų klasifikavimo metodo kūrimas ir tyrimas

Baigiamasis magistro projektas

Vadovas Doc. dr. Vidas Raudonis

KAUNAS, 2015

KAUNO TECHNOLOGIJOS UNIVERSITETAS
ELEKTROS IR ELEKTRONIKOS FAKULTETAS
AUTOMATIKOS KATEDRA

Embriono skilimo stadijų klasifikavimo metodo kūrimas ir tyrimas

Magistro projektas

Valdymo technologijos (kodas 621H66001)

Vadovas

Doc. dr. Vidas Raudonis

Recenzentas

Doc. dr. Kęstytis Ratkevičius

Projektą atliko

Domas Jonaitis

KAUNAS, 2015



KAUNO TECHNOLOGIJOS UNIVERSITETAS

Elektros ir elektronikos

(Fakultetas)

Domas Jonaitis

(Studento vardas, pavardė)

Valdymo technologijos, 621H66001

(Studijų programos pavadinimas, kodas)

Embriono skilimo stadijų klasifikavimo metodo kūrimas ir tyrimas

AKADEMINIO SAŽININGUMO DEKLARACIJA

20 ____ m. _____ d.
Kaunas

Patvirtinu, kad mano **Domo Jonaičio** baigiamasis projektas tema „Embriono skilimo stadijų klasifikavimo metodo kūrimas ir 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)

Jonaitis, D. Embriono skilimo stadijų klasifikavimo metodo kūrimas ir tyrimas. *Valdymo technologijų magistro baigiamasis darbas.*/ vadovas doc. dr. Vidas Raudonis; Kauno technologijos universitetas, Elektros ir elektronikos fakultetas, automatikos katedra.

Kaunas, 2015. 70 psl.

SANTRAUKA

Šiame darbe pristatomas embriono skilimo stadijų klasifikavimo algoritmas. Naudojami statistiniai požymių surinkimo metodai ir du klasifikavimo metodai: klasifikavimas su mokymu ir klasifikavimas be mokymo.

Pagrindinė šio darbo problema yra ankstyvo embriono branduolio skilimo stadijų aptikimas. Darbo tikslas yra pritaikyti tinkamą klasifikavimo metodą.

Pirmoje darbo dalyje pristatoma literatūros analizė, ir metodai kuriais naudojami kiti tyrėjai nagrinėjant panašaus pobūdžio problemas.

Antroje tiriamojoje dalyje pateiktas siūlomas algoritmas. Pristatomi siūlomi metodai. Požymių išgavimui siūlomi statistiniai metodai: entropija, paveikslėlių momentai invariantai ir principinių komponentų koeficientai. Klasifikavimui taikomas neuronų tinklų ir K-artimiausio kaimyno metodas.

Siūloma metodika tikrinama eksperimentų būdu. Tikimasi kad šis metodas gerai veiks vaizdo sekose.

Magistro darbą sudaro įvadas, trys skyriai, literatūros sąrašas ir autoriaus publikacijų magistro tema sąrašas.

Bendra magistro darbo apimtis 70 psl. plius priedai, numeruotų formulių 26, paveikslėlių 103 ir lentelių 8. Literatūros sąrašą sudaro šaltiniai.

Raktiniai žodžiai: embriono vystymosi stadijų aptikimas, neuroniniai tinklai, K-artimiausio kaimyno algoritmas, bruožų išrinkimas.

Jonaitis, D. Research and development of classification method of embryo cleavage stages. Master's thesis of control technologies. / Head Assoc. Dr. Vidas Raudonis; Kaunas University of Technology, Faculty of Electrical and Electronics, automation department.

Kaunas, 2015. 70 pages.

SUMMARY

This paper represents an embryo cleavage-stage classification algorithm. There are used statistical feature extraction methods and two classification methods: Classification with training and classification without training.

The main problem of this work is detection of early embryo cleavage stages. The aim is to adapt the proper classification method.

The first part of this paper represents the analysis of the literature, and the methods used by other researchers examining similar issues.

The second part of this research represents the proposed algorithm. There are introduced proposed methods. For the feature extraction proposed statistical methods: entropy, invariant moments and principal components analyses. For the classification are used neural networks and K-nearest neighbor method.

The proposed method is checked by experiment. It is expected that this method will work well in video sequences.

The Master's thesis consists of an introduction, three chapters, references and author of publications on the topic of the Master.

General master's thesis consists of 70 pages, numbered 26 formulas, 103 pictures and 8 tables. References list includes sources.

Keywords: detection the cleavage stages of embryo , neural networks, K- nearest neighbor algorithm, feature extraction.

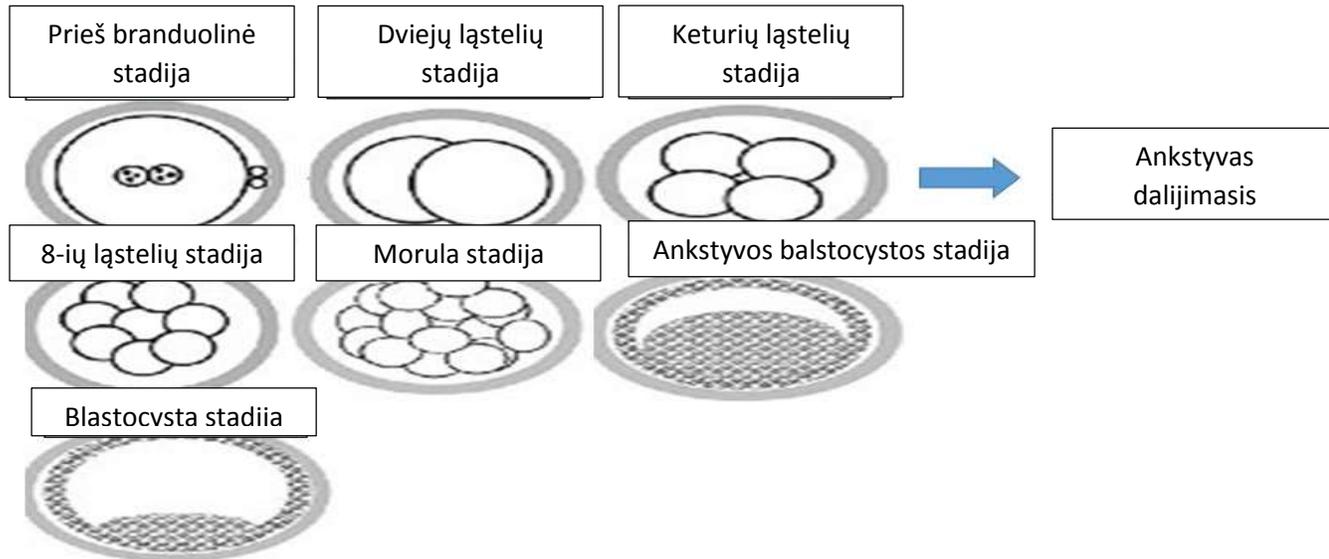
Turinys

SANTRAUKA	4
Įvadas	8
1. Technologijų apžvalga	11
1.1. Skyriaus apibendrinimas	14
2. Metodinė dalis	14
2.1. Objekto atpažinimas	14
2.2. Vaizdo gavimo technologija embriono vaizdams registruoti.....	15
2.3. Duomenų bazė	16
2.4. Požymių išskyrimo metodai	18
2.4.1. Entropija	18
2.4.2. Momentiniai nuotraukos „invariantai“	19
2.4.3. Principinių komponentių koeficientai.....	23
2.5. Klasifikavimo metodai	25
2.5.1. Neuroniniai tinklai.....	25
2.5.2. K – artimiausio kaimyno metodas.....	29
2.6. Skyriaus apibendrinimas	32
3. Eksperimentinis tyrimas.....	32
3.2 Siūlomas algoritmas	45
3.3. Skyriaus apibendrinimas	48
4. Rezultatai	49
Išvados.	66
Naudota literatūra.....	68
Priedai	70
Priedas nr. 1.	70
Priedas Nr 2.....	71
Priedas Nr 3.....	72
Priedas nr 4	72
Priedas nr 5	74
Priedas Nr 6.....	75
Priedas nr 7	77
Priedas nr 8	78
Priedas nr 9	86

Autoriaus publikacijos magistro darbo tema..... 104

Įvadas

Apvaisinimas mėgintuvėlyje – tai procedūra, kurios tikslas gauti embrioną pritaikant metodus, kai „oocitas“ apvaisinamas sperma ne žmogaus kūne. Šios procedūros pabaigoje gaunami keli embrionai, ir iškyla problema pasirinkti tinkamiausią embrioną, kuris bus perkeltas į gimdą. Tinkamo embriono atrinkimui mokslininkai tiria įvairius metodus. Paveikslėlyje(1) , pateikiamas embriono ląstelės vystymosi etapai, kuriuos kompiuterinis algoritmas turėtų atpažinti ir vertinti.



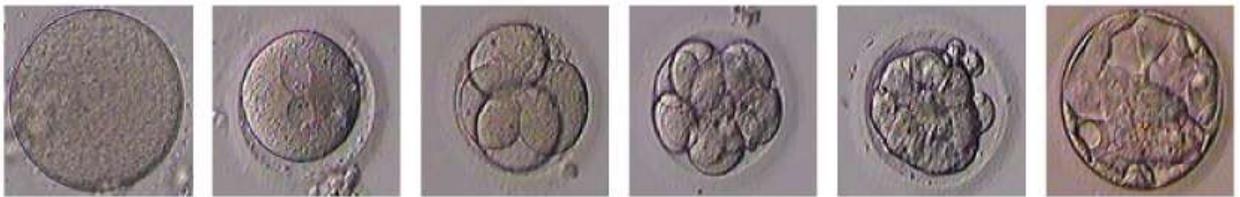
1 pav. Embriono vystymosi stadijos [1]

Apvaisinimas mėgintuvėlyje – vienas nevaisingumo gydymo metodų, kurio metu „oocitas“ apvaisinamas sperma ne žmogaus kūne. Tam reikia pašalinti kelis nevaisingumo priežasčių faktorius, pirmiausia mažą spermos kiekį ejakuliacijos metu arba obstrukciją moters kiaušintakiuose. Vienu metu apvaisinami ir kultivuojami keli „oocitai“, o programos pabaigoje išrenkamas vienas ar daugiau embrionų, kurie bus perkelti į gimdą. Viena didžiausių tokio apvaisinimo problemų yra parinkti gyvybingiausią embrioną, t.y. aukščiausios kokybės embrioną, kurio perkėlimas galėtų garantuoti klinikinį nėštumą[2].

Sukurta nemažai metodų, kurių tikslas padėti atrinkti gyvybingiausią embrioną taikant pagalbinio apvaisinimo terapiją. Literatūroje nagrinėjami keli skirtingi metodai. Wharf [3] duomenimis, ankstyva segmentacija 4 ląstelių fazėje leidžia nustatyti, kurie embrionai turi aukštą potencialą implantacijai. Balaban [4] naudojo iki branduolinę morfologiją, kuri leidžia prognozuoti būsimą embriono vystymąsi. Dar kitokie Borini [5] tyrimų rezultatai pasiekti blastulės stadijoje siekiant sumažinant „aneuploidijos“ riziką. Rienzi et al [6] tyrimas apjungė anksčiau aptartas schemas į bendrą/kaupiamąją embriono vertinimo balų sistemą ir nustatė aukštus sėkmingo implantavimo rezultatus. Tačiau visi šitie paminėti embriono vertinimo metodai atliekami specialisto, ne automatinių technologijų.

Vienas iš svarbiausių kriterijų pagal ką sprendžiama embriono išsivystymo kokybė yra ankstyvas dalijimasis. Ankstyvas dalijimasis – tai pirminė embriono vystymosi stadija, kada ląstelės branduolys pasidalina į keturis branduolius (pav. 1). Branduolio skilimo laiko momentai ir yra vertintinas kriterijus [3].

Šiuolaikinės technologijos leidžia stebėti embriono vystymąsi. Naujausias būdas stebėti embriono vystymąsi yra – „Time lapse“ (vert. Laiko tarpas) mikroskopas, kuris nuolat seka embriono vystymąsi (2 pav).



2 pav. embriono vystymosi skirtingu laiko momentu kadrai.[7]

Šiuo metu mokslininkai aktyviai domisi nauju metodu („time-lapse“ mikroskopu). Buvo publikuota nemažai tyrimų, įrodančių jo efektyvumą atrenkant implantacijai tinkamus embrionus, pavyzdžiui, Meseguer ir kt.[9] ir Chamayou [10]. „Time-lapse“ stebėjimas turi pranašumą, todėl yra patrauklesnis lyginant su įprastais stebėjimo būdais, nes šis metodas leidžia labai tiksliai nustatyti gyvybiškai svarbų embriono vystymosi laiką. Tačiau fiziškai yra labai sudėtinga peržiūrėti prietaiso sukauptus duomenis, esant ypatingai dideliame vaizdinės informacijos kiekiui. Pavyzdžiui, taikant „time lapse“ mikroskopą, vaizdas fiksuojamas kas 5

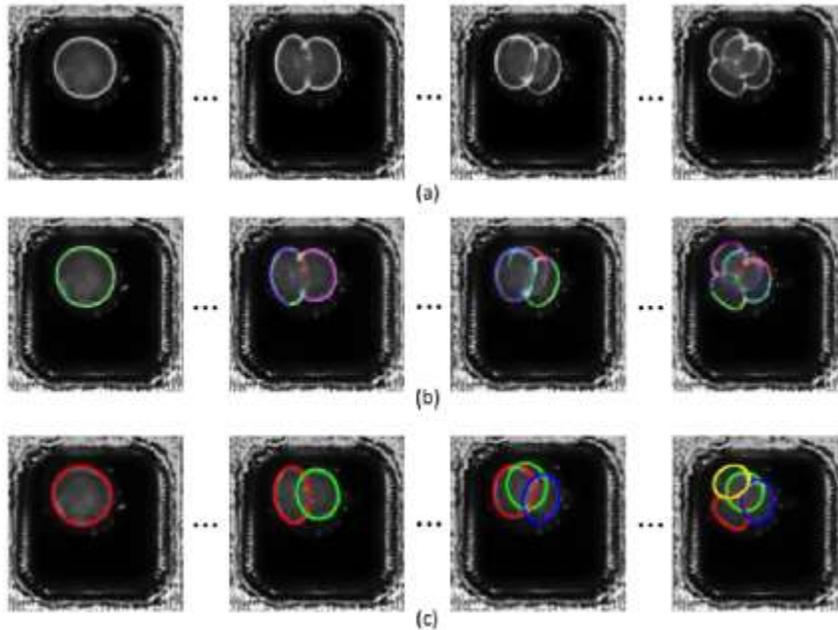
minutes, todėl bendras vaizdų skaičius po 5 stebėjimo dienų gali lengvai siekti 1440 nuotraukų vienam klientui. Norint atrasti, paaiškinti ir apdoroti tokį didžiulį kiekį informacijos reikia didelių pastangų. Todėl čia ypač praverstų automatinė embriono paieškos bei atitinkamų savybių įvertinimo sistema.

Darbo aktualumą pagrindžia statistika. Kas aštunta pora turi nevaisingumo problemų.[11] Todėl automatinė priemonė, gerokai palengvintų tokio pobūdžio klinikų darbą. Šio darbo tikslas yra sukurti ir išbandyti automatinį embriono skilimo stadijų aptikimo algoritmą.

1. Technologijų apžvalga

Dabartiniuose dirbtinio apvaisinimo klinikose dažniausiai naudojami standartiniai inkubatoriai, kur išmaniąja automatikos dalimi vadinami temperatūros reguliatoriai su itin mažom reguliavimo paklaidomis, bei CO ir N₂ dujų mišinio reguliatoriais (tai dirbtinio apvaisinimo klinikose didelis pasiekimas, kadangi nereikia naudoti „premixed-gas“ (iš anksto sumaišytų dujų), kurių kaina gerokai lenkia nesumaišytų dujų kainą). Šiuose inkubatoriuose, pats gydytojas, reguliariai išiminėja embrionus, ir mikroskopo pagalba seka jų vystymąsi[12]. Keletas klinikų naudoja „Time Lapse“[13] inkubatorius (su integruotu mikroskopu ir kameros sensoriumi), tačiau vienintelė ir pagrindinė jų funkcija, kaupti embriono vystymosi kadrus, jau nekalbant apie tai, kad daugelis šių prietaisų veikia ne itin preciziškai. Ne visada automatiškai atpažįstamas embrionas, arba embriono poziciją (koordinates) turi kalibravimosi momentu priskirti pats vartotojas. Tad analizuoti turimą sukauptą informaciją vis tiek turi daktaras. Didžiausia problema, kad dėl didėjančių nevaisingumo problemų, klientų tokiuose klinikose vis daugėja, tad fiziškai tampa nebeįmanoma peržiūrėti ir įvertinti kiekvieno embriono išsivystymo kokybę. Šios paslaugos kainuoja didelius pinigus, todėl klinikos negali daryti klaidų. Kiekvienas technikos tobulėjimas šioje srityje, kuris leistų optimizuoti klinikos darbą yra vertinimas tiek moksliniu tiek praktiniu požiūriu.

TL(time lapse) sistemos iškilo kaip galingas neinvazinis metodas įvertinti žmogaus embriono vystymąsi. TL gali suteikti įžvalgų, kaip žmogaus embrionas pasiekia kritinius vystymosi etapus ir į jas reaguoti esant sutrikimams. Kaip embriono vystymosi kokybės parametrų galima paminėti, embriono sienelių storį, skersmenį embrionų (turi būti tolygus), fragmentacijos procentinę dalį embriono ploto išsivysčiusioje ląstelėje. Daugelis naujausių tyrimų parodė, kad ląstelių dalijimosi laikus ankstyvame vystymosi etape (iki keturių ląstelių) gali padėti nuspėti, tolesnį embrionų likimą. Ankstyvas embriono vystymasis nuo apvaisinimo (vienos ląstelės) iki keturių ląstelių stadijos - paprastai trunka iki 48 valandų. Keletas pavyzdžių parodyta 3 paveiksle.



1.1 pav. Ankstyvas embriono įsivystymas[14]

Taigi automatinis embriono „keitimosi“ (vystymosi) identifikavimas, kaip minėta ir anksčiau gerokai pagerintų IVF klinikų darbo kokybę. Turint etaloninį modelį, pagal ką būtų galima nuspręsti įsivystymo kokybę, atsirastų ir daugiau objektyvumo. Kadangi kompiuteris, tam tikrus bruožus vertintų vienodai. Gydytojas, dėl pernelyg didelio informacijos kiekio gali suklysti, ar padaryti kitą klaidą kuri būdinga žmogui.

Kompiuterinė rega yra tyrinėjama daugelio mokslininkų ir sukurta labai daug įvairių metodų, sekti ar aptikti tam tikrus objektus. Nagrinėjamam objektui taip pat yra nagrinėta keletas iš metodų, tačiau kol kas nėra pasiekta jokio technologijos novatoriškumo šioje srityje. Didžiausia problema, tai kad esamos vaizdo apdorojimo sistemos, seka tam tikrus bruožus, tai yra tam tikrą spalvų pasiskirstymą, formą, nekintančius požymius ar kitus bruožus. Embriono vystymosi procese susiduriame su problema, kadangi nėra vieno formos modelio, sekamo objekto kraštai kinta laike, kiekvienas embrionas yra skirtingo dydžio, keičiasi topologija, nėra modelio apibūdinančio konkrečią embriono būseną laike ir t.t. Standartiniam sekimo sistemoms naudojama begalė metodų, tokių kaip „Hidden Markov model“, „Neural network“, „Kalman filters“, „Gaussian“, „Bayesen“ ir kt.

Morales [8] tyrė skirtingas Bajeso klasifikavimo sistemas embrionų gyvybingumui palyginti ir išrinko geriausias embrionus pagal tam tikrus deskriptorius - centrinis embriono vaizdo momentus (*central moments of embryo image*). Šių rezultatų duomenimis, geriausiai tam tinka „*tree augmented naive Bayes*“ (TAN) metodas pasak tyrėjo. Manna.[15] siūlo naudoti bendrą/visuminį neuroninio tinklo („neural network“) vertinimą kartu su „*local binary pattern*“ (LBP) nustatant gyvybingiausią embrioną. Ning [17] pasiūlė metodą, kurio metu aparatais gaunama informacija apie neuroninį tinklą ir energiją, kurios pagrindu klasifikuojami *C. elegans* embrionai. Kito tyrimo metu, kurį atliko Jiang ir kt.. [16], buvo naudojamas „*Scale Invariant Feature Transform*“ (SIFT), kurio metu buvo stebimas ir registruojamas ląstelės judėjimas, kai „*petri*“ lėkštelėje vienu metu buvo kultivuojamos kelios ląstelės. Taip pat buvo pasiūlytos technologijos, kurių metu „mikrofluidinių lustų“ pagalba patikrinama mechaninė varža ir išmatuojamas „oocito“ amžius [18].

Kultanen[14] embriono ląstelės atpažinimui taikė Hough Transform metodą. Šis metodas naudojamas atpažįstant apskritimą (circle detection) ir yra plačiai pritaikomas, kaip, pavyzdžiui, judesio, formos ir ultragarso vaizdo detektorius. HT transformuoja formos paieškos erdvinėje srityje užduotį į užduotį surasti maksimalią *voted value* / parametrinę vertę. (finding a shape in the spatial domain into finding maximal voted value in the parametre domain.) [14] Erdvės parametrų dydis ir išmatavimai priklauso nuo formos, kurią reikia „spręsti“. Šiuo atveju, kai gauta užduotis yra identifikuoti apskritimą, apskritimui sudaryti naudojami trys skirtingi parametrai x_0 , y_0 , ir r . Siekiant sumažinti Hough Transform erdvės ir laiko sudėtingumą, tyrėjas atlikto kelias studijos. Vienos jų rezultate buvo sukurtas Randomized Hough Transform (RHT)[14] (*randomize – atrinkti atsitiktine tvarka*) ir panaudotas siekiant aptikti ląstelių dalijimąsi. Pagrindinis skirtumas tarp HT ir RHT yra tas, kad (*elements voted*) pasirinktieji elementai parenkami atsitiktine tvarka, nenaudojant visų parametro „domain“ elementų. Vienas RHT panaudojimo trūkumų tas, kad jautrumas „triukšmams“ gan didelis.

PSO (Particle Swarm Optimization) – tai optimizacijos algoritmas, kuris „pamėgdžioja“ socialinį paukščių ir žuvų elgesį, būdingą jiems buriantis į spiečius (mimic the social behaviour of bird flocking or fishschooling.). Paskleidus daugybę dalelių paieškos erdvėje, kurioje kiekviena dalelė tarnauja viena kitai kaip galimas sprendimas, atsiranda galimybė rasti priimtina sprendimą. Šį algoritmą pasiūlė Kenedy ir Eberhal[19]. Šiam algoritmui pritaikoma Xie[20] idėja ir naudojamas

tik 1D *accumulator array*/ sumatoriaus masyvas ir tokiu būdu smarkiai supaprastinamas sudėtingas kompiuterinio skaičiavimo procesas. Šis metodas ypatingas tuo, kad PSO dalelių pozicijas atstovauja atsitiktinai sukurtų apskritimų aplink realų vaizdą centriniai taškai (x_c, y_c) . Taip pat ląstelės aptikimui.

Osher ir Sethian [21], taikė nustatyto lygio funkcija (LSF) evoliuciškai prisitaikančią prie norimo aptikti objekto panašioms problemoms spręsti.

1.1. Skyriaus apibendrinimas

Apžvelgta literatūra ir metodai embriono vystymosi kriterijams vertinti. Analizuojama tema vis dar nėra pakankamai gerai išnagrinėta. Temos aktualumą grindžia nevaisingų porų statistika. Esant tokiam dideliame kiekiui nevaisingų porų (kas aštunta pora turi vaisingumo problemų), šio metodo praktinis įgyvendinimas turėtų tiek praktinę tiek mokslinę vertę.

2. Metodinė dalis

2.1. Objekto atpažinimas

Vaizdų analizė bendruoju aspektu skirstoma į tokias sritis:

- 1) segmentavimas,
- 2) transformavimas
- 3) požymių išgavimas
- 4) objekto klasifikavimas arba objekto atpažinimas :
 - a. Neuroninių tinklų,
 - b. sintaksės metodų,
 - c. genetinių algoritmų,
 - d. statistinių metodų ir kt.

Vaizdo atpažinimą galima skirstyti į atpažinimą su mokymu ir atpažinimą be mokymo. [22] Klasifikatoriams su mokymu klasifikavimo funkcijos parametrai nustatomi pagal mokymo imties duomenis.

Mokymo imtis – informacija apie dalies tiriamų objektų požymių reikšmes ir priklausomybę vienai ar kitai klasei. Mokymo imtis susideda iš aibės mokymo pavyzdžių, nuotraukų su embrionų stadijų pavyzdžiais. Kiekvienas mokymo imties elementas yra pora, sudaryta iš stebinio, kurį dažniausiai sudaro stebinių vektorius, ir klasės, kuriai priklauso objektas. Pvz. nuotrauka su vienu branduoliu priklauso pirmai klasei.. Klasifikavimo funkcija privalo prognozuoti bet kuriam naujam stebiniui, atitinkančiam funkcijos apibrėžimo sritį(tikimybę kad priklauso kuriai nors klasei).

Klasifikavimo be mokymo metodai yra naudojami tada, kai klasės nėra apibrėžtos iš anksto. Naudojant abu metodus pagal nustatytus duomenų požymius atitinkami objektai priskiriami atitinkamai klasei.

Šiame tyrime naudojami statistiniai bruožų surinkimo metodai :

1. Entropija
2. Paveikslėlio momentiniai invariantai (angl. vert. invariant moments)
3. Principinių komponentių koeficientai

Klasifikavimui naudojami

1. Neuroniniai tinklai
2. K- artimiausio kaimyno algoritmas

2.2. Vaizdo gavimo technologija embriono vaizdams registruoti

Duomenų pagrindą sudaro 84 embrionai, gauti iš 6 pacientų.. Viena lėkštelė, gali talpinti skirtingą kiekį embrionų, pvz 10, 14, ar 20, ar kitokį skaičių. Kiekvienas embrionas fotografuojamas naudojantis tam tikrą įrangą. Praktikoje naudojama sraigtinė pavara, ir ant jos pritvirtintas kameros sensorius su mikroskopu. Tiek pavaros tiek kameros modelis nėra labai svarbus, kadangi pavaros pagrindinis kriterijus yra žingsnis, o kameros sensoriaus jos vidiniai parametrai. Taigi gamintojas nėra taip svarbu, kadangi jeigu jisai tenkina keliamus reikalavimus ir vaizdo kokybė yra pakankamai gera, vadinasi gali būti naudojamas bet kokio gamintojo kameros sensorius ar pavara. Kompiuterinės programos tikslas – nustatyti embrioną vaizde naudojant atitinkamą algoritmą. Kiekvieno embriono kultivavimo laikas skiriasi dėl įvairių klinikinių priežasčių. Todėl duomenų apie kiekvieną embriono vystymosi stadiją paskirstymas labai

netolygus. pav.2 pateikti keli embriono nuotraukų pavyzdžiai. Šiose nuotraukose yra užfiksuotas „idealus“ ląstelės atvaizdas. Praktikoje vaizde yra nemažai „triukšmų“ ir dažnai pastebimas persidengimas, kas ir įtakoja algoritmo sudėtingumą.(2.1 pav)

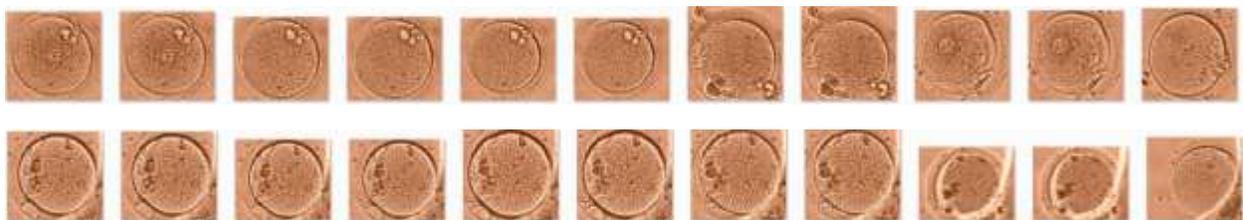


2.1pav. Realus bandymo metu gautas embriono atvaizdas

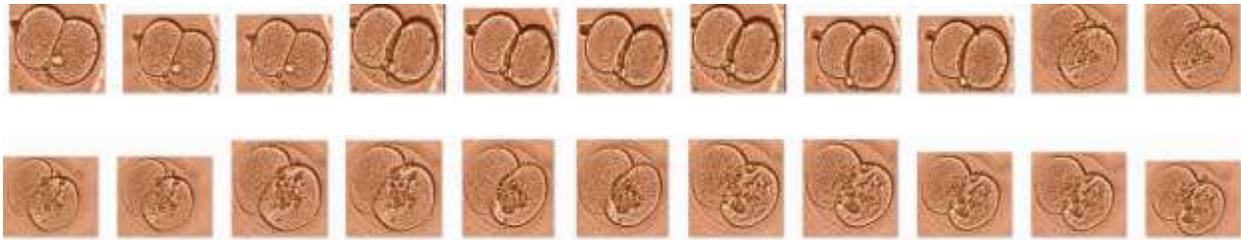
Paveikslėlyje galima matyti realiu laiku paimtą atvaizdą, kur branduolių kraštai menkai išsiskiria iš bendro fono, ir matosi daugybė „triukšmų“, kas apsunkina tyrimą.

2.3. Duomenų bazė

Programa kuriama „Matlab“ aplinkoje. Duomenų bazė kuriama iš „jpg“ formato nuotraukų. Kadangi ankstyvas branduolio dalijimosi procesas apima keturis branduolius, todėl duomenų bazei ruošiamos nuotraukos su vieno, dviejų, trijų ir keturių branduolių atvaizdais. Kiekvienai klasei panaudota 50 nuotraukų, kad kuo tiksliau būtų atkartota, visi įmanomi varijantai. Nuotraukų pavyzdžiai kiekvienai klasei pateikiami žemiau(pav 2.2;2.3.2;2.4;25):



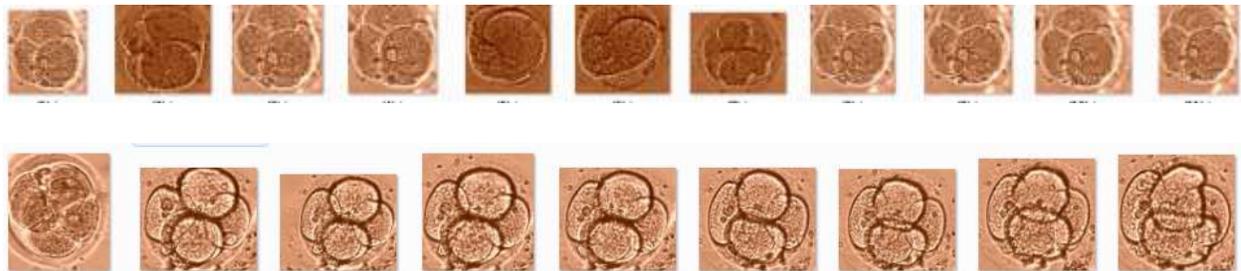
2.2 pav. Pirmos klasės nuotraukų pavyzdžiai



2.3 pav. Antros klasės nuotraukų pavyzdžiai



2.4 pav. Trečios klasės nuotraukų pavyzdžiai



2.5 pav. Ketvirtos klasės nuotraukų pavyzdžiai

„Matlab“ programiniame pakete nurodomas kiekis nuotraukų kiekvienos klasės atskirai mokymo imčiai suformuoti. Nuotraukos konvertuojamas į bw (black and white formatą). Suvienodinti duomenims naudojama funkcija „imresize“. Pasirinkta 50 skirtingų nuotraukų kiekvienai klasei:

```
n=50;
file_name='a (%d).jpg'
image=imread(sprintf(file_name,i));
    image = imresize(image,[60 60])
imgbw=im2bw(image);
    imgbw=logical(imgbw);
```

Sukuriamos keturios saugyklos nuotraukoms skirtoms duomenų bazėj formuoti.

2.4. Požymių išskyrimo metodai

2.4.1. Entropija

Bruožų surinkimui naudojama plačiai taikomi metodai:

Entropija[24]– informacijos kiekis, kurį suteikia konkretus simbolis ar pranešimas.

Vaizdų analizėje entropija reiškia informacijos kiekį, kuris išreiškiamas:

$$-\sum(p.\log_2(p)) \quad (1)$$

Kur p – yra atitinkamas histogramos skaičius.

Naudodami šį metodą iš kiekvienos nuotraukos gaunam tam tikrą bruožų rinkinį, kurį ir klasifikuosime.

Naudojama „matlab“ pakete esanti „entropy“ funkcija, gauti kiekvienos nuotraukos entropijos reikšmėms:

```
data=[data image(:)];  
J = entropy(image);  
vienaent = [vienaent J]
```

Rezultatai pateikiami prieduose, o duomenų fragmentas žemiau:

Lentelėje pateikiamos pirmų penkių kadrų entropijos reikšmės, likusios priede nr. 7):

2.1 lentelė. Entropijos duomenų fragmentas

Kadras	Viena ląstelė	Dvi ląstelės	Trys ląstelės	Keturios ląstelės
1	7.685050172105294	7.563200427936030	7.582432360381941	7.672834135017689
2	7.685050172105294	7.563200427936030	7.575049211949569	7.623732279971059
3	7.672314299589511	7.539523904369442	7.503832598987189	7.684115410846588
4	7.672314299589511	7.539523904369442	7.638771089713060	7.697074310612736
5	7.699094017345568	7.566994587238206	7.663029874526347	7.596680763123553

Surinkti bruožai išsaugomi „mat“ formatu :

```
save kketvienaentropy.mat kketvienaent
```

2.4.2. Momentiniai nuotraukos „invariantai“

Paveikslėlių momentai[25] naudojami objektų formai aprašyti. Paveikslėlių momentai yra tam tikri konkretūs pasverti vidurkiai (matematiniai momentai), skaičiuojami paveikslėlio elementų intensyvumo reikšmėms. Naudojant paveikslėlių momentus, yra randamas geometrinis srities plotas (ar visas intensyvumas) ir centrinis vaizdo elementas.

Skaičiuojant momentinius invariantus, reikia apibrėžti paveikslėlio funkcijos, geometrinį momentą ir centrinį momentą.

Geometrine paveikslėlio $f(x,y)$ (paveikslėlio 2 –D funkcija turinti ribas ir baigtinį nenulinį integralą) funkcija *momentas* m_{pq} , kur p ir q yra neneigiami sveikieji skaičiai ir suma ($p + q$) vadinama momento *eile*, apibrėžiamas tokia formule:

$$m_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^p y^q f(x, y) dx dy \quad (2)$$

kur $p, q = 0, 1, 2, \dots$

Diskrečiu atveju, kai momentai skaičiuojami skaliariniam (pilkumo lygių) paveikslėliui, integralas momento apibrėžime turi būti pakeistas suma. Tuomet formulė (2) pavirsta į tokią:

$$m_{pq} = \sum_{x=0}^N \sum_{y=0}^N x^p y^q f_{ij} \quad (3)$$

kur N yra paveikslėlio vaizdo elementų skaičius, o f_{ij} - atskirų vaizdo elementų pilkumo lygių reikšmės.

Naudoți Invariantinių momentų metodą gauname tokias savybės: *Plotą* m_{00} ir *centrinis vaizdo elementas*:

$$\{\bar{x}, \bar{y}\} = \{m_{10} / m_{00}, m_{01} / m_{00}\}. \quad (4)$$

Centrinis momentas μ_{pq} apibrėžiamas tokia formule :

$$\mu_{pq} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \bar{x})^p (y - \bar{y})^q f(x, y) dx dy \quad (5)$$

kur koordinatės $\{\bar{x}, \bar{y}\}$ nurodo $f(x, y)$ centrą (centrinį paveikslėlio vaizdo elementą, apskaičiuojamą pagal formulę (4)).

Toks pats integralo pakeitimas suma kaip paprastajam momentui (formulėje (3)) skaitmeninio paveikslėlio atveju pritaikomas ir centriniam momentui. Tuomet formulė (5) pavirsta į tokią:

$$\mu_{pq} = \sum_{x=0}^N \sum_{y=0}^N (x - \bar{x})^p (y - \bar{y})^q f_{ij} \quad (6)$$

Pirmos ir antros eilės centriniai momentai:

$$\mu_{00} = m_{00} \quad (7)$$

$$\mu_{01} = 0, \quad (8)$$

$$\mu_{10} = 0, \quad (9)$$

$$\mu_{11} = m_{11} - \bar{x}m_{01} = m_{11} - \bar{y}m_{10} \quad (10)$$

$$\mu_{20} = m_{20} - \bar{x}m_{10}, \quad (12)$$

$$\mu_{02} = m_{02} - \bar{y}m_{01}. \quad (13)$$

$$\mu_{pq} = \sum_{x=0}^N \sum_{y=0}^N (x - \bar{x})^p (y - \bar{y})^q f_{ij} \quad (14)$$

1962 m. M. K. Hu paskelbė septynis mastelio keitimo ir *posūkiu invariantus* (objektui paveikslėlyje skaičiuojami momentai, kurių reikšmės nekinta perkeliant, didinant ar mažinant bei pasukant tą objektą), sudarytus iš antros ir trečios eilės centrinių momentų[26]:

$$I_1 = \eta_{20} + \eta_{02} \quad (15)$$

$$I_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \quad (16)$$

$$I_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \quad (17)$$

$$I_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \quad (18)$$

$$I_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})] \quad (19)$$

$$I_6 = (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} - \eta_{03}) \quad (20)$$

$$I_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] - (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \quad (21)$$

Aprašytas metodas realizuojamas „matlab“ aplinkoje. Invariantiniams momentams (angl. vert. Invariant moments) išskviečiama „affine_moment“ funkcija. Programos fragmentas pateiktas žemiau:

```
temp_vect=affine_moment(imgbw);

mom1 = [mom1 temp_vect];
duomhu_moment_vector(:, :, i)=temp_vect;
format long
vienamom(:, i)=duomhu_moment_vector(:, :, i);
```

„Matlab“ aplinkoje aprašomi septyni momentai, kurie panaudoti skaičiavimuose. Programos fragmentas pateiktas žemiau :

```
I1=(mu_20 * mu_02 - mu_11^2)/(mu_00)^4;
I2=(-(mu_30^2) * (mu_03^2) + 6*mu_30*mu_21*mu_12*mu_03 - 4*mu_30*(mu_12)^3)/(mu_00)^10;
I3=(mu_20 * mu_21 * mu_03 - mu_20 * (mu_12)^2 - mu_11 * mu_30 * mu_03 + mu_11 * mu_21 * mu_12 + mu_02 * mu_30 * mu_12 - mu_02 * (mu_21)^2)/(mu_00)^7;
I4=(-(mu_20)^3 * (mu_03)^2 + 6 * (mu_20)^2 * mu_11 * mu_12 * mu_03 - 3 * (mu_20)^2 * mu_02 * (mu_12)^2 - 6 * mu_20 * (mu_11)^2 * mu_21 * mu_03 - 6 * mu_20 * mu_11^2 * mu_12^2 + 12 * mu_20 * mu_11 * mu_02 * mu_21 * mu_12 - 3 * mu_20 * mu_02^2 * mu_21^2 + 2 * mu_11^3 * mu_30 * mu_03 + 6 * mu_11^3 * mu_21 * mu_12 - 6 * mu_11^2 * mu_02 * mu_30 * mu_12 - 6 * mu_11^2 * mu_02 * mu_21^2 + 6 * mu_11 * mu_02^2 * mu_30 * mu_21 - 1 * mu_02^3 * mu_30^2)/(mu_00)^11;
I5=(1 * mu_40 * mu_04 - 4 * mu_31 * mu_13 + 3 * mu_22^2)/(mu_00)^6;
I6=(1 * mu_40 * mu_22 * mu_04 - 1 * mu_40 * mu_13^2 - 1 * mu_31^2 * mu_04 + 2 * mu_31 * mu_22 * mu_13 - 1 * mu_22^3)/(mu_00)^9;
I7=(1 * mu_20^2 * mu_04 - 4 * mu_20 * mu_11 * mu_13 + 2 * mu_20 * mu_02 * mu_22 + 4 * mu_11^2 * mu_22 - 4 * mu_11 * mu_02 * mu_31 + 1 * mu_02^2 * mu_40)/(mu_00)^7;
```

Rezultatai pirmų dviejų kadru pateikiami lentelėje žemiau, visi kiti duomenys pateikti prieduose.

2.2 lentelė Invariantinių momentų fragmentas.

Kadras	1 ląstelė	2 ląstelės	3 ląstelės	4 ląstelės
1	0.011809285952778	0.715789580830763	0.541892700503943	0.017508635885359
	-0.000000000004348	0.000065939651944	-0.000066922196473	-0.000000000004552
	-0.000000135158625	-0.007322968793837	-0.004684607951774	0.000000366135545
	-0.00000008450029	-0.011021435750441	-0.029380757248270	-0.000000065971995
	0.000842706502081	2.082254229279224	1.390216515885090	0.001693328230776
	0.000003380613805	0.518683805916161	0.266048550801067	0.000009361741859
	0.000765830073433	2.358928475400965	1.449300937135317	0.001605519861746
	2	0.011809285952778	0.715789580830763	0.498380827841830
-0.000000000004348		0.000065939651944	-0.000076604641878	-0.001279291812172
-0.000000135158625		-0.007322968793837	0.001953769197919	0.002663743396875
-0.00000008450029		-0.011021435750441	-0.042091795469229	-0.050275933568072
0.000842706502081		2.082254229279224	1.262763934032163	1.986631941279850
0.000003380613805		0.518683805916161	0.236951727889957	0.401795113191295
0.000765830073433		2.358928475400965	1.275578386157658	1.990133521011410

Surinkti bruožai išsaugomi „mat“ formatu :

```
save kketvienamoments.mat ketvienamom
```

2.4.3. Principinių komponentų koeficientai

Principal component analyses (angl. vert. Pagrindinis komponentai analizė) yra statistinė procedūra, kai naudojama stačiakampė transformacija konvertuoti susietų kintamųjų rinkinį į bruožų rinkinį. (tiesiškai nekoreliuotų kintamųjų vadinamų pagrindinėmis komponentėmis duomenims sumažinti). Kai paveikslėlio parametrai randami, jie gali būti suspausti, ty, jų matmenys gali būti sumažintas, be daug informacijos praradimo. Apibendrinant, principinių komponentų kompozicija gali būti naudojama kaip skaitmeninis vaizdo duomenų sumažinimo algoritmas su mažu informacijos praradimu. Toks sumažinimas yra naudingas keliais atvejais: vaizdų suspaudimo, duomenų pateikimo, ir t.t. Todėl duomenys supaprastinama ir naudojami principiniai koeficientai kurie teikia tik reikalingą informaciją. Iš pagrindinių sudedamųjų dalių (paveikslėlio), išreikštas skaičius yra mažesnis negu arba lygus originalių kintamųjų skaičiui. Ši

transformacija yra apibrėžiama tokiu būdu, kad pirmasis pagrindinis komponentas turi didžiausią galimą dispersiją (tai yra, sudaro kaip atspindį į duomenis ir kiekvienas kitas komponentas, savo ruožtu, yra labiausiai tikėtina dispersija pagal tai, kad ji yra statmenos projekcijos į (nekoreliuoja) ankstesnį komponentą. Pagrindinės komponentės yra statmenos, nes jos yra vektoriai variacijų matricos, kuri yra simetriška. PCA yra proporcingas santykis mastelio originalių kintamųjų. Principinių komponentių koeficientai randami randant „eigeno“ vektorius.

Principinių komponentių koeficientams rasti taip pat naudojamos „Matlab“ funkcijos, kurių pagalba gaunamas tam tikras kiekis koeficientų. Nuo pasirinkto koeficientų skaičiaus priklauso duomenų kiekis, kuris bus naudojamas klasifikavimui:

```
[vienaomeg eig psi] = compcca2(double(data),15);
```

Žemiau pateikta funkcija, apskaičiuoti principinių komponentių koeficientams:

```
function [Omega EigenVectors Psi]= compcca2(Data,NumberOfEigenVectors)

NumberOfData = size(Data,2);
Psi = mean(Data,2);
Theta = Data - repmat(Psi,1,NumberOfData);
[EigVect EigVal] = eig(Theta'*Theta);
for i = 1:NumberOfData
    EigenVectors(:,(NumberOfData + 1) - i) = Theta*EigVect(:,i);
end
EigenVectors = normc(EigenVectors);
Omega = zeros(NumberOfEigenVectors,NumberOfData);
for i = 1:NumberOfData
    Omega(:,i) = EigenVectors(:,1:NumberOfEigenVectors) '*Theta(:,i);
end
```

Žemiau esančioje lentelėje atvaizduoti kiekvienos nuotraukos PCA(principal component analysis) koeficientai. Pateiktame pavyzdyje atvaizduota penkiolika kiekvieno atvaizdo koeficientų(kiti duomenys pateikti priede nr.9):

Lentelė 2.3 Principinių komponentių koeficientų duomenų fragmentas:

Kadr as	1 ląstelė	2 ląstelės	3 ląstelės	4 ląstelės
1	0.966528724530410	-4.976067178381150	-2.801559613736563	0.608240912646916
	2.101065473429166	-0.184059373418128	-0.374099638491891	1.454199899734550
	0.243029624857310	-0.009289334005829	-0.069916477658810	-0.523261179385246
	0.333735312207404	0.175145928932713	0.069407364828431	-0.130874024256887
	-0.045148905965369	0.074732608555364	0.051067194280684	0.019438945638558
	-0.180562402568506	0.092201878370941	0.097982836064425	0.636911042890773
	1.211690372874501	0.774217347483406	0.053188691233873	-0.429825764071519
	-0.291711394440801	0.138230708903851	0.039142313347159	0.376901846622636
	-0.574417670144986	-0.098035839617935	0.047409957050647	-0.061297715215545
	-0.445910863117401	0.141094411113032	0.194267217377151	0.174465080383044
	-0.183026272293181	0.263460218726084	0.019681578185135	0.766869000146533
	-0.116932051192127	0.121223791460348	-0.105155918897446	-0.040356129940736
	-0.104844973663114	-0.195455632577580	-0.111081563115564	-0.193918812112015
	-0.127360773428061	-0.183406826304695	-0.054576968865706	0.090087515777589
	0.306970697822589	-0.187375805876724	0.028480425357250	0.301221691408267
				0.608240912646916

Surinkti bruožai išsaugomi „mat“ formatu :

```
save kketvienaomega.mat ketvienaomeg;
```

2.5. Klasifikavimo metodai

2.5.1. Neuroniniai tinklai

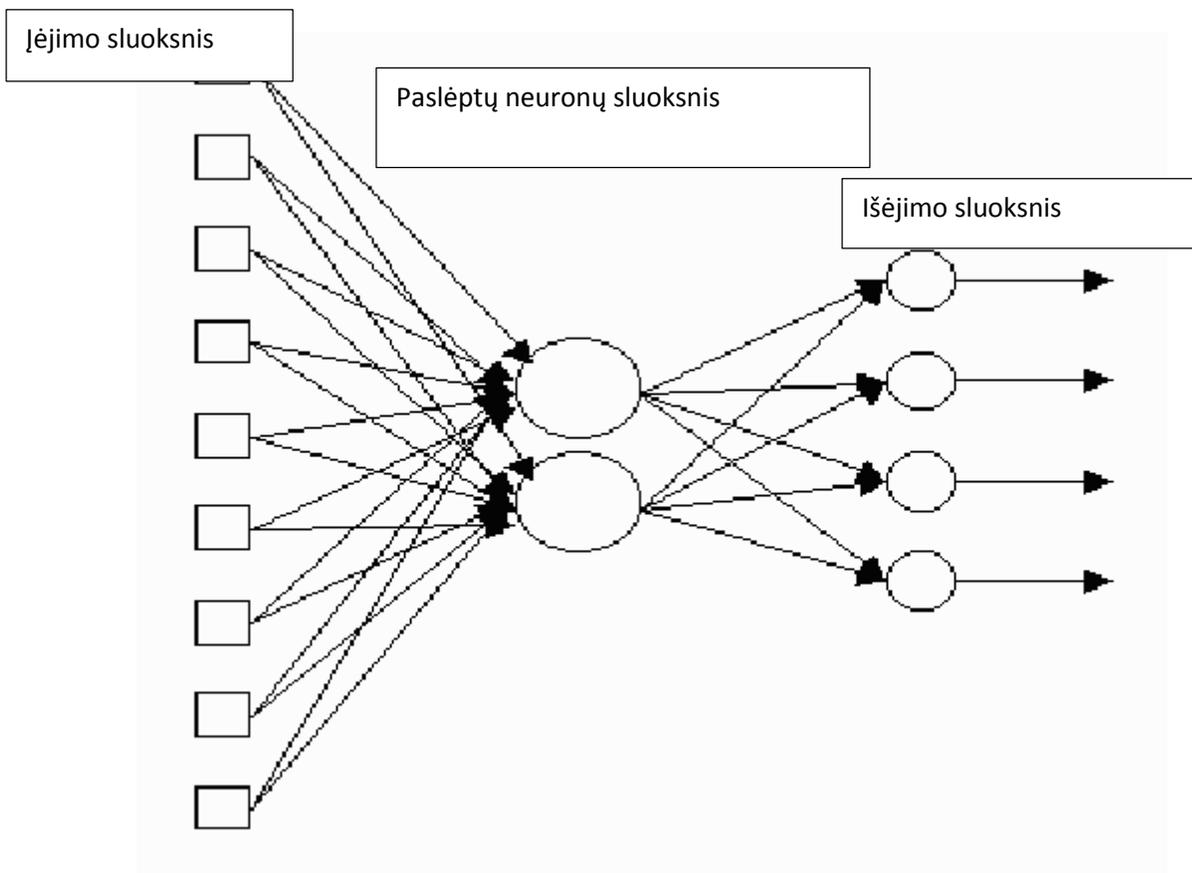
Dirbtinių neuroninių tinklų [28] atsiradimą lėmė biologiniai neuroniniai tinklai, kurie atkartoja žmogaus smegenų sandarą susidedančią iš daugelio tarpusavyje sujungtų neuronų (vidutiniškai jie turi keletą tūkstančių jungčių). Kiekvienas neuronas yra specifinė biologinė ląstelė, galinti generuoti elektrocheminį signalą, turinti ir informacijos apdorojimo galimybių ypatybę. Biologinis neuronas gali būti sąlyginai suskirstytas į tris dalis: įėjimo, laidumo bei išėjimo sluoksnius.

Dirbtinis neuronas bando imituoti biologinį neuroną. Įėjime turime signalą X (vektorių), kurį mes gauname kaip pradinius duomenis arba kaip kitų neuronų išėjimus. Kiekviena šio vektoriaus komponentė x_i dauginama iš atitinkamos svorio w_i ir visos šios sandaugos yra sumuojamos. Ši suma ir lemia neurono aktyvavimo lygį. Neuroninio tinklo išėjimo reikšmė

$$y = \varphi \left(\sum_{j=0}^n w_j x_j \right) \quad (22)$$

Kur $(x_0, x_1, x_2, \dots, x_n)$ įėjimai, (y) - išėjimas - w_j - įėjimų svoriai, o funkcija φ - aktyvavimo funkcija.

Neuronų tinklai, turintys daugiau nei vieną neuronų sluoksnį, vadinami daugiasluoksniais neuroniniais tinklais. Kiekvienas toks tinklas sudarytas iš įėjimų aibės, išėjimų neuronų sluoksnio ir paslėptų neuronų sluoksnio tarp įėjimų ir išėjimų (pav. 2.6).



2.6 pav. neuroninio tinklo pavyzdys

Neuroninio tinklo pagrindą sudaro įėjimai, neuronai, kurie šakojasi į kopijas paskirstomas kitiems neuronams, ir neurono išėjimas – išėjimo sluoksnis. „Matlab“ programiniame lange kuriamas neuroninis tinklas. Naudojami anksčiau gauti bruožų vektoriai. Tam yra užkraunama

duomenų bazė, gauta naudojant bruožų surinkimo metodus. Užkraunami duomenų rinkiniai kiekvieno naudoto metodo keturioms klasėms:

```
clc
clear all
close all
load('dvientropy.mat')
load('dvimoments.mat')
load('dviomega.mat')
load('keturiosentropy.mat')
load('keturios_moments.mat')
load('keturiosomega.mat')
load('trysentropy.mat')
load('trysmoments.mat')
load('trysomega.mat')
load('vienaentropy.mat')
load('vienamoments.mat')
load('vienaomega.mat')
```

Suformuojamas tikslo vektorius, keturioms klasėms :

```
T=[ ones(1,length(vienaent)),          zeros(1,length(dvient) + length(trysent)
+ length(keturios_entrop))
      zeros(1,length(vienaent)),          ones(1,length(dvient)),
zeros(1,length(trysent)+length(keturios_entrop));
      zeros(1,length(vienaent)+length(dvient)),          ones(1,length(trysent)),
zeros(1,length(keturios_entrop));
      zeros(1,length(vienaent)+length(dvient)+length(trysent)),
ones(1,length(keturios_entrop))];
```

Duomenų vektoriui formuoti, bruožai sugrupuojami pagal klases:

```
T_viena=[vienaent; vienamom;vienaomeg];
T_dvi=[dvient;dvimoment;dviomeg] ;
T_trys=[trysent;trysmoment;trysomeg];
T_keturios=[keturios_entrop;moment_keturios;keturiosomeg];
```

Suformuojamas duomenų vektorius:

```
Vec = [T_viena, T_dvi, T_trys, T_keturios];
```

Kuriamas neuroninis tinklas, tam naudojama „newff“ funkcija, taip pat nustatomas neuronų skaičius bei kiti parametrai. Programos fragmentas pateiktas pavyzdyje žemiau:

```
net = newff(Vec,T,110);
net.trainParam.epochs = 1000;
net.trainParam.goal = 0.001;
net=train(net,Vec,T);
out=sim(net,Vec);
```

Naudojant komandą „plot“ atvaizduojami neuroninio tinklo išėjimai:

```
hold on
figure(1)
plot(T(1,:), 'b.-');
hold on
plot(out(1,:), 'r.-')%pirmas isejims
figure(2)
plot(T(2,:), 'b.-');
hold on
plot(out(2,:), 'g.-')%antras isejims
figure(3)
plot(T(3,:), 'b.-');
hold on
plot(out(3,:), 'k.-')%trečias isejims
figure(4)
plot(T(4,:), 'b.-');
hold on
plot(out(4,:), 'm.-')%ketvirtas isejims
```

Sukurtas neuroninis tinklas išsaugomas „mat“ formatu.

```
save lasteles.mat net
```

Metodo patikimumui patikrinti, naudojami aukščiau paminėti bruožų surinkimo metodai.

Suformuojamas testavimo vektorius naudojant visus tris paminėtus bruožų surinkimo metodus (entropija, principinių komponentių koeficientai, ir „invariantiniai“ momentai):

```
tvec=[kktvienaent; ketvienamom; ketvienaomeg];
testVec = [tvec];
```

Tada “simuliuojamas” modelis ir lyginami rezultatai su mokymo imtimi:

```
out= sim(net, testVec);
% plot(T,'b.-')

level = 0.7;
Names = 'images';
arr = [];
for j=1:0.05:length(level)
```

Aprašomas automatinis metodas paskaičiuoti tikslumui testuojamos klasės. Algoritmas automatiškai padalina testuojamų nuotraukų kiekį iš atpažintų nuotraukų skaičiaus. Taip gaunama procentinė išraiška algoritmo patikimumo.

```
count = 0;
ok_ = 0;
for i=1:size(out,2)
    [maxvalue klase]=max(out(:,i));
    if maxvalue>level(j) && klase == 4;
```

```

        embryo=klase;
        ok_ = ok_+1
    else
        embryo = 0;
    end;
    count = count + 1;
end
arr = [arr (ok_/count)*100]
end

```

Komandos “plot“ naudojama atvaizduoti grafiškai :

- 1) tikimybinio slenksčio įtaką tikslumo rezultatui
- 2) teisingai algoritmo priskirtas nuotraukas atitinkamai klasei.

```

figure(1)
plot(level, arr, 'b.-')
figure(2)
plot(ok_, arr, 'b.-')

```

Realaus laiko sistemai, testavimo algoritme buvo naudojamas komandos „tic“ ir „toc“ sistemos greitaveikai tirti.

2.5.2. K – artimiausio kaimyno metodas

K-artimiausio kaimyno metodas (angl. vert k-nearest neighbor, k-NN) priklauso vektorinių metodų grupei. Jo esmė yra duomenų atvaizdavimas specialioje vektorinėje erdvėje. Vektorinės erdvės dimensijos atitinka naudojamų klasifikacijai raktinių požymių aibę (anksčiau minėti bruožų rinkiniai). Šis metodas veikia pagal paprastą algoritmą objektui randami artimiausi „k“ pagal tam tikrą (euklidinį, kosinusinį ir pan.) atstumą objektų iš apmokymo aibės, ištyrus gautus k kaimynų atstumus nustatoma, kokia kategorijai jų priklauso daugiausiai, ir tai kategorijai yra priskiriamas klasifikuojamas objektas (branduolys).

Matematiškai šis modelis pagal aprašomas taip: naujo atvaizdo priskyrimas klasei $c(i)$ jei $c(i)$ turi didžiausią panašumo rodiklį tarp visų kategorijų. Panašumo rodiklis apskaičiuojamas pagal formulę:

$$s(d, c_j) = \sum_{d_i \in k-NN} sim(d, d_i) y(d_i, c_j) \quad (23)$$

kur $sim(d, d_i)$ – panašumas tarp nuotraukos d ir klasės d_i .

Paprasčiausiu atveju apskaičiuojamas kaip euklidinis atstumas tarp vektorių, atitinkančių d ir d_j ;

Apskaičiavus šiuos rodiklius klasės priskyrimas vykdomas pagal formulę:

$$\arg \max_{j=1, \dots, m} (s(d, c_j)) \quad (24)$$

c_1, \dots, c_m – iš anksto apibrėžtos kategorijos.

Egzistuoja kelios algoritmo k-NN atmainos.

Gali būti kitaip apskaičiuojamas branduolio priskyrimo klasei funkcija, ir atstumas tarp „kaimynų“. Atvaizdo panašumą galima apskaičiuoti vietoj euklidinio atstumo panaudojant kosinusinį panašumą. Tokiu atveju duotiems atvaizdams atitinkantys vektoriai su svoriais yra

$$w_{i,j} = \frac{freq_{i,j}}{\max_i(freq_{i,j})} \times \log \frac{N}{n_i} \quad (25)$$

kur $freq_{i,j}$ yra bruožo i pasikartojimo dažnis atvaizde; N yra bendras paveikslėlių skaičius ir n_i yra atvaizdų, kuriose pasitaiko atitinkamas atstumas skaičius. Tada panašumo funkcija

$$sim(d_1, d_2) = \frac{V_1 * V_2}{\|V_1\|_2 \|V_2\|_2} = \frac{\sum_{i=1}^n w_{1i} \times w_{2i}}{\sqrt{\sum_{i=1}^n w_{1i}^2} \sqrt{\sum_{i=1}^n w_{2i}^2}} \quad (26)$$

Kuriamas K- artimiausio kaimyno algoritmas. Užkraunama duomenų bazė:

```
clc
clear all
close all
load('dvientropy.mat')
load('dvimoments.mat')
load('dviomega.mat')
load('keturiosentropy.mat')
load('keturios_moments.mat')
load('keturiosomega.mat')
load('trysentropy.mat')
load('trysmoments.mat')
load('trysomega.mat')
load('vienaentropy.mat')
load('vienamoments.mat')
load('vienaomega.mat')
load('vienaentropy.mat')
load('dvitestentropy.mat')
load('trysyentropys.mat')
load('ketvienaentropy.mat')
load('kktvienaomega.mat')
    load('kktvienamoments.mat')
        load('kktvienaentropy.mat')
```

Suformuojamas tikslo vektorius:

```
T=[ ones(1,length(vienaent)), ones(1,length(dvient))*2,
ones(1,length(trysent))*3, ones(1,length(keturios_entrop))*4];
```

Taip pat suformuojamas duomenų bazės vektorius:

```
T_viena=[vienaent; vienamom;vienaomeg];
T_dvi=[dvient;dvimoment;dviomeg] ;
T_trys=[trysent;trysmoment;trysomeg];
T_keturios=[keturios_entrop;moment_keturios;keturiosomeg];

Vec = [ T_viena, T_dvi, T_trys, T_keturios];
```

Sukuriamas vektorius testuojamai klasei:

```
testas=[kktvienaent; ketvienamom; ketomeg]
```

Klasifikuojami duomenys naudojant artimiausio kaimyno algoritmą. Nurodomas kiekis artimiausių kaimynų kurie bus naudojami klasifikavime, taip pat atstumo metodas ir taisyklės kaip bus klasifikuojama testavimo imtis.

```
out = knnclassify(testas',Vec',T',15,'euclidean' , 'consensus' );
```

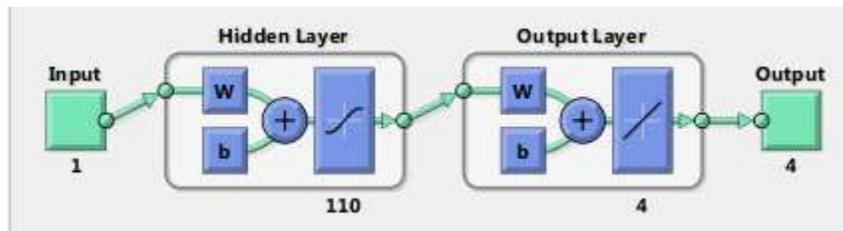
Tada naudodami knnclassify funkciją klasifikuojami duomenys, ir priskiriant atitinkamą vektorių atsitiktinių duomenų tikrinami rezultatai.

2.6. Skyriaus apibendrinimas

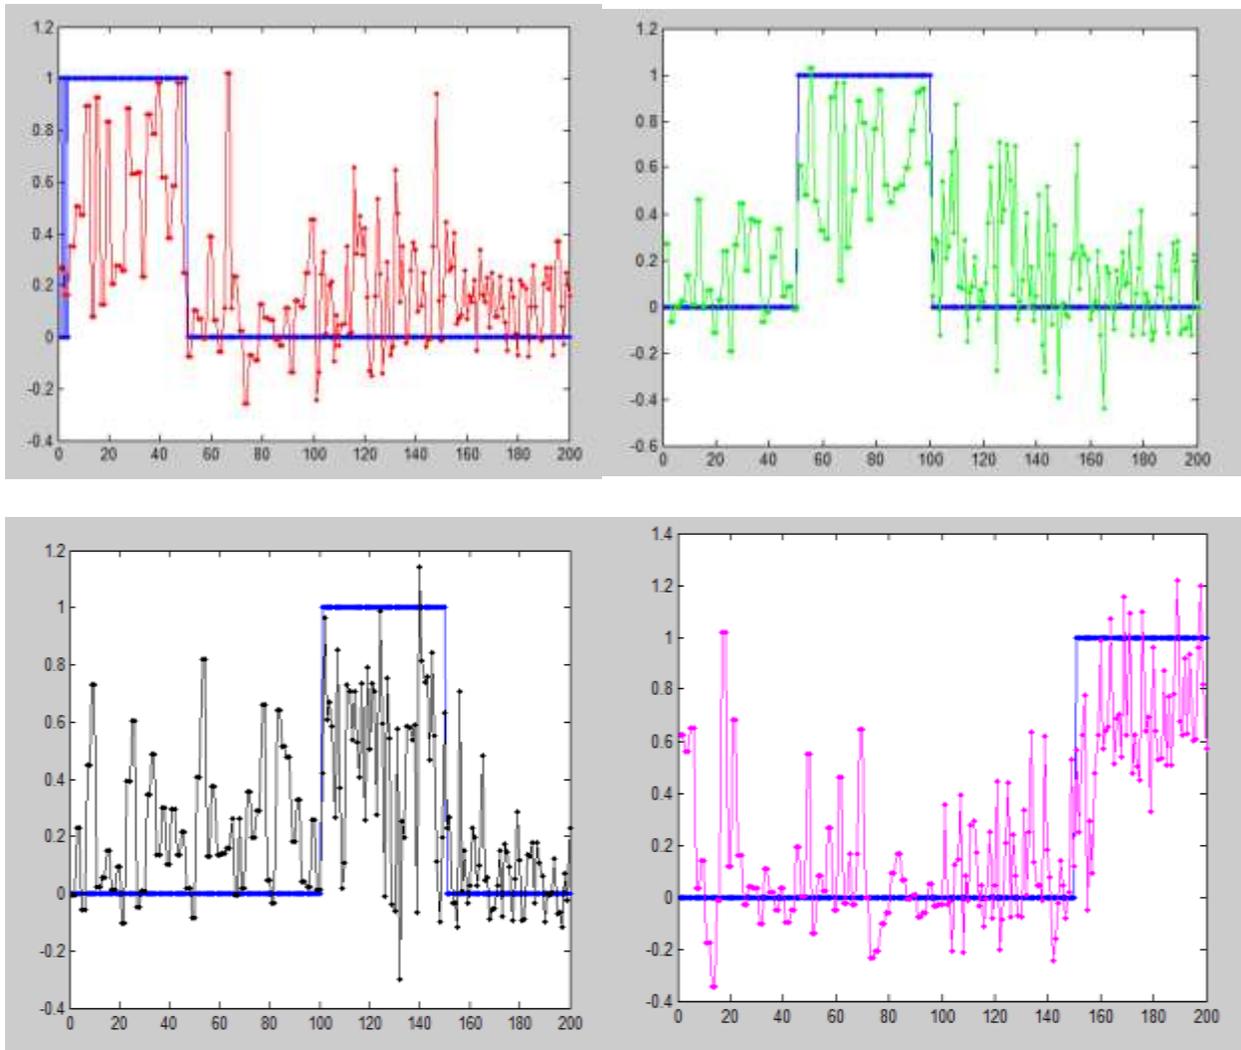
Antrame skyriuje buvo pristatyti metodai, kurie bus naudojami tolimesniam tyrimui. Bruožų išskyrimui taikomi statistiniai metodai :entropija, invariantiniai momentai, principinių komponentų koeficientai. Klasifikavimui pasirinkti du metodai : 1) su mokymu- neuroninis tinklas, ir 2) be mokymo K-artimiausio kaimyno algoritmas. Pristatytas papildomas algoritmas testavimams atlikti.

3. Eksperimentinis tyrimas

Klasifikavimui, kaip minėta ankstesniuose tyrimuose panaudoti du metodai, neuroniniai tinklai ir K- artimiausio kaimyno algoritmas. Tyrimas pradedamas formuojant duomenų bazę. Kadangi nuo duomenų bazės priklauso visas tolimesnis tyrimas. Bruožams išgauti naudojami trys anksčiau paminėti metodai. Kadangi nuotraukos yra labai panašios, ir bruožus identifikuoti yra pakankamai sunku, todėl pasirinkti trys statistiniai metodai. Buvo tirta bruožų įtaka neuroninio tinklo klasifikavimo rezultatams. Padavus vieną įėjimą (entropijos reikšmę) į neuroninį tinklą(3.1 pav) gauti tokie išėjimai(3.2 pav):



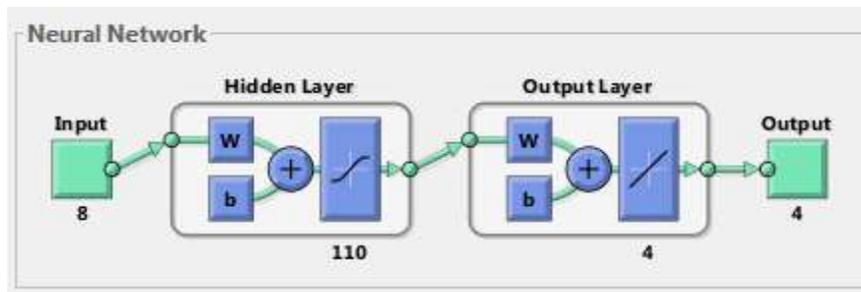
3.1 pav. Neuroninis tinklas su vienu įėjimu



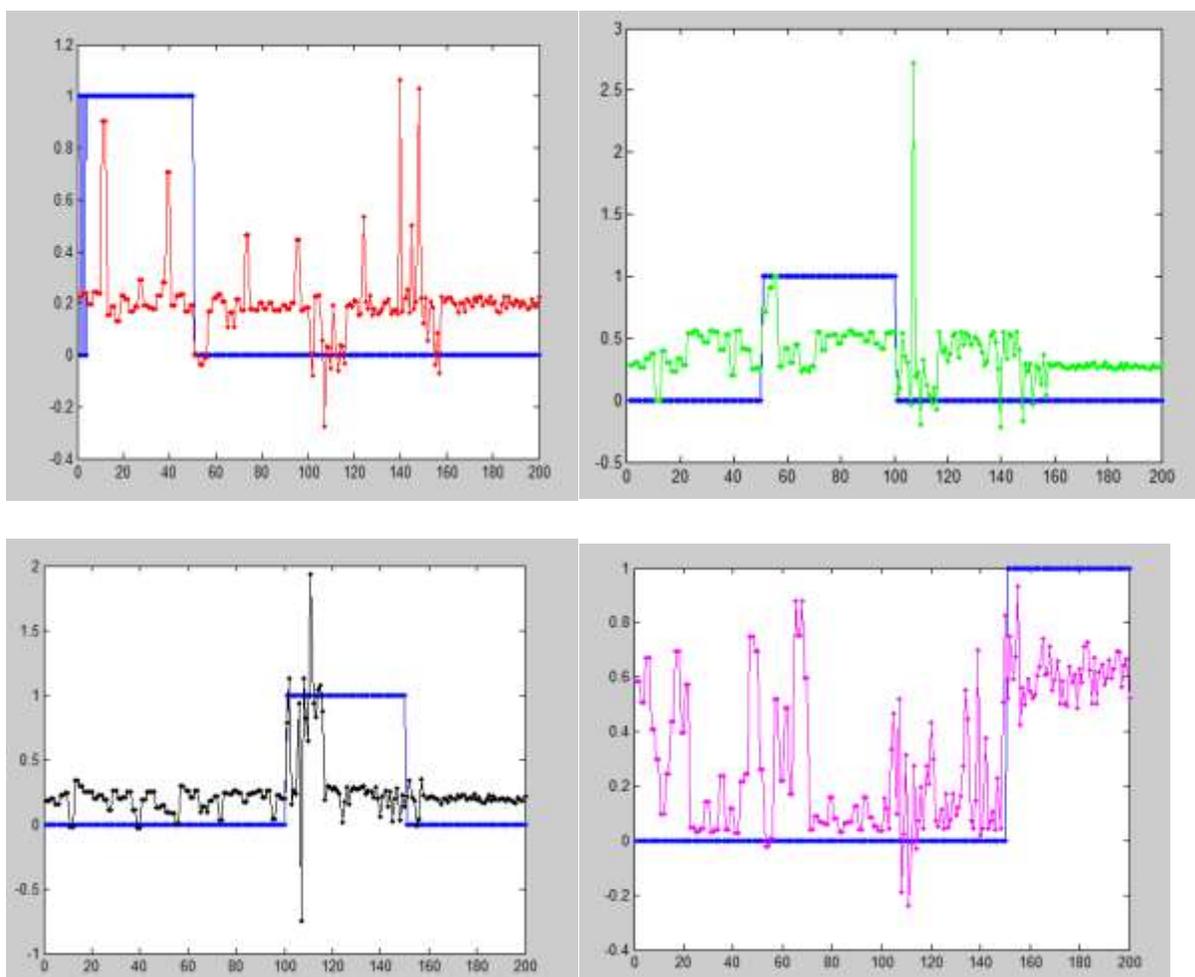
3.2 pav. Neuroninio tinklo išėjimai visų keturių klasių (padavus vieną įėjimą)..

Kaip matyti iš neuroninio tinklo išėjimo bruožų nėra pakankamai, suklasifikuoti duomenims.

Į neuroninio tinklo įėjimą padavus entropijos koeficientą ir septynis momentus rezultatai gavosi tokie (3.3 ir 3.4 pav):



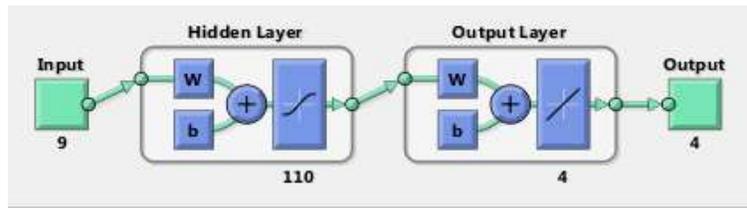
3.3 pav. Neuroninis tinklas su aštuoniais įėjimais.



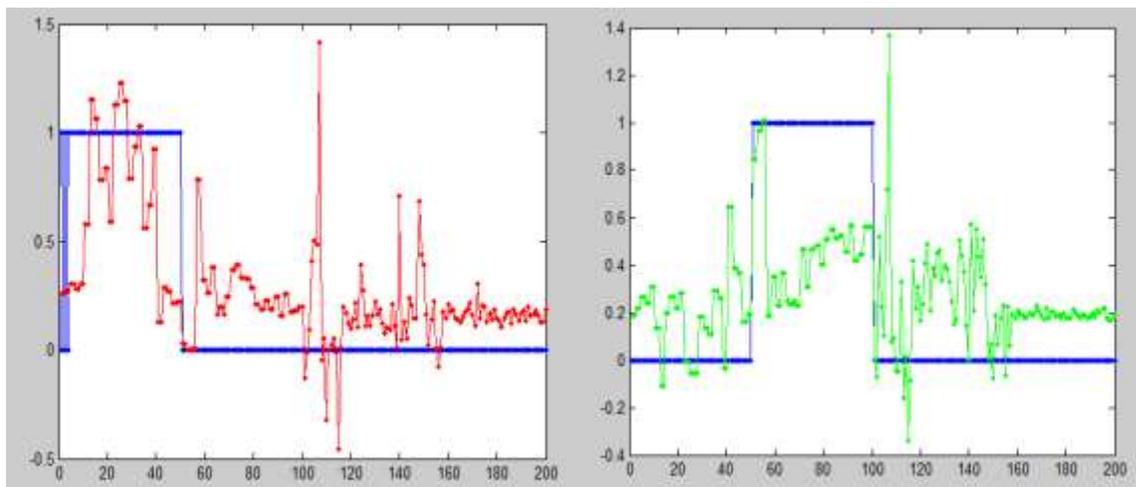
3.4 pav. Neuroninio tinklo išėjimai.

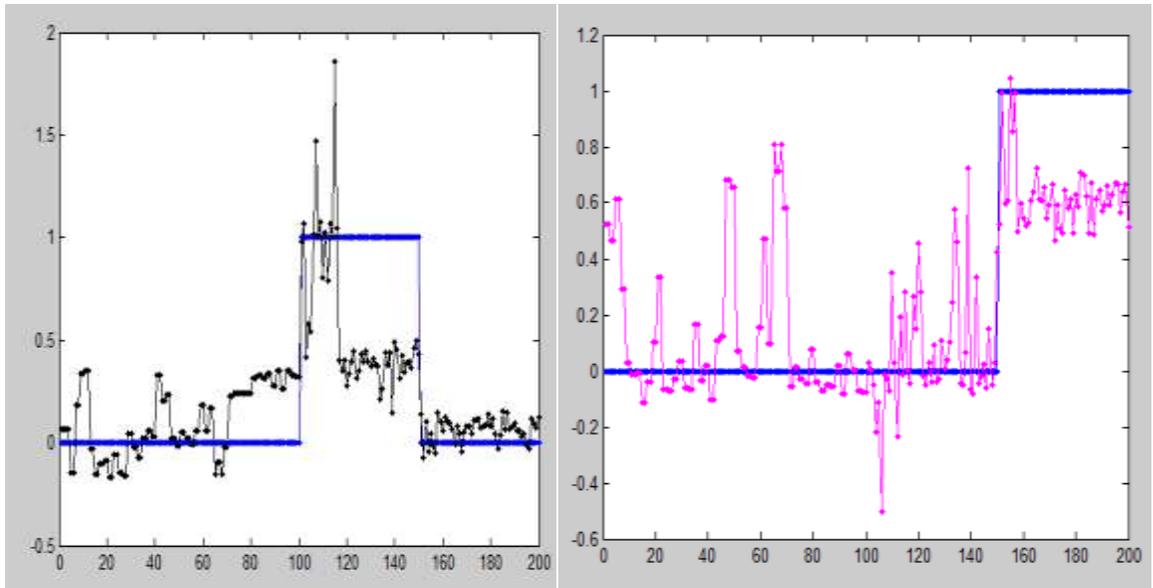
Iš rezultatų galima daryti išvadas kad klasių atskirtinumas yra labai menkas, todėl duomenų neužtenka tinkamai suklasifikuoti duomenims. Į neuroninį tinklą buvo paduoti ir PCA (ang. Principal component analyzės) koeficientai. Grafikuose atvaizduota rezultatai, kai

paduodamas 1 koeficientas prie anksčiau minėtų entropijos, ir momentų koeficientų, kai paduodama 15, ir 30 koeficientų. Daugiau tyrimų nebuvo tikslinga daryti, kadangi esant 15 koeficientų rezultatai gavosi geriausi. Didinant koeficientų skaičių rezultatai yra iškraipomi, mažinant - duomenų yra per mažai. Rezultatai atvaizduoti paveikslėliuose 3.5 -3.10.

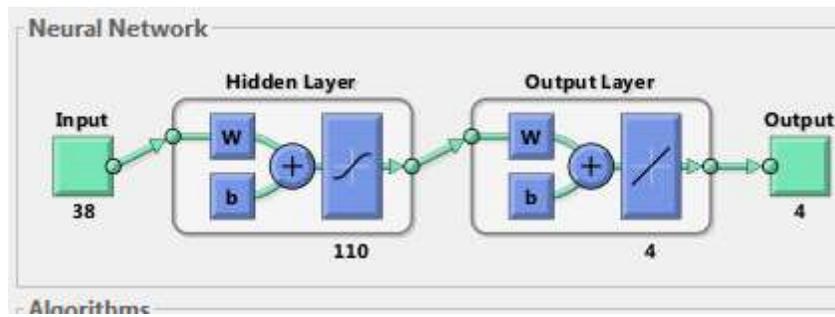


3.5 pav. Neuroninis tinklas su devyniais įėjimais(entropija, 7-i momentai, ir vienas PCA koeficijantas)

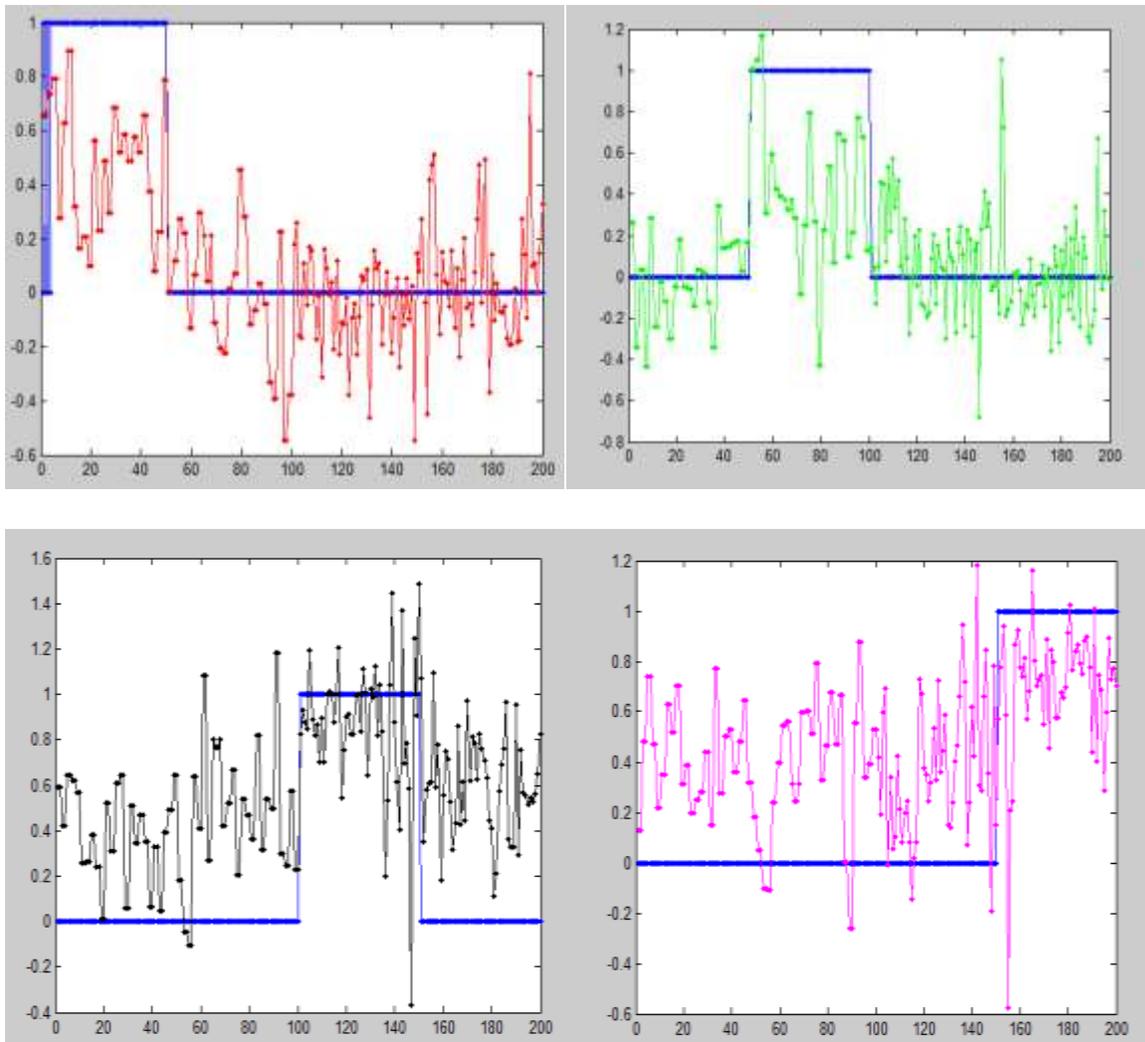




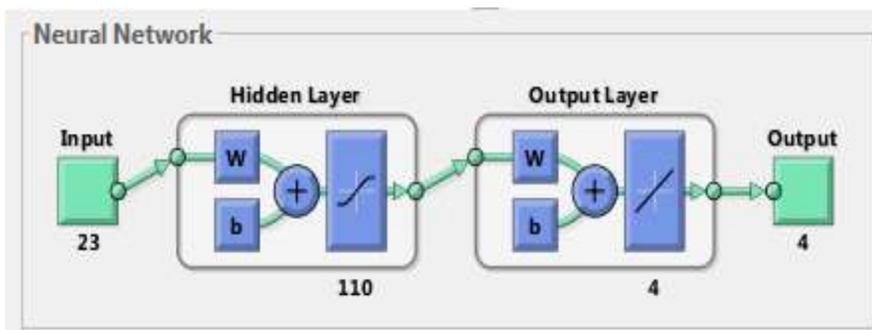
3.6 pav. neuroninio tinklo išėjimai



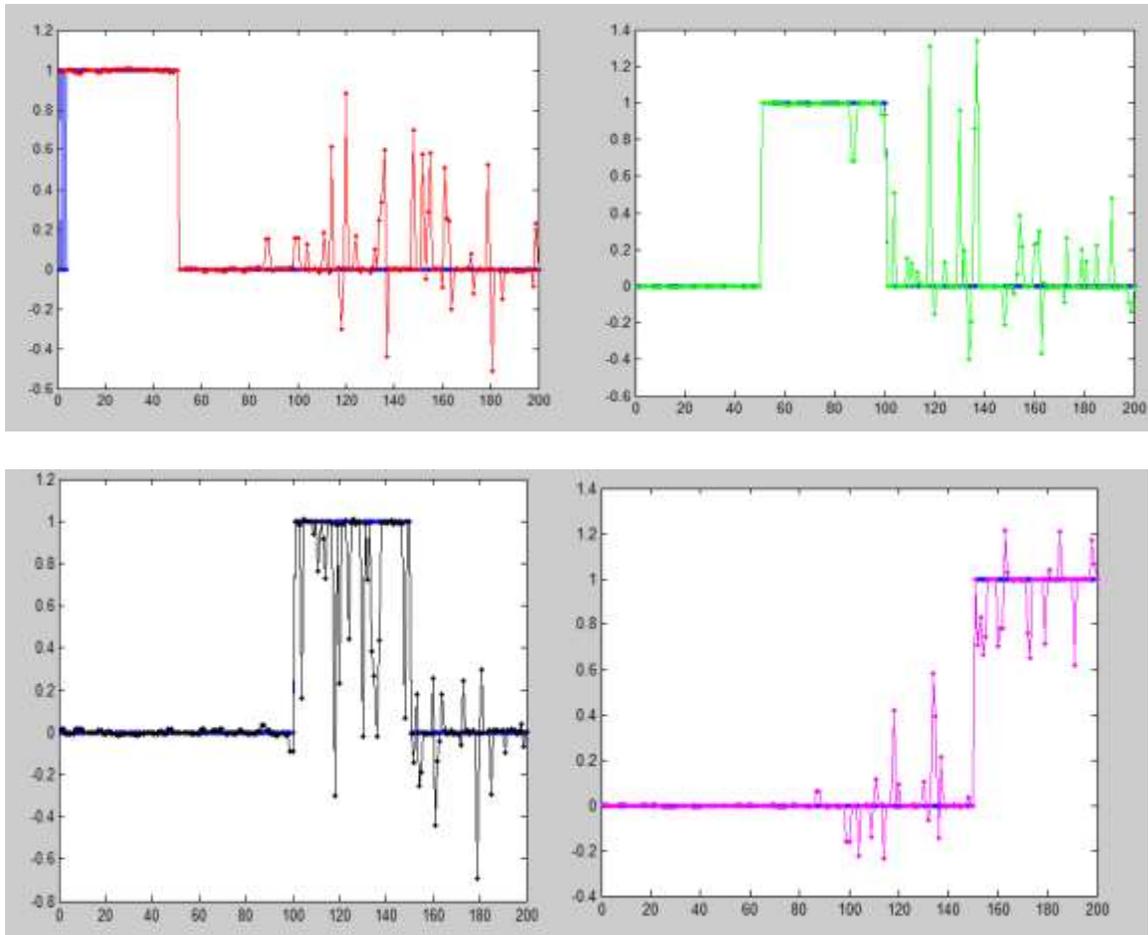
3.7 pav. Neuroninis tinklas su 38-iais įėjimais(entropija, 7-i momentai, ir trisdešimt PCA koeficientas)



3.8 pav., neuroninio tinklo išėjimai (naudojant 38 įėjimus)

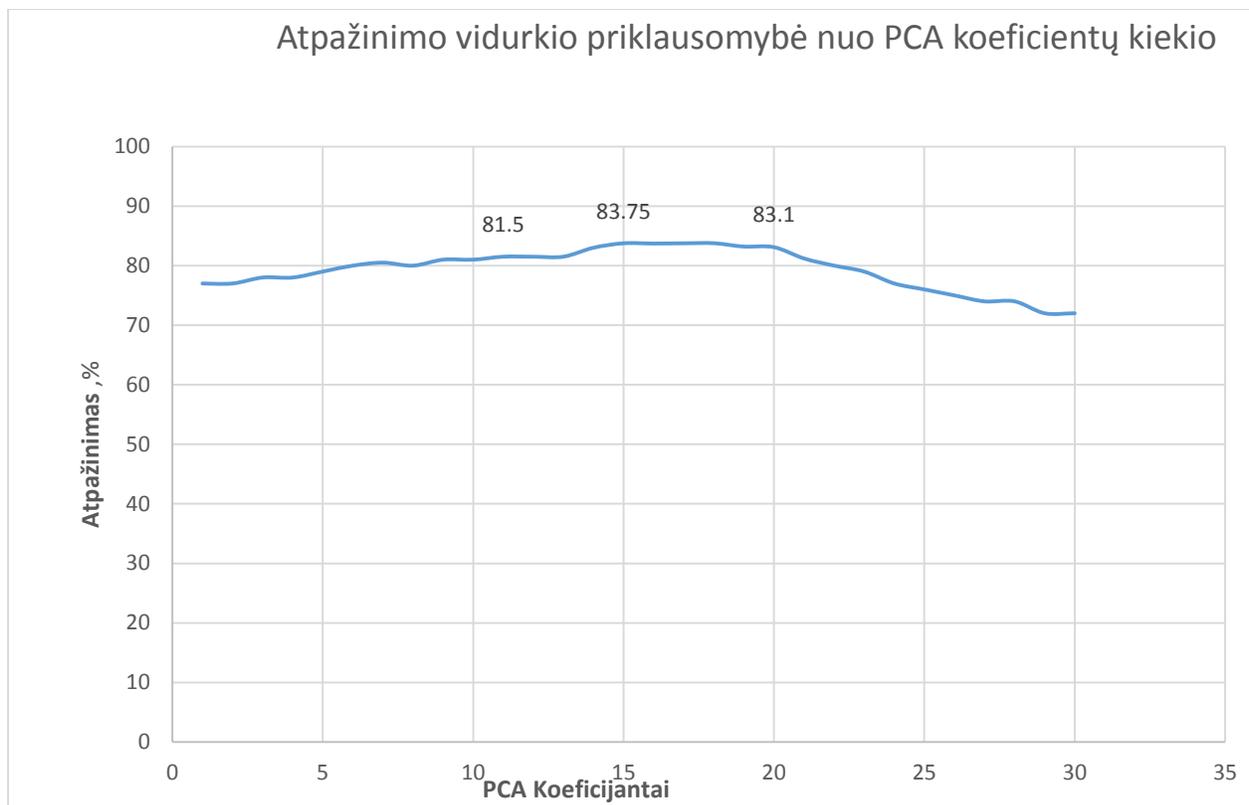


3.9 pav. Neuroninis tinklas su dvidešimt trimis įėjimais (entropija, 7-i momentai, ir penkiolika PCA koeficientų)



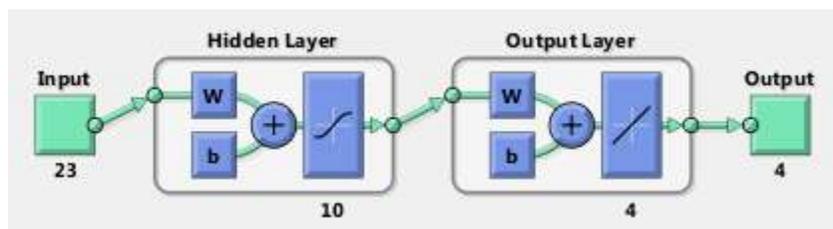
3.10 pav. neuroninio tinklo išėjimai(110 neuronų)

Kaip matyti iš rezultatų(pav. 3.10), klasifikacijos rezultatai pakankamai geri, kadangi požymiai yra arti tikslo vektoriaus, o „triukšmai“ kuriuos galima matyti grafikuose yra suprantamas dalykas, kadangi bruožai yra gana panašūs kiekvienos klasės. Paveiksle 7 pateiktas išvestas vidurkis klasių atpažinimo , ir jo priklausomybė nuo PCA koeficientų skaičiaus naudojant neuroninį tinklą. Geriausias rezultatas gautas esant 15 koeficientų.

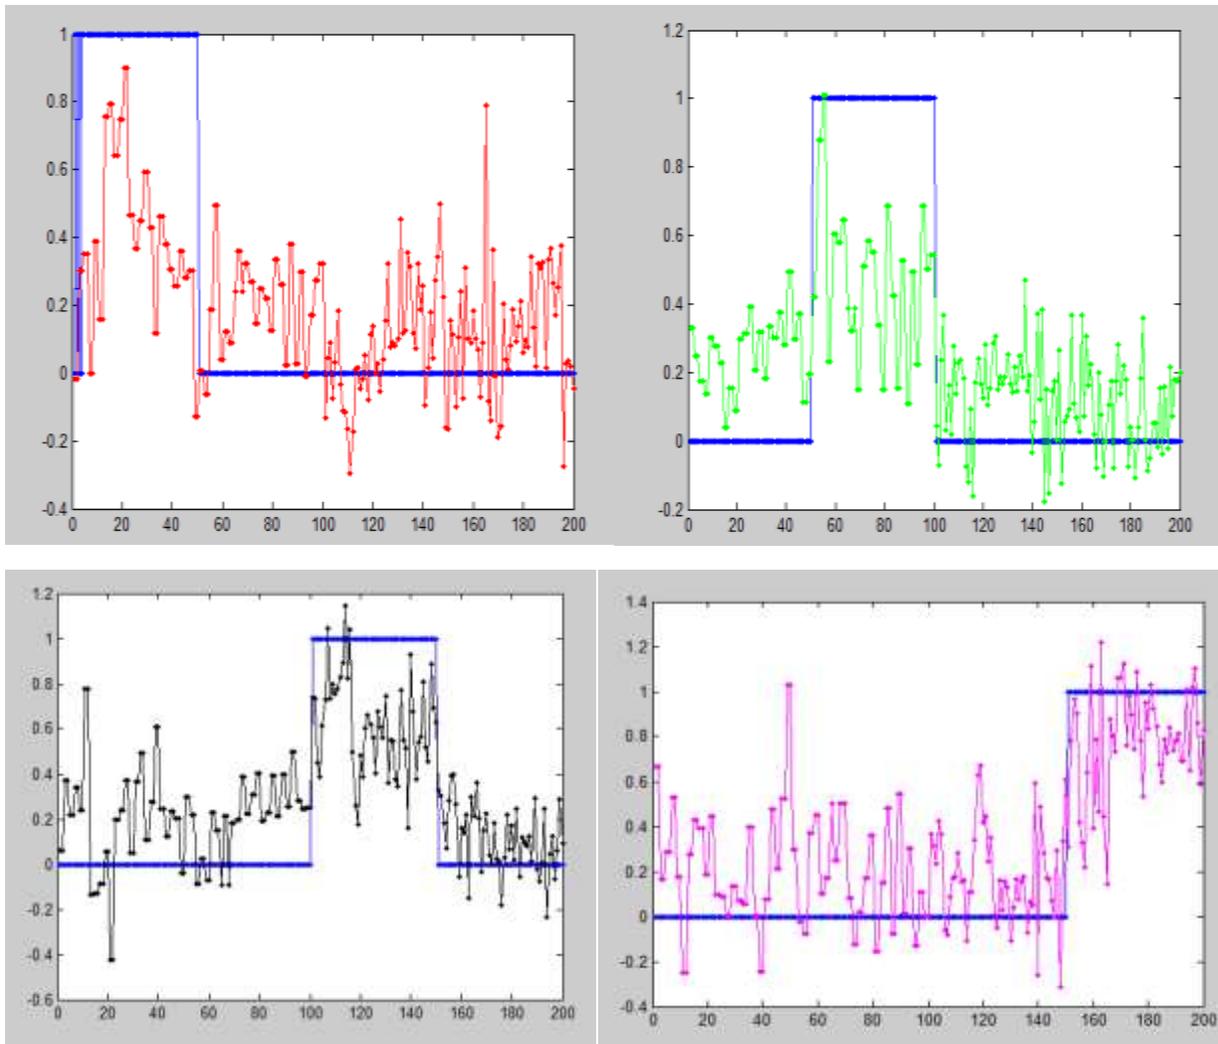


3.11 pav. principinių koeficientų atpažinimo tikslumui naudojant neuroninį tinklą.

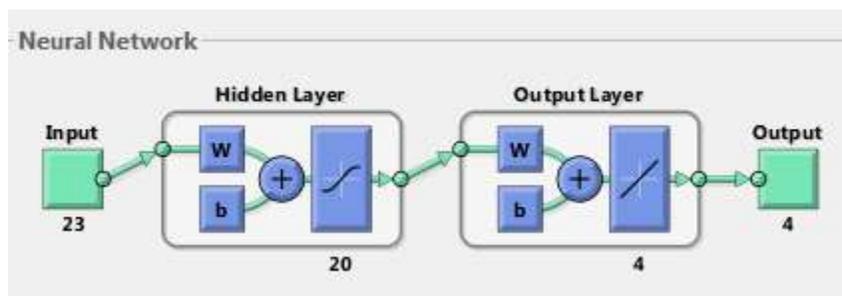
Neuronų skaičius, prie kurio klasifikacijos rezultatai būtų geriausi, taip pat buvo nustatytas, eksperimento būdu. Geriausias neuroninio tinklo išėjimas gautas prie 110 neuronų (pav 3.10). Žemiau pateiktas eksperimentas su neuronų skaičiumi (pav 3.12-3.17).



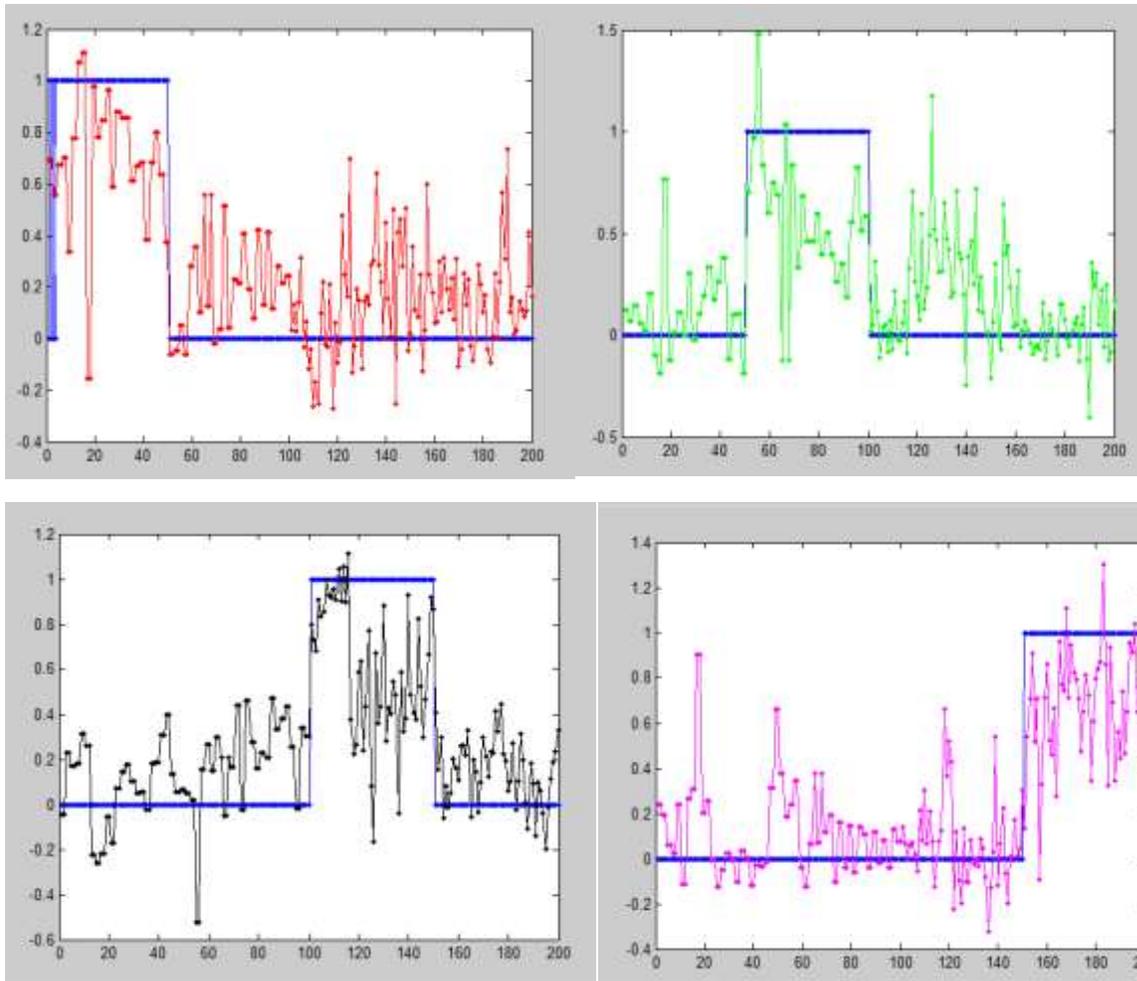
3.12 pav. Neuroninis tinklas su dešimt neuronų



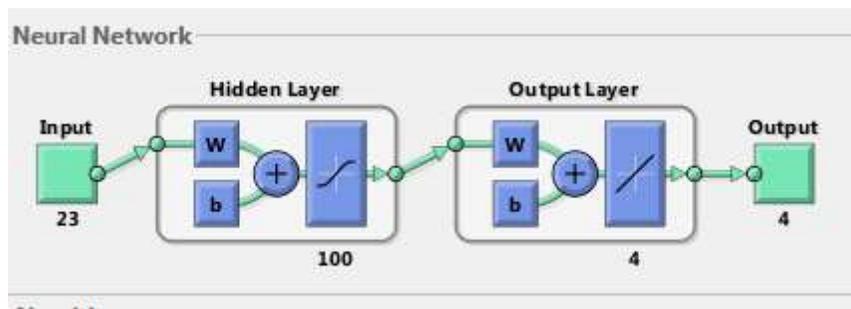
3.13 pav. Neuroninio tinklo išėjimai.



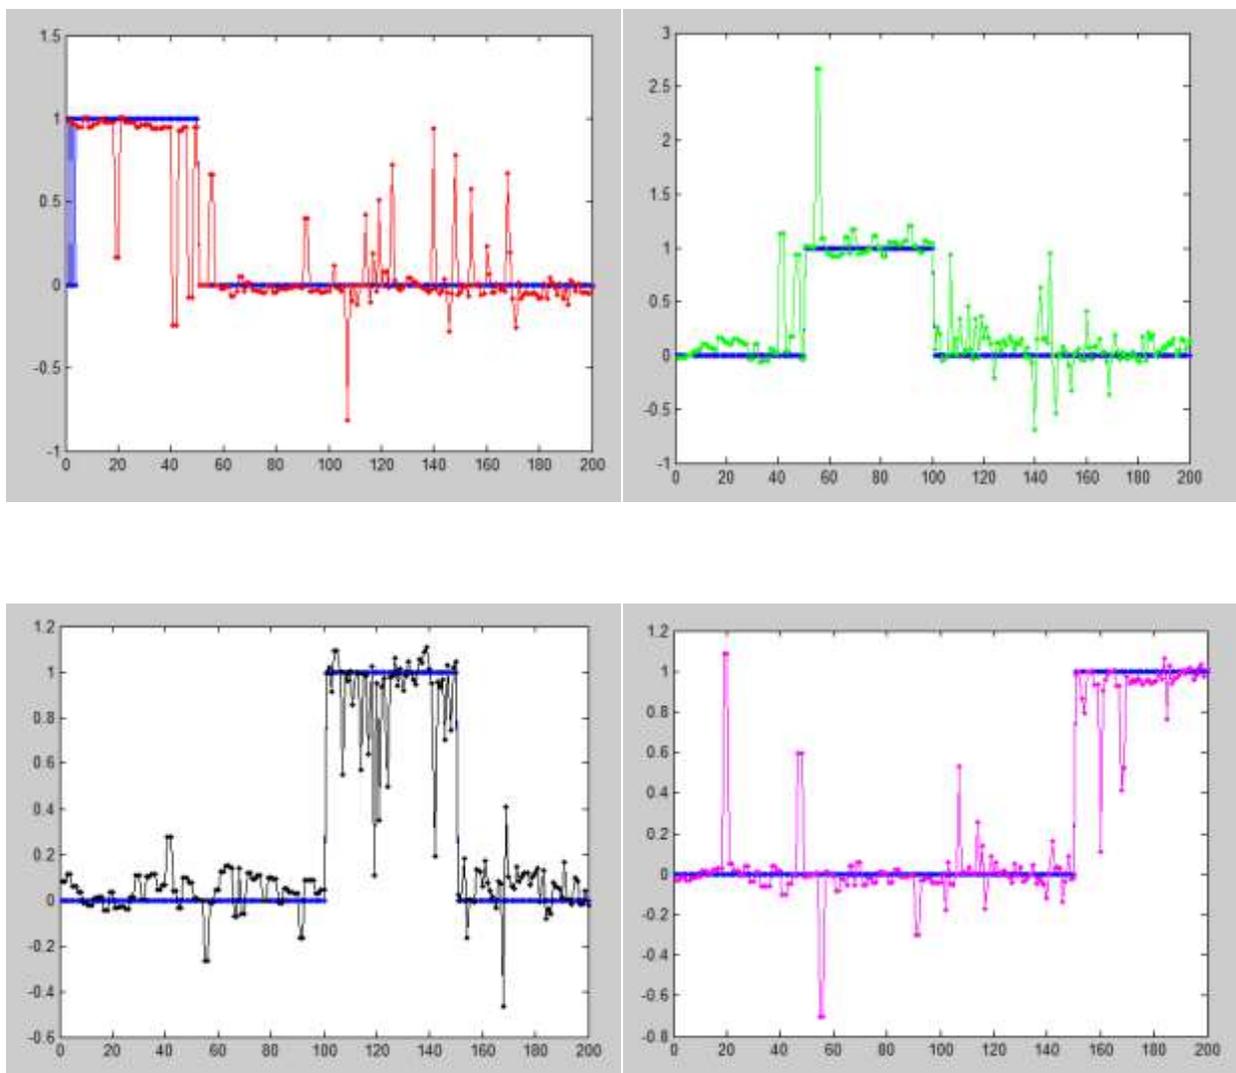
3.14 pav. Neuroninis tinklas su dvidešimt neuronų.



3.15 pav. neuroninis tinklo išėjimai.

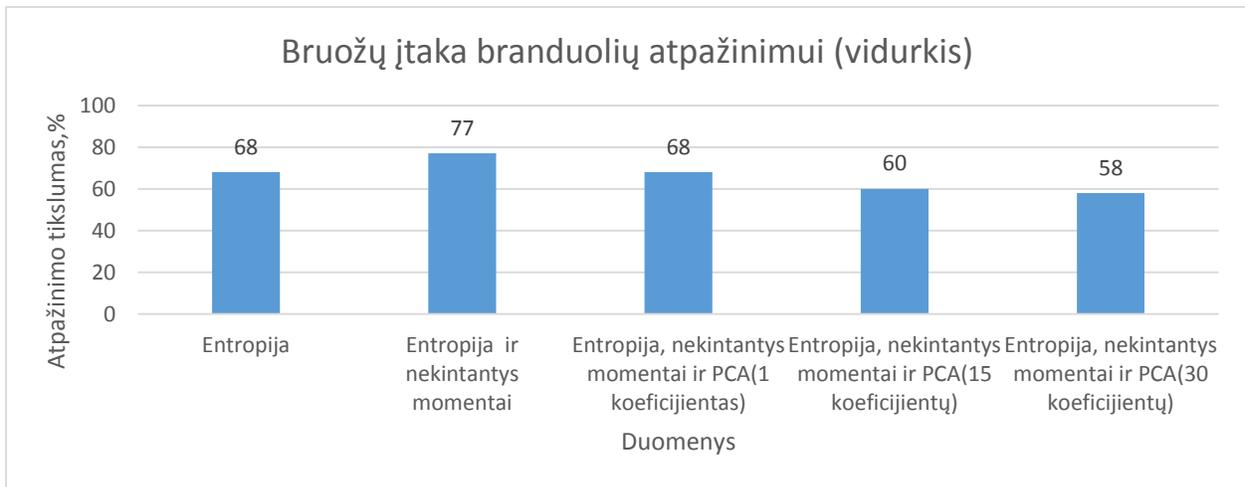


3.16 pav. neuroninis tinklas su 100 neuronų.



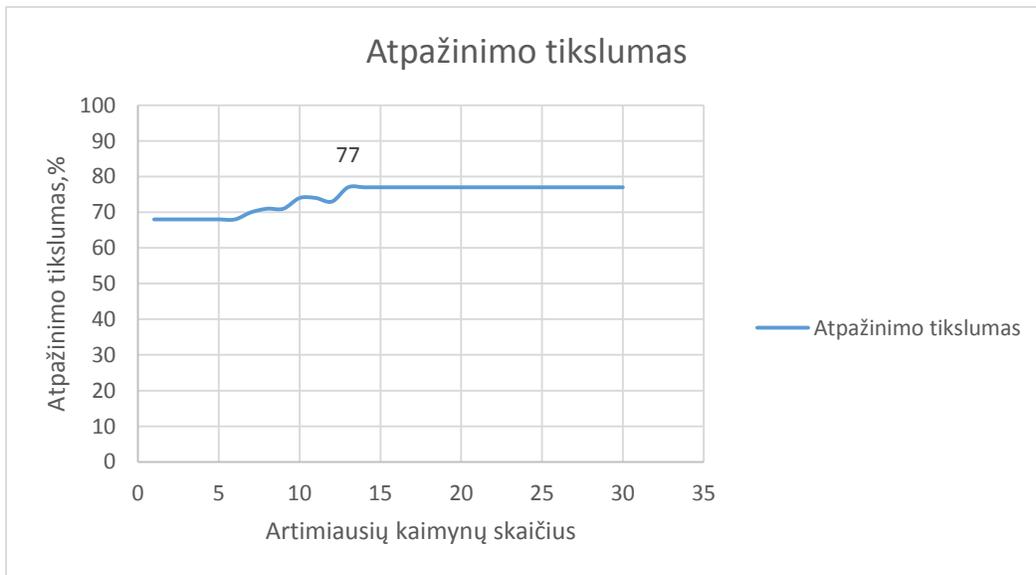
3.17 pav. neuroninio tinklo išėjimai.

Tiriant metodą artimiausio kaimyno algoritmu taip pat eksperimento būdu, buvo nagrinėjama duomenų kiekis įtakojantis atpažinimo rezultata. Tyrimas buvo atliekamas tokiu principu: pirmiausia buvo tiriami klasifikatoriaus rezultatai naudojant tik entropijos koeficientą, po to buvo paduodami į klasifikatorių Nekintamų momentų metodu gauti duomenys, ir PCA koeficientai. Geriausi rezultatai gavo si naudojant entropija ir inavariantinius momentus(3.18 pav.). Todėl tolimesniuose tyrimuose PCA koeficientai nenaudojami.



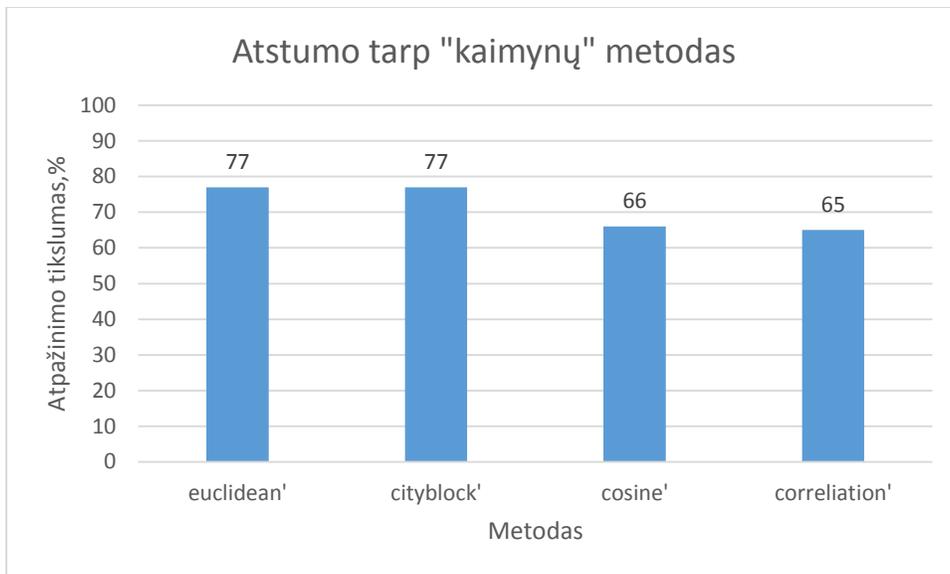
3.18 pav. Naudojamų bruožų įtaką K -artimiausio kaimyno algoritmui

Buvo tiriamas artimiausių kaimynų skaičius naudojamas klasifikavimui. Geriausias rezultatas gautas naudojant 13 kaimynų, kaimynų skaičių didinant rezultatas nebesikeičia.

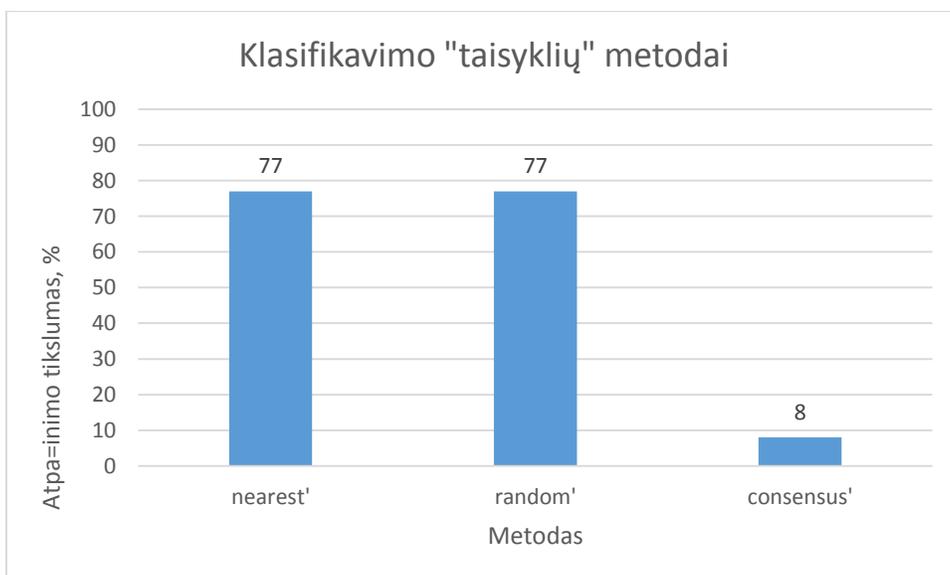


3.19 pav. Naudojamų kaimynų „ k “ įtaka atpažinimo tikslumui.

Tiriant artimiausio kaimyno algoritmo parametrus, buvo ištirti artimiausio kaimyno atstumo, bei klasifikavimo taisyklių metodai. (3.20, 3.21 pav.)



3.20 pav. Atstumo skaičiavimo metodo įtaka atpažinimo tikslumui

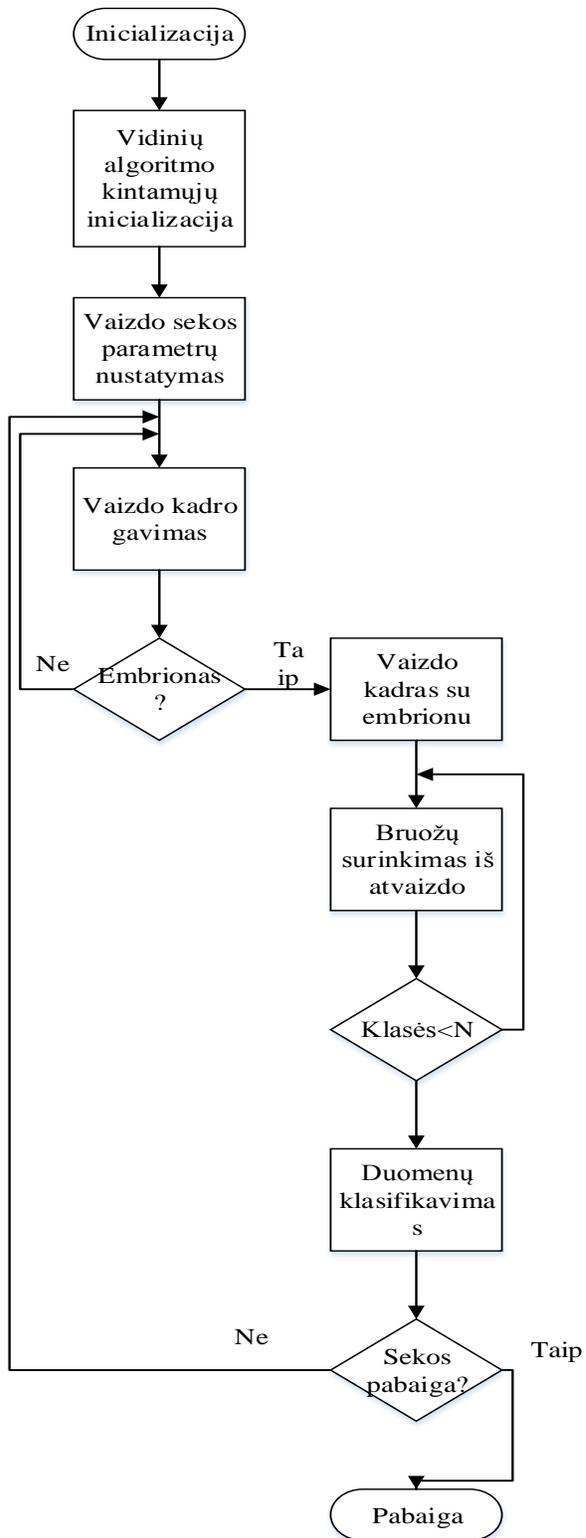


3.21 pav. Klasifikavimo taisyklių metodo įtaka atpažinimo tikslumui

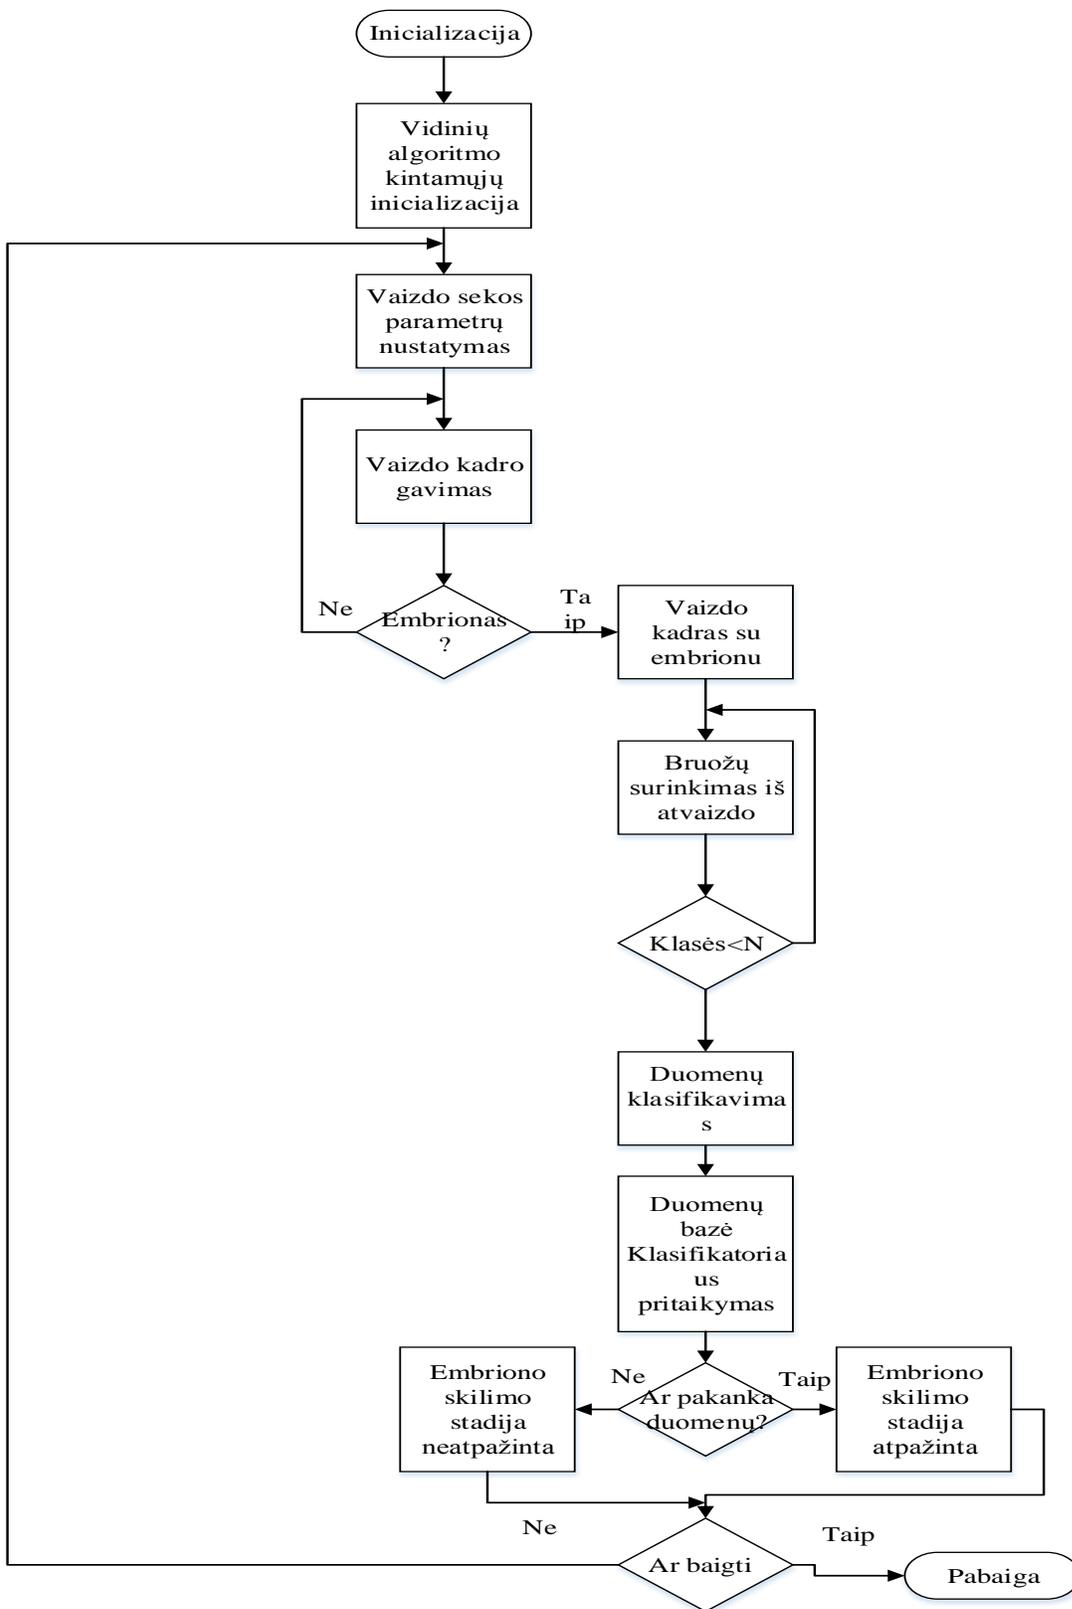
3.2 Siūlomas algoritmas

Pateikti du algoritmai, kadangi patį tyrimą galima suskirstyti į dvi atskiras dalis:

1. Bruožų surinkimas ir klasifikavimas;
2. Realus siūlomo metodo veikimas;



3.22 pav. Mokymosi algoritmas



3.23 pav. Testavimo algoritmas

Mokymosi algoritmas(3.22pav). Inicijuojamas algoritmas, nustatomi pradiniai nustatymai, tokie kaip duomenų saugyklos, duomenų kiekis, nuotraukų parametrai. Parenkama nuotraukų seka. Gaunama nuotrauka, jeigu nuotraukoje yra embriono atvaizdas, duomenys grupuojami, jeigu ne skenuojamas kitas paveikslėlis. Surenkami anksčiau paminėti bruožai, kurie yra surūšiuojami pagal klases, ir išsaugomi duomenų bazėje. Surūšiuoti duomenys klasifikuojami naudojant atitinkamą neuroninių tinklų ar artimiausio kaimyno klasifikatorių.

Testavimo, realaus veikimo algoritmas(3.23pav): Kartojamas tas pats ciklas kaip ir mokymosi algoritme. Gauti bruožai kiekvieno atvaizdo lyginami su klasifikatoriaus išėjimu. Jeigu pasirinktas klasifikatorius atpažįsta atvaizdą, skilimo stadija priskiriama atitinkamai klasei, o jeigu duomenų nepakanka atvaizdas atmetamas. Atvaizdų tikrinimas vyksta kol vartotojas nusprendžia baigti.

3.3. Skyriaus apibendrinimas

Trečiame skyriuje buvo tiriama bruožų įtaka klasifikavimo rezultatams.

Neuroninio tinklo geriausi rezultatai gauti naudojant entropijos reikšmę, 7is invariantinius momentus ir 15 principinių komponentų koeficientų. Neuronų skaičius taip pat labai įtakoja rezultatą. Esant 110 neuronų klasifikavimo rezultatai geriausi.

K-artimiausio kaimyno algoritmas geriausiai klasifikuoja duomenis naudojant entropijos reikšmę ir 7-is invariantinius momentus. Naudojant 13-a kaimynų klasifikavimo rezultatai yra geriausi. Tariant atstumo skaičiavimo algoritmus nustatyta kad tiek naudojant „euclidean“ tiek „cityblock“ rezultatus gauname tokius pačius. Naudojant klasifikavimo taisykles „nearest“ ir „random“ gavom taip pat tokius pat rezultatus. Tyrimas buvo atliekamas naudojant 4-ą klasę, kadangi parametrai naudojant abu algoritmus keturių branduolių gaunasi prasčiausi. Tolimesniuose tyrimuose naudojant K- artimiausio kaimyno algoritmą bus naudojami atstumui skaičiuoti „euclidean“ metodas, Klasifikavimo taisyklė „nearest“ ir kaimynų skaičius 13-a.

Algoritmų greitaveika, taip pat turi skirtumų: neuroninis tinklas kadram apdoroja per 0,094s, K-artimiausio kaimyno algoritmas per 0,03s

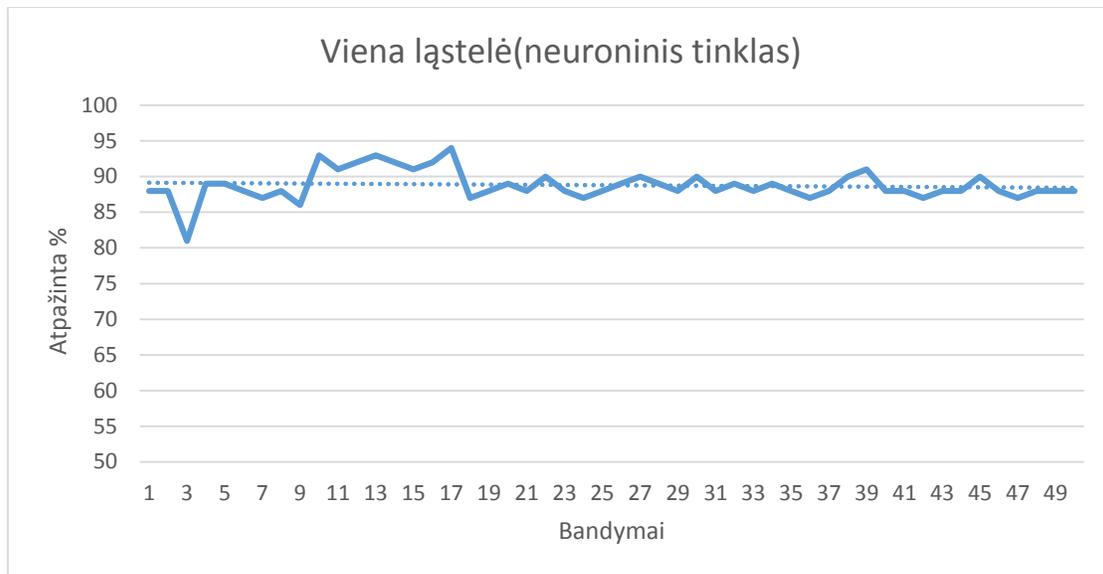
4. Rezultatai

Tyrimo rezultatams nustatyti buvo suformuota 50 skirtingų vektorių su skirtingais laikais gautomis nuotraukomis. Tai reiškia kad buvo tikrinta 2500 nuotraukų. Rezultatai pateikiami lentelėse žemiau naudojami tyrimo metu gauti geriausi parametrai. Rezultatų tikslumas priklauso nuo vystymosi stadijos, kaip matyti iš rezultatų, esant nuotraukoje vienam branduoliui, siūlomas metodo atpažinimas naudojant neuroninį tinklą 88.78%, naudojant K- artimiausio kaimyno algoritmą 86.4%, esant dviem ląstelėms neuroninio tinklo klasifikatorius atpažįsta vidutiniškai 88,32 %. K- artimiausio kaimyno algoritmas **85.92%**, esant trimis branduoliams atpažinimo tikslumas krenta iki **78.52%** naudojant neuroninį tinklą ir **79.12%** naudojant artimiausio kaimyno klasifikatorių. Esant keturiems branduoliams **79.4%** ir atinkamai 77%

Lentelė 4.1 pav. vienos ląstelės atpažinimo tikslumas naudojant neuroninį tinklą.

Bandymas	Viena ląstelė
1	88
2	88
3	81
4	89
5	89
6	88
7	87
8	88
9	86
10	93
11	91
12	92
13	93
14	92
15	91
16	92
17	94
18	87
19	88
20	89
21	88

22	90
23	88
24	87
25	88
26	89
27	90
28	89
29	88
30	90
31	88
32	89
33	88
34	89
35	88
36	87
37	88
38	90
39	91
40	88
41	88
42	87
43	88
44	88
45	90
46	88
47	87
48	88
49	88
50	88
Vidurkis	88.78
Standartinis nuokrypis	2.081249625

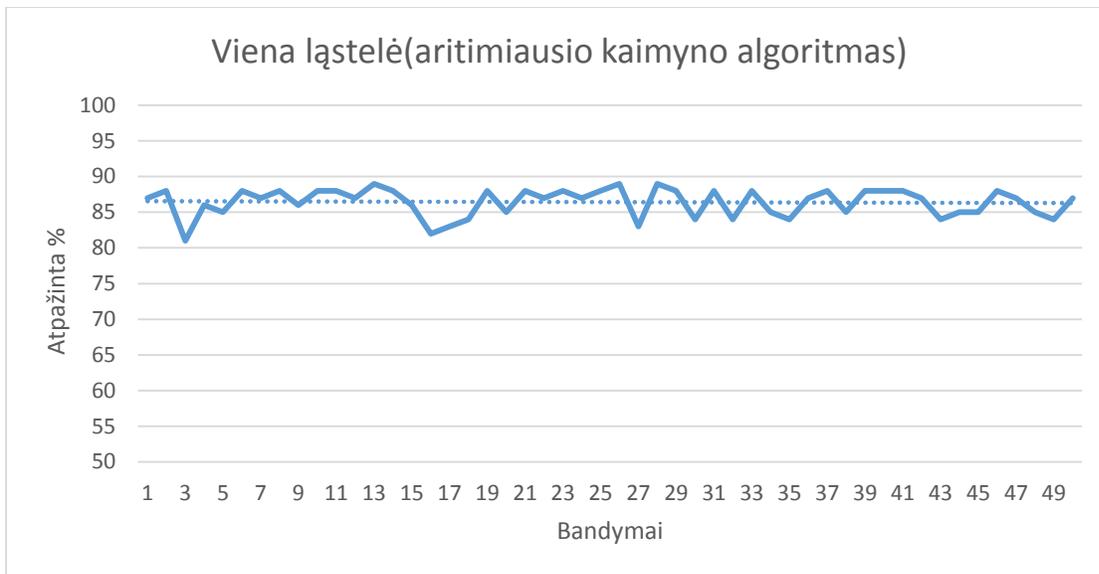


4.1 pav. Vienos ląstelės bandymų skaičius ir atpažinimo tikslumas

Lentelė 4.2 pav. vienos ląstelės atpažinimo tikslumas naudojant K- aritmiausio kaimyno algoritmą..

Bandymas	Viena lastelė
1	87
2	88
3	81
4	86
5	85
6	88
7	87
8	88
9	86
10	88
11	88
12	87
13	89
14	88
15	86
16	82
17	83
18	84
19	88

20	85
21	88
22	87
23	88
24	87
25	88
26	89
27	83
28	89
29	88
30	84
31	88
32	84
33	88
34	85
35	84
36	87
37	88
38	85
39	88
40	88
41	88
42	87
43	84
44	85
45	85
46	88
47	87
48	85
49	84
50	87
Vidurkis	86.4
Standartinis nuokrypis	1.949358869

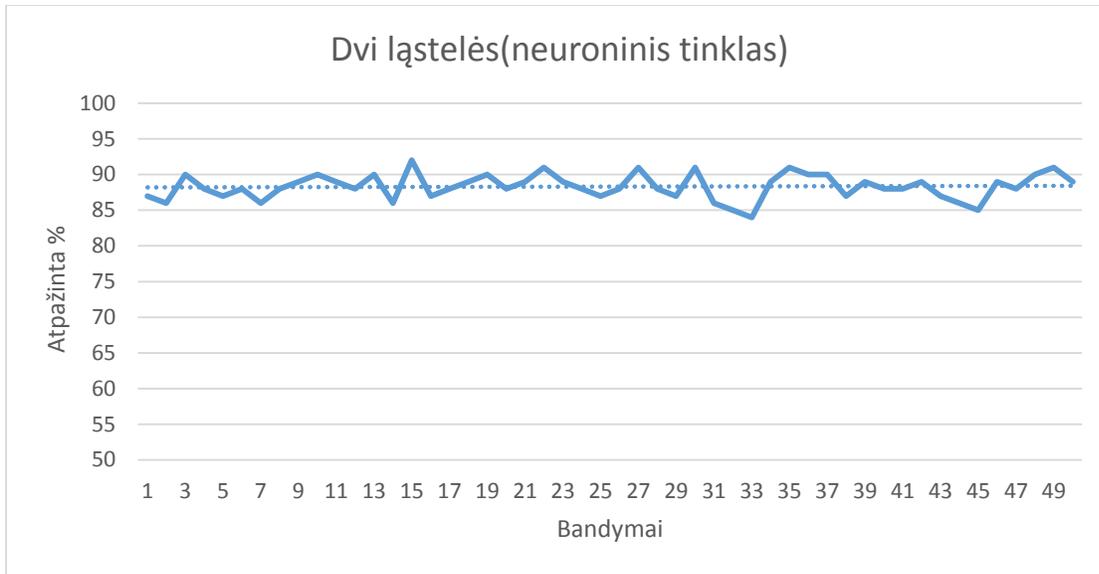


4.2 pav. Vienos ląstelės atpažinimo tikslumas naudojant K- artimiausio kaimyno algoritimą.

Lentelė 4.3 pav. Dviejų ląstelių atpažinimo tikslumas naudojant neuroninį tinklą.

Bandymas	Dvi ląstelės
1	87
2	86
3	90
4	88
5	87
6	88
7	86
8	88
9	89
10	90
11	89
12	88
13	90
14	86
15	92
16	87
17	88
18	89
19	90

20	88
21	89
22	91
23	89
24	88
25	87
26	88
27	91
28	88
29	87
30	91
31	86
32	85
33	84
34	89
35	91
36	90
37	90
38	87
39	89
40	88
41	88
42	89
43	87
44	86
45	85
46	89
47	88
48	90
49	91
50	89
Vidurkis	88.32
Standartinis nuokrypis	1.76

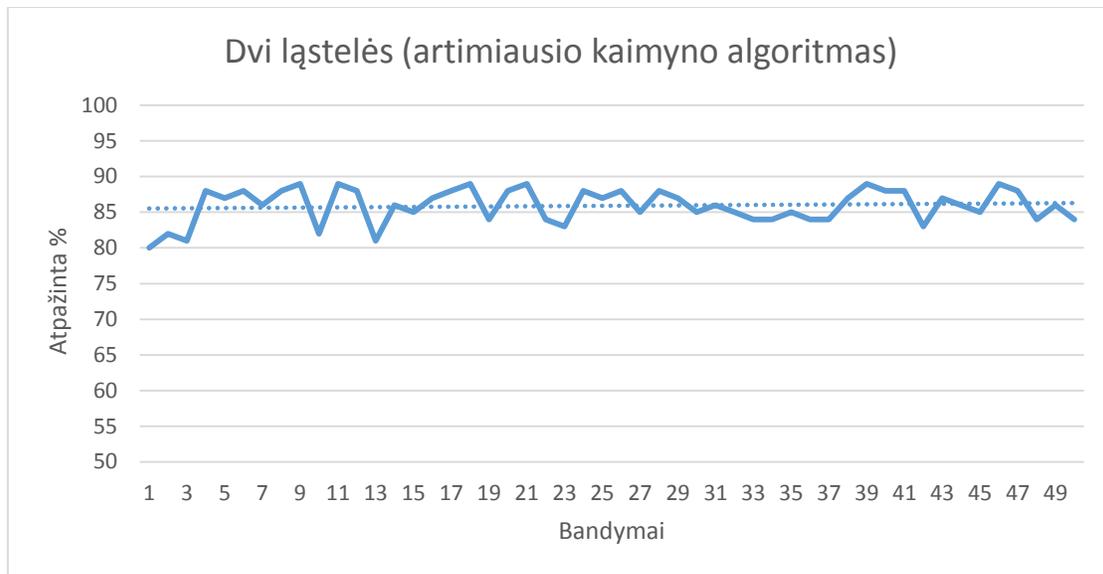


Paveiklis 1 Dviejų ląstelių bandymų skaičius ir atpažinimas naudojant neuroninį tinklą

Lentelė 4.4 pav. dviejų ląstelių atpažinimo tikslumas naudojant K-artimiausio kaimyno algoritmą..

Bandymas	Dvi ląstelės
1	80
2	82
3	81
4	88
5	87
6	88
7	86
8	88
9	89
10	82
11	89
12	88
13	81
14	86
15	85
16	87
17	88
18	89
19	84
20	88
21	89

22	84
23	83
24	88
25	87
26	88
27	85
28	88
29	87
30	85
31	86
32	85
33	84
34	84
35	85
36	84
37	84
38	87
39	89
40	88
41	88
42	83
43	87
44	86
45	85
46	89
47	88
48	84
49	86
50	84
Vidurkis	85.92
Standartinis nuokrypis	2.373520592

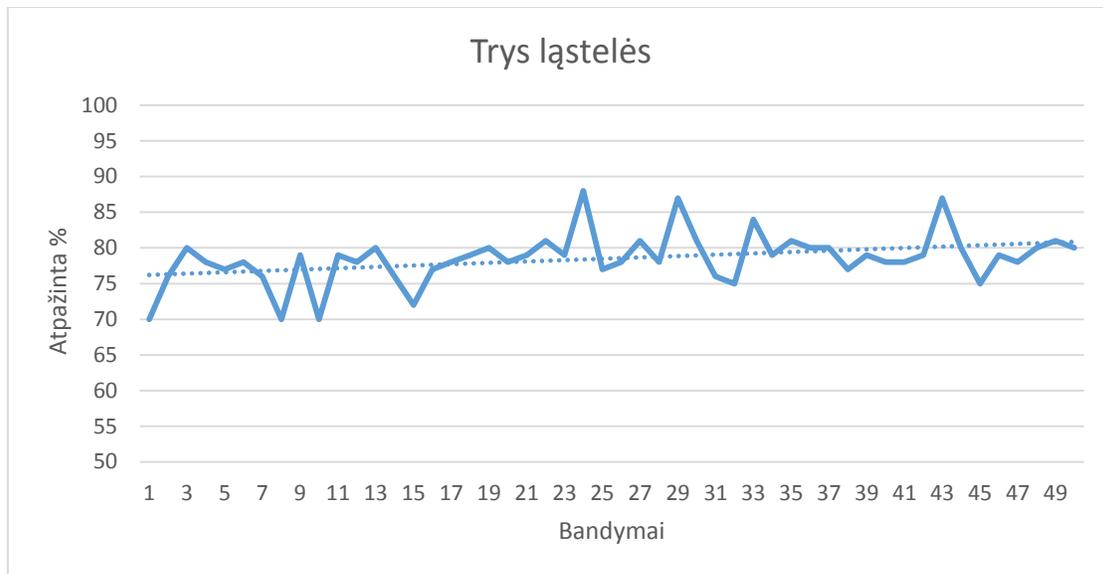


4.4 pav. Dviejų ląstelių atpažinimo tikslumas naudojant K-artimiausio kaimyno algoritmą.

Lentelė 4.5 pav. trijų ląstelių atpažinimo tikslumas naudojant neuroninį tinklą.

Bandymas	Trys ląstelės
1	70
2	76
3	80
4	78
5	77
6	78
7	76
8	70
9	79
10	70
11	79
12	78
13	80
14	76
15	72
16	77
17	78
18	79
19	80
20	78
21	79

22	81
23	79
24	88
25	77
26	78
27	81
28	78
29	87
30	81
31	76
32	75
33	84
34	79
35	81
36	80
37	80
38	77
39	79
40	78
41	78
42	79
43	87
44	80
45	75
46	79
47	78
48	80
49	81
50	80
Vidurkis	78.52
Standartinis nuokrypis	3.567856499

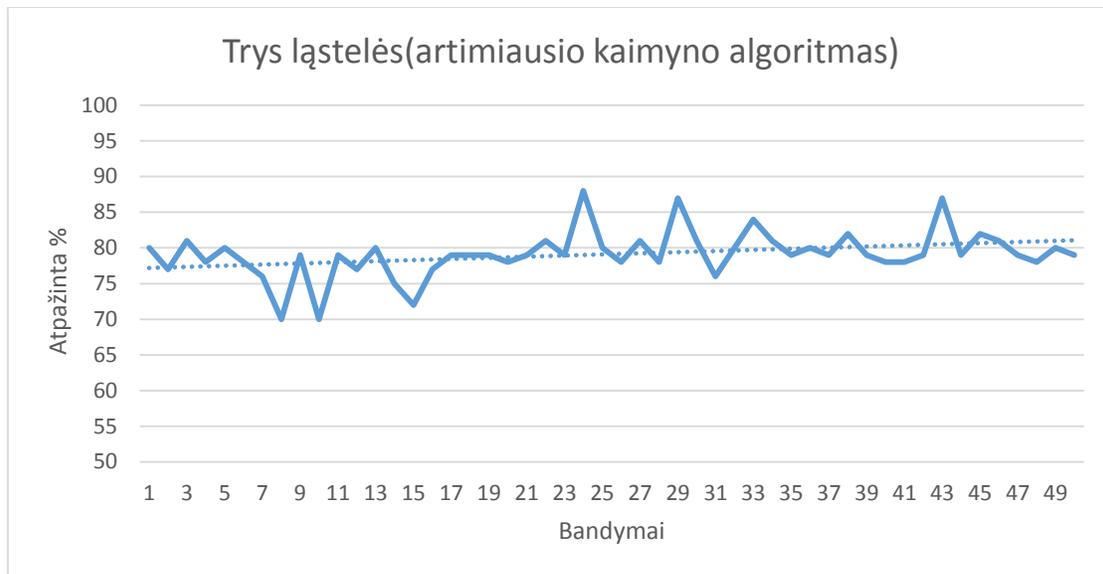


4.5 pav. trijų ląstelių atpažinimo tikslumas naudojant neuroninį tinklą.

Lentelė 4.6 lentelė. trijų ląstelių atpažinimo tikslumas naudojant K-artimiausio kaimyno algoritmą

Bandymas	Trys ląstelės
1	80
2	77
3	81
4	78
5	80
6	78
7	76
8	70
9	79
10	70
11	79
12	77
13	80
14	75
15	72
16	77
17	79
18	79
19	79

20	78
21	79
22	81
23	79
24	88
25	80
26	78
27	81
28	78
29	87
30	81
31	76
32	80
33	84
34	81
35	79
36	80
37	79
38	82
39	79
40	78
41	78
42	79
43	87
44	79
45	82
46	81
47	79
48	78
49	80
50	79
Vidurkis	79.12
Standartinis nuokrypis	3.308413517

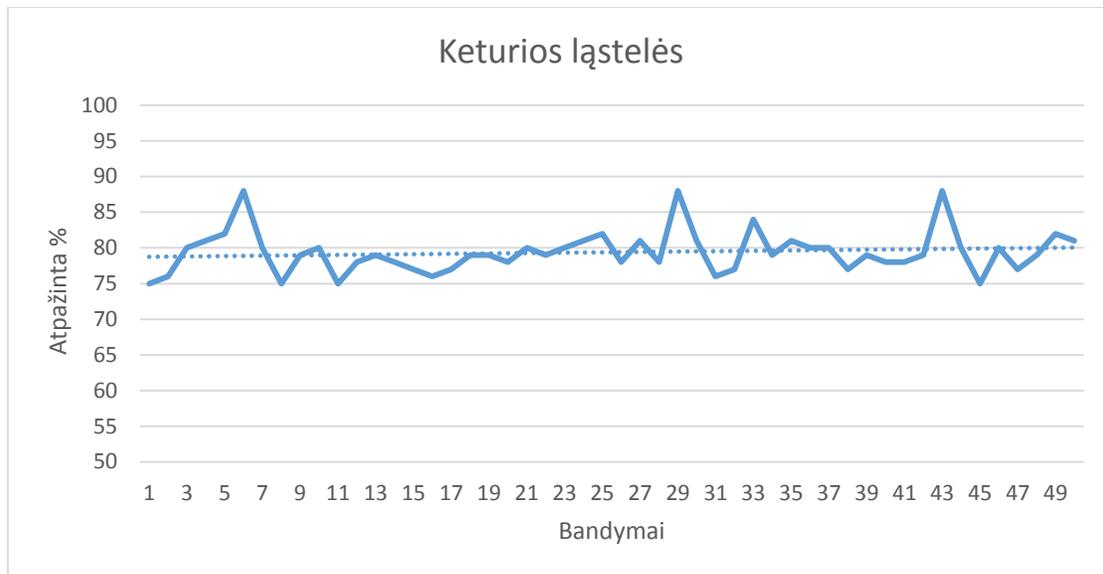


4.6 pav.. trijų ląstelių atpažinimo tikslumas naudojant K-artimiausio kaimyno algoritmą

4.7 lentelė. keturių ląstelių atpažinimo tikslumas naudojant neuroninį tinklą

Bandymas	Keturios ląstelės
1	75
2	76
3	80
4	81
5	82
6	88
7	80
8	75
9	79
10	80
11	75
12	78
13	79
14	78
15	77
16	76
17	77
18	79
19	79
20	78
21	80

22	79
23	80
24	81
25	82
26	78
27	81
28	78
29	88
30	81
31	76
32	77
33	84
34	79
35	81
36	80
37	80
38	77
39	79
40	78
41	78
42	79
43	88
44	80
45	75
46	80
47	77
48	79
49	82
50	81
Vidurkis	79.4
Standartinis nuokrypis	2.959729717

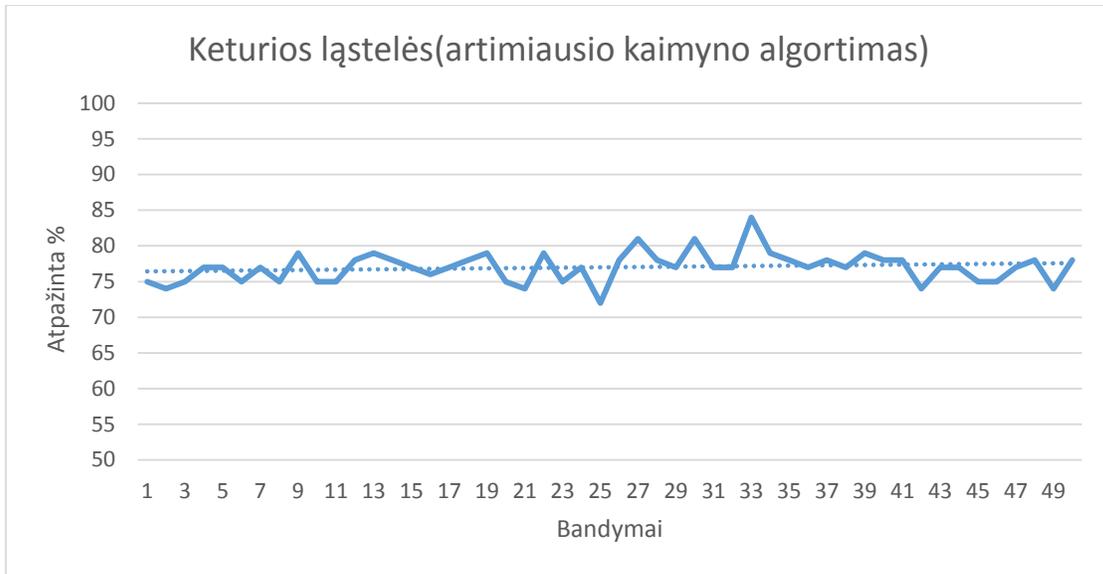


4.7.pav. keturių ląstelių bandymų skaičius ir atpažinimas naudojant neuroninį tinklą

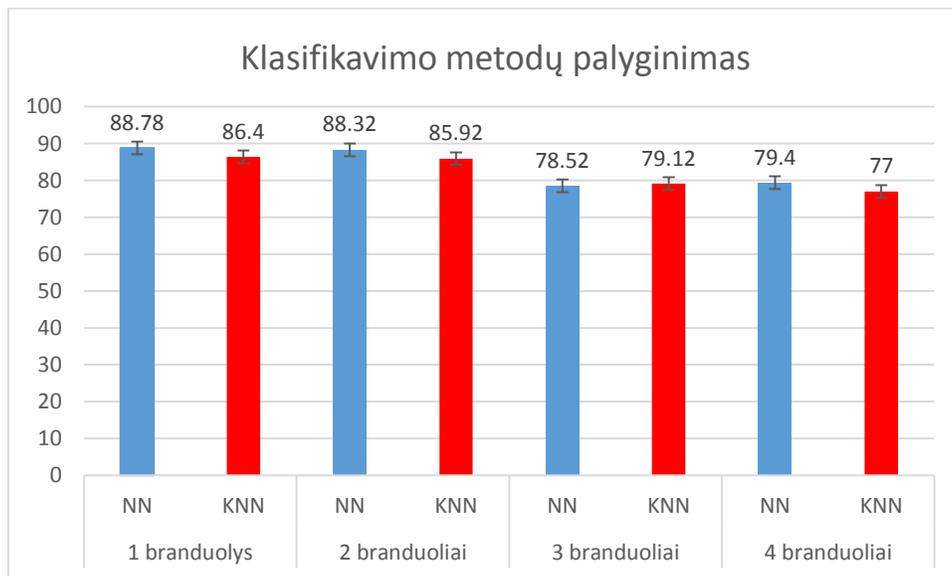
4.8 lentelė. keturių ląstelių atpažinimo tikslumas naudojant K- artimiausio kaimyno algoritmą

Bandymas	Keturios ląstelės
1	75
2	74
3	75
4	77
5	77
6	75
7	77
8	75
9	79
10	75
11	75
12	78
13	79
14	78
15	77
16	76
17	77
18	78
19	79
20	75
21	74

22	79
23	75
24	77
25	72
26	78
27	81
28	78
29	77
30	81
31	77
32	77
33	84
34	79
35	78
36	77
37	78
38	77
39	79
40	78
41	78
42	74
43	77
44	77
45	75
46	75
47	77
48	78
49	74
50	78
Vidurkis	77
Standartinis nuokrypis	2.088061302



4.8 pav. keturių ląstelių atpažinimo tikslumas naudojant K- artimiausio kaimyno algoritmą



Pav.4.9 Abiejų klasifikatorių atpažinimo tikslumo sulyginimas

Išvados.

1. Apžvelgta literatūra ir metodai embriono vystymosi kriterijams vertinti. Analizuojama tema vis dar nėra pakankamai gerai išnagrinėta. Temos aktualumą grindžia nevaisingų porų statistika. Esant tokiam dideliame kiekiui nevaisingų porų (kas aštunta pora turi vaisingumo problemų), šio metodo praktinis įgyvendinimas turėtų tiek praktinę tiek mokslinę vertę.
2. Pristatyti metodai, kurie panaudoti tyrimui. Bruožų išskyrimui taikomi statistiniai metodai :entropija, invariantiniai momentai, principinių komponenčių koeficientai. Klasifikavimui pasirinkti taikomi metodai : neuroninis tinklas, ir K-artimiausio kaimyno algoritmas.
3. Išnagrinėta bruožų įtaka klasifikavimo rezultatams.
Neuroninio tinklo geriausi rezultatai gauti naudojant entropijos reikšmę, 7is invariantinius momentus ir 15 principinių komponenčių koeficientų. Principinių komponenčių koeficientų kiekis įtakoja tyrimo rezultatą. Nuo neuronų skaičiaus taip pat priklausomas rezultatas. Esant 110 neuronų klasifikavimo rezultatai geriausi.
K-artimiausio kaimyno algoritmas geriausiai klasifikuoja duomenis naudojant entropijos reikšmę ir 7-is invariantinius momentus. Naudojant 13-a „kaimynų“ klasifikavimo rezultatai yra geriausi. Tiriant atstumo skaičiavimo algoritmus nustatyta kad tiek naudojant „Euclidean“ tiek „cityblock“ rezultatus gauname tokius pačius rezultatus. Naudojant klasifikavimo taisyklės „nearest“ ir „random“ gavom tokius pačius rezultatus. Bruožų įtakos tyrimas rezultatams buvo atliekamas naudojant 4-ą klasę. 4-a klasė pasirinkta, nes dėl branduolių persidengimo, klasifikavimo rezultatai prasčiausi.
4. Duomenų apdorojimo greitis taip pat skirtingas. Geresni rezultatai gauti naudojant K-artimiausio kaimyno algoritmą. Neuroninis tinklas kadra apdoroja per 0,094s , K-artimiausio kaimyno algoritmas per 0,03s
5. Neuroninio tinklo klasifikavimas gaunasi geriausias esant 23 įėjimams, ir 110 neuronų. Gauti stadijos atpažinimo rezultatai pirmos(vieno branduolio) klasės 88,78%, antros (dviejų branduolių)88,32 %, trečios(trijų branduolių) 78,52%, ketvirtos(keturių branduolių) 79,4%.

Naudojant Artimiausio kaimyno algoritmą su šiais nustatymais: atstumui skaičiuoti „euclidean“ metodas, klasifikavimo taisyklė „nearest“ ir kaimynų skaičius 13-a , gauti rezultatai :pirma klasė – 86,4%, antra klasė -85.92%, trečia klasė-79.12%, ketvirta klasė-77%.

6. Abu metodai pakankamai gerai suklasifikuoja duomenis. Neuroninio tinklo bendras atpažinimo vidurkis -83,75 %, standartinis nuokrypis- 2,54, K- artimiausio kaimyno algoritmo bendras atpažinimo vidurkis- 82,13%, standartinis nuokrypis - 2,395. Atpažinimo procentas yra geresnis neuroninio tinklo, tačiau Standartinis nuokrypis r šiek tiek prastesnis. K- artimiausio kaimyno algoritmas greičiau apdoroja duomenis vieną kadra -0,03s , kai neuroninis tinklas per 0,094s.

Naudota literatūra

1. http://www.maxhealthcare.in/newsletter/2010/january/ivf-simpler.html?utm_source=ivf-simpler&utm_medium=Facebook&utm_campaign=FB
2. D. Neubourg and J. Gerris, “Single embryo transfer—state of the art,” *Reproductive biomedicine online*, vol. 7, no. 6, pp. 615–622, 2003.
3. E. Wharf, A. Dimitrakopoulos, Y. Khalaf, and S. Pickering, “Early embryo development is an indicator of implantation potential,” *Reproductive biomedicine online*, vol. 8, no. 2, pp. 212–218, 2004.
4. B. Balaban, K. Yakin, B. Urman, A. Isiklar, and J. Tesarik, “Pronuclear morphology predicts embryo development and chromosome constitution,” *Reproductive BioMedicine Online*, vol. 8, no. 6, pp. 695–700, 2004.
5. A. Borini, C. Lagalla, M. Cattoli, E. Sereni, R. Sciajno, C. Flamigni, and G. Coticchio, “Predictive factors for embryo implantation potential,” *Reproductive biomedicine online*, vol. 10, no. 5, pp. 653–668, 2005.
6. L. Rienzi, F. Ubaldi, M. Iacobelli, S. Romano, M. G. Minasi, S. Ferrero, F. Sapienza, E. Baroni, and E. Greco, “Significance of morphological attributes of the early embryo,” *Reproductive BioMedicine Online*, vol. 10, no. 5, pp. 669–681, 2005.
7. Ikhsanul Habibie*, Anom Bowolaksono†, Robeth Rahmatullah*, Muhammad Nanda Kurniawan*, “Automatic Detection of Embryo Using Particle Swarm Optimization based Hough Transform”
8. D. A. Morales, E. Bengoetxea, and P. Larrañaga, “Selection of human embryos for transfer by bayesian classifiers,” *Computers in Biology and Medicine*, vol. 38, no. 11, pp. 1177–1186, 2008.
9. M. Meseguer, J. Herrero, A. Tejera, K. M. Hilligsøe, N. B. Ramsing, and J. Remohí, “The use of morphokinetics as a predictor of embryo implantation,” *Human reproduction*, vol. 26, no. 10, pp. 2658–2671, 2011.
10. S. Chamayou, P. Patrizio, G. Storaci, V. Tomaselli, C. Alecci, C. Ragolia, C. Crescenzo, and A. Guglielmino, “The use of morphokinetic parameters to select all embryos with full capacity to implant,” *Journal of assisted reproduction and genetics*, pp. 1–8, 2013.
11. <http://www.resolve.org/about/fast-facts-about-fertility.html?referrer=https://www.google.lt/2015/10/10/09:00>
12. <http://www.escoglobal.com/product/art-equipment/multi-room-incubator/MRI-6A10/2015/10/10/09:00>
13. <http://www.escoglobal.com/product/art-equipment/time-lapse-incubator/MRI-TL/2015/10/10/09:00>
14. P. Kultanen, L. Xu, and E. Oja, “Randomized hough transform (rht),” in *Pattern Recognition, 1990. Proceedings., 10th International Conference on*, vol. i, 1990, pp. 631–635 vol.1.
15. Manna, L. Nanni, A. Lumini, and S. Pappalardo, “Artificial intelligence techniques for embryo and oocyte classification,” *Reproductive biomedicine online*, 2012.
16. R. M. Jiang, D. Crookes, N. Luo, and M. W. Davidson, “Live-Cell Tracking Using SIFT Features in DIC Microscopic Videos,” *IEEE Transactions on Biomedical Engineering*, vol. 57, no. 9, pp. 2219–2228, September 2010.
17. F. Ning, D. Delhomme, Y. LeCun, F. Piano, L. Bottou, and P. E. Barbano, “Toward Automatic Phenotyping of Developing Embryos From Videos,” *IEEE Transactions on Image Processing*, vol. 14, no. 9, pp. 1360–1371, September 2005.

18. S. Sakuma, M. Kaneko, and F. Arai, "Ocian; on-chip impedance analyzer for measurement of cellular mechanical parameters," in *Micro-NanoMechatronics and HumanScience (MHS), 2012 International Symposium on*, 2012, pp. 384–386.
19. J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Neural Networks, 1995. Proceedings., IEEE International Conference on*, vol. 4, 1995, pp. 1942–1948.
20. Y. Xie and Q. Ji, "A new efficient ellipse detection method," in *Pattern Recognition, 2002. Proceedings. 16th International Conference on*, vol. 2. IEEE, 2002, pp. 957–960.
21. S. Osher and J. Sethian, "Fronts propagating with curvature-dependent speed: Algorithms based on Hamilton-Jacobi formulations," *J. Comput. Phys.*, vol. 79, no. 1, pp. 12–49, Nov. 1988.
22. Liu, J. G., Mason, P. J. (2009). *Essential image processing and GIS for remote sensing*. Wiley-Blackwell. UK.
23. Ripley, B. D. (1996). *Pattern Recognition and Neural Networks*. Cambridge university press.
24. <http://se.mathworks.com/help/images/ref/entropy.html/2015/10/10/09:00>
25. http://en.wikipedia.org/wiki/Image_moment/2015/10/10/09:00
26. M. K. Hu, "Visual Pattern Recognition by Moment Invariants", *IRE Trans. Info. Theory*, vol. IT-8, pp. 179–187, 1962
27. Aldrich, John (2006), "Eigenvalue, eigenfunction, eigenvector, and related terms", in Jeff Miller (Editor), *Earliest Known Uses of Some of the Words of Mathematics*, retrieved 2006-08-22
28. Dominic, S., Das, R., Whitley, D., Anderson, C. (July 1991). "Genetic reinforcement learning for neural networks". *IJCNN-91-Seattle International Joint Conference on Neural Networks*. *IJCNN-91-Seattle International Joint Conference on Neural Networks*. Seattle, Washington, USA: IEEE. doi:10.1109/IJCNN.1991.155315. ISBN 0-7803-0164-1. Retrieved 29 July 2012.

Priedai

Priedas nr. 1.

„Matlab“ kodas bruožų gavimui

```
clc
clear all
close all
n=50;
file_name='a (%d).jpg'
vienaent = [];
data = [];
mom1= [];
for i=1:n

    image=imread(sprintf(file_name,i));
    image = imresize(image,[60 60]);

    data=[data image(:)];
    J = entropy(image);
    vienaent = [vienaent J];

    entropijoj_vector(:, :, i)=J;
    % d=entropijoj_vector(:, :, i)
    xlformat1_vector(:, i)=entropijoj_vector(:, :, i);

    d(i)= xlformat1_vector(:, i);
    % d= xlformat1_vector(:, i)
    % [o data]=d(i)

    save ('vienaentropy.mat' , 'vienaent');
    %
    % load('entropy.mat')

    imgbw=im2bw(image);
    imgbw=logical(imgbw);

    temp_vect=huu_moment(imgbw);

    mom1 = [mom1 temp_vect];
    duomhu_moment_vector(:, :, i)=temp_vect;
    format long
    vienamom(:, i)=duomhu_moment_vector(:, :, i);
    save ('vienamoments.mat', 'vienamom');
    figure(1), imshow(imgbw, []);
end
%write the name of the excel file

[vienaomeg eig psi] = compcca2(double(data),15);
save vienaomega.mat vienaomeg;
```

Priedas Nr 2

Matlab funkcija invariantiniams momentams

```
function hu_moment = huu_moment ( image )

[x_bar,y_bar] = centroid_image(image);

mu_00 = sum(sum(image));
mu_11 = central_mm( image ,x_bar,y_bar,1,1);
mu_13 = central_mm( image ,x_bar,y_bar,1,3);
mu_20 = central_mm( image ,x_bar,y_bar,2,0);
mu_02 = central_mm( image ,x_bar,y_bar,0,2);
mu_21 = central_mm( image ,x_bar,y_bar,2,1);
mu_22 = central_mm( image ,x_bar,y_bar,2,2);
mu_12 = central_mm( image ,x_bar,y_bar,1,2);
mu_03 = central_mm( image ,x_bar,y_bar,0,3);
mu_30 = central_mm( image ,x_bar,y_bar,3,0);
mu_31 = central_mm( image ,x_bar,y_bar,3,1);
mu_40 = central_mm( image ,x_bar,y_bar,4,0);
mu_04 = central_mm( image ,x_bar,y_bar,0,4);

I1=(mu_20 * mu_02 - mu_11^2)/(mu_00)^4;
I2=(-(mu_30^2) * (mu_03^2) + 6*mu_30*mu_21*mu_12*mu_03 - 4*mu_30*
(mu_12)^3)/(mu_00)^10;
I3=(mu_20 * mu_21 * mu_03 - mu_20 * (mu_12)^2 - mu_11 * mu_30 * mu_03 +
mu_11 * mu_21 * mu_12 + mu_02 * mu_30 * mu_12 - mu_02 * (mu_21)^2)/(mu_00)^7;
I4=(-(mu_20)^3 * (mu_03)^2 + 6 * (mu_20)^2 * mu_11 * mu_12 * mu_03 - 3 *
(mu_20)^2 * mu_02 * (mu_12)^2 - 6 * mu_20 * (mu_11)^2 * mu_21 * mu_03 - 6 *
mu_20 * mu_11^2 * mu_12^2 + 12 * mu_20 * mu_11 * mu_02 * mu_21 * mu_12 - 3 *
mu_20 * mu_02^2 * mu_21^2 + 2 * mu_11^3 * mu_30 * mu_03 + 6 * mu_11^3 * mu_21
* mu_12 - 6 * mu_11^2 * mu_02 * mu_30 * mu_12 - 6 * mu_11^2 * mu_02 * mu_21^2 +
6 * mu_11 * mu_02^2 * mu_30 * mu_21 - 1 * mu_02^3 * mu_30^2)/(mu_00)^11;
I5=(1 * mu_40 * mu_04 - 4 * mu_31 * mu_13 + 3 * mu_22^2)/(mu_00)^6;
I6=(1 * mu_40 * mu_22 * mu_04 - 1 * mu_40 * mu_13^2 - 1 * mu_31^2 * mu_04 + 2 *
mu_31 * mu_22 * mu_13 - 1 * mu_22^3)/(mu_00)^9;
I7=(1 * mu_20^2 * mu_04 - 4 * mu_20 * mu_11 * mu_13 + 2 * mu_20 * mu_02 * mu_22
+ 4 * mu_11^2 * mu_22 - 4 * mu_11 * mu_02 * mu_31 + 1 * mu_02^2 * mu_40)/(
mu_00)^7;
hu_moment = [I1 I2 I3 I4 I5 I6 I7];

function cm = central_mm(image,x_bar,y_bar,p,q)

[row cul]=size(image);

cm=0;
for i=1:row
    for j=1:cul
        cm=cm+((i-1-x_bar)^p) * ((j-1-y_bar)^q) * (image(i,j));
    end
end
end
```

```

function [x_bar,y_bar]=centroid_image(image)

gm10=geomoment(image,1,0);
gm01=geomoment(image,0,1);
m00=sum(sum(image));

x_bar=(gm10)/m00;
y_bar=(gm01)/m00;

function gm = geomoment (image,p,q)
[row cul]=size(image);

gm=0;
for i=1:row%x axis
    for j=1:cul%y axis
        gm=gm+((i-1)^p) * ((j-1)^q) * (image(i,j));
    end
end
end

```

Priedas Nr 3

Matlab funkcija PCA koeficientams

```

function [Omega EigenVectors Psi]= compcca2(Data,NumberOfEigenVectors)

NumberOfData = size(Data,2);
Psi = mean(Data,2);
Theta = Data - repmat(Psi,1,NumberOfData);
[EigVect EigVal] = eig(Theta'*Theta);

for i = 1:NumberOfData
    EigenVectors(:,(NumberOfData + 1) - i) = Theta*EigVect(:,i);
end

EigenVectors = normc(EigenVectors);

Omega = zeros(NumberOfEigenVectors,NumberOfData);
for i = 1:NumberOfData
    Omega(:,i) = EigenVectors(:,1:NumberOfEigenVectors) '*Theta(:,i);
end

End

```

Priedas nr 4

Matlab kodas klasifikuoti duomenims naudojant neuroninius tinklus

```

clc
clear all
close all
load('dvientropy.mat')
load('dvimoments.mat')
load('dviomega.mat')
load('keturiosentropy.mat')
load('keturios_moments.mat')
load('keturiosomega.mat')
load('trysentropy.mat')
load('trysmoments.mat')
load('trysomega.mat')
load('vienaentropy.mat')
load('vienamoments.mat')
load('vienaomega.mat')

T=[ ones(1,length(vienaent)),          zeros(1,length(dvient) +
length(trysent) + length(keturios_entrop))
      zeros(1,length(vienaent)),          ones(1,length(dvient)),
      zeros(1,length(trysent)+length(keturios_entrop));
      zeros(1,length(vienaent)+length(dvient)),          ones(1,length(trysent)),
      zeros(1,length(keturios_entrop));
      zeros(1,length(vienaent)+length(dvient)+length(trysent)),
      ones(1,length(keturios_entrop)) ]];

T_=[ones(1,length(vienaent))*10, ones(1,length(dvient))*20,
ones(1,length(trysent))*30 ones(1,length(keturios_entrop))*40]';

T_viena=[vienaent; vienamom;vienaomeg];
T_dvi=[dvient;dvimoment;dviomeg] ;
T_trys=[trysent;trysmoment;trysomeg];
T_keturios=[keturios_entrop;moment_keturios;keturiosomeg];

Vec = [T_viena, T_dvi, T_trys, T_keturios];

% fazis=[Vec, T];
% Vec_frag_yeas = [ent1;momfrag;omeg];
% Vec_frag_non = [duoment1;duommomfrag;omeg1];

net = newff(Vec,T,110);
net.trainParam.epochs = 1000;
net.trainParam.goal = 0.001;
net=train(net,Vec,T);
out=sim(net,Vec);

```

```

plot(T, 'b.-');

hold on
figure(1)
plot(T(1,:), 'b.-');
hold on
plot(out(1,:), 'r.-')%pirmas isejims
figure(2)
plot(T(2,:), 'b.-');
hold on
plot(out(2,:), 'g.-')%pirmas isejims
figure(3)
plot(T(3,:), 'b.-');
hold on
plot(out(3,:), 'k.-')%pirmas isejims
figure(4)
plot(T(4,:), 'b.-');
hold on
plot(out(4,:), 'm.-')%pirmas isejims
save lasteles.mat net

```

Priedas nr 5

Matlab kodas KNN klasifikatoriui

```

clc
clear all
close all
load('dvientropy.mat')
load('dvimoments.mat')
load('dviomega.mat')
load('keturiosentropy.mat')
load('keturios_moments.mat')
load('keturiosomega.mat')
load('trysentropy.mat')
load('trysmoments.mat')
load('trysomega.mat')
load('vienaentropy.mat')
load('vienamoments.mat')
load('vienaomega.mat')
load('vienaentropy.mat')
load('dvitestentropy.mat')
load('trysyentropys.mat')
load('ketvienaentropy.mat')

```

```
T=[ ones(1,length(vienaent)), ones(1,length(dvient))*2,
ones(1,length(trysent))*3, ones(1,length(keturios_entrop))*4];
```

```
ClassNames={'T_viena' 'T_dvi' 'T_trys' 'T_keturios'};
```

```
Vec = [vienaent, dvient, trysent, keturios_entrop];
dist
```

```
out = knnclassify(ketvienaent',Vec',T');
```

Priedas Nr 6

Matlab kodas testavimui

```
clc
clear all
close all
load lasteles.mat
n=50;
file_name='a (%d).jpg';
% hu_moment_vector=zeros([7 1 n]);
% xlformat_vector=zeros(7,n);
vienaenttest = [];
data = [];
mom1= [];
for i=1:n

    image=imread(sprintf(file_name,i));
    image = imresize(image,[60 60]);

    data=[data image(:)];
    J = entropy(image);
    vienaenttest = [vienaenttest J];

    entropijoj_vector(:, :, i)=J;
    %     d=entropijoj_vector(:, :, i)
    xlformat1_vector(:, i)=entropijoj_vector(:, :, i);

    d(i)= xlformat1_vector(:, i);

    save ('vienaentropy.mat' , 'vienaenttest');
    %
    %     load('entropy.mat')
```

```

imgbw=im2bw(image);
imgbw=logical(imgbw);

temp_vect=affine_moment(imgbw);

mom1 = [mom1 temp_vect];
duomhu_moment_vector(:, :, i)=temp_vect;
format long
vienamom(:, i)=duomhu_moment_vector(:, :, i);
save ('vienamoments.mat', 'vienamom');
figure(1), imshow(imgbw, []);

)
end

[vienaomeg eig psi] = compcca2(double(data),15);

save vienaomega.mat vienaomeg;

tvec=[vienaenttest; vienamom; vienaomeg];
testVec = [tvec];

out= sim(net, testVec);
level = 0.55;
Names = 'images';
arr = [];
for j=1:length(level)

    count = 0;
    ok_ = 0;
    for i=1:size(out,1)
        [maxvalue klase]=max(out(:,i));
        if maxvalue>level(j) && klase == 1;
            embrio=klase;
            ok_ = ok_+1
        else
            embrio = 0;
        end;
        count = count + 1;
    end
    arr = [arr (ok_/count)*100]
end
figure(1)
plot(level, arr, 'b.-')
figure(2)
plot(ok_, arr, 'b.-')

```

Bruožai (entropija)

Kadras	Viena ląstelė	Dvi ląstelės	Trys ląstelės	Keturios ląstelės
1	7.685050172105294	7.563200427936030	7.582432360381941	7.672834135017689
2	7.685050172105294	7.563200427936030	7.575049211949569	7.623732279971059
3	7.672314299589511	7.539523904369442	7.503832598987189	7.684115410846588
4	7.672314299589511	7.539523904369442	7.638771089713060	7.697074310612736
5	7.699094017345568	7.566994587238206	7.663029874526347	7.596680763123553
6	7.699094017345568	7.566994587238206	7.548782702555476	7.578978271440292
7	7.655071192825310	7.665807927089679	7.513197101033398	7.550957070556517
8	7.655071192825310	7.665807927089679	7.563786456536921	7.669080354903570
9	7.633521539116429	7.615394393040828	7.551239942723499	7.684085310237561
10	7.633521539116429	7.615394393040828	7.600119422944531	7.677259717792269
11	7.369429598696461	7.668408794575383	7.578739751586712	7.673146375948694
12	7.369429598696461	7.668408794575383	7.578978303487854	7.675643429164131
13	7.611411812156611	7.602128419765336	7.547092209285952	7.686607776354506
14	7.611411812156611	7.602128419765336	7.460397197046564	7.691409840567980
15	7.652980802090548	7.731539239426971	7.527185548881563	7.708216041033588
16	7.652980802090548	7.711002179609769	7.533393313215320	7.687189160531631
17	7.694993883866430	7.711002179609769	7.517487909829926	7.687376782705860
18	7.69499388386643	7.731539239426971	7.623267564524629	7.703030801319670
19	7.650679458753734	7.686374097033717	7.608568860532643	7.677941999283087
20	7.650679458753734	7.686374097033717	7.655482265592397	7.683625956032511
21	7.681658437129997	7.544402158445514	7.629704341647670	7.694602921287533
22	7.681658437129997	7.544402158445514	7.558600621406736	7.669003230563300
23	7.548230987702612	7.448255764409487	7.542836703765763	7.682937391309276
24	7.548230987702612	7.448255764409487	7.433125197675149	7.669796820835764
25	7.529739488384165	7.565602711579919	7.510087222195267	7.667988342588434
26	7.529739488384165	7.565602711579919	7.597818283091851	7.691575918276245
27	7.486953363681149	7.559208510700214	7.500463361996381	7.682324249502254
28	7.486953363681149	7.559208510700214	7.560949832224587	7.687253252670543
29	7.592554164632293	7.598989155471652	7.597370442342981	7.666289556934075
30	7.592554164632293	7.598989155471652	7.571484318720741	7.690727127227904
31	7.533612382001754	7.570058240879003	7.581051169251796	7.682289111729482
32	7.533612382001754	7.570058240879003	7.595660227308225	7.703406059141638
33	7.545395587647866	7.518941879001818	7.623119290192808	7.705657599318456
34	7.545395587647866	7.518941879001818	7.675614529673035	7.689887001768977
35	7.619869843464781	7.561683501313461	7.658025624259084	7.669900861498869
36	7.619869843464781	7.561683501313461	7.560227118274854	7.697106396781483
37	7.490422621530051	7.562346324085319	7.527408514359784	7.669905007228698
38	7.490422621530051	7.562346324085319	7.590256191528821	7.688400419609683
39	7.405347007644012	7.588235269398390	7.699742523212301	7.693140465102771
40	7.405347007644012	7.588235269398390	7.332244423605521	7.681689955349531

41	7.533775322850739	7.542237843452825	7.539658293321976	7.685131836230097
42	7.533775322850739	7.542237843452825	7.645823721367390	7.695549069209875
43	7.615325067269112	7.598898567731071	7.494915077521965	7.685477429850032
44	7.615325067269112	7.598898567731071	7.562450277622181	7.690523554374677
45	7.622132076285986	7.452258047999456	7.439367697815369	7.700649498436677
46	7.622132076285986	7.452258047999456	7.527800611900086	7.700367335039472
47	7.710750502299613	7.554362290857089	7.614975267900127	7.680245964280760
48	7.7107505022996	7.554362290857089	7.340641912445120	7.692432341711469
49	7.702802645842479	7.535894229779261	7.670418834350567	7.696372465833012
50	7.702802645842479	7.535894229779261	7.720981170707521	7.673157914738246

Priedas nr 8

Bruožai (momentai)

Kadras	1 laštelė	2 laštelės	3 laštelės	4 laštelės
1	0.011809285952778	0.715789580830763	0.541892700503943	0.017508635885359
	-0.000000000004348	0.000065939651944	-0.000066922196473	-0.000000000004552
	-0.000000135158625	-0.007322968793837	-0.004684607951774	0.000000366135545
	-0.000000008450029	-0.011021435750441	-0.029380757248270	-0.000000065971995
	0.000842706502081	2.082254229279224	1.390216515885090	0.001693328230776
	0.000003380613805	0.518683805916161	0.266048550801067	0.000009361741859
	0.000765830073433	2.358928475400965	1.449300937135317	0.001605519861746
2	0.011809285952778	0.715789580830763	0.498380827841830	0.627777856786567
	-0.000000000004348	0.000065939651944	-0.000076604641878	-0.001279291812172
	-0.000000135158625	-0.007322968793837	0.001953769197919	0.002663743396875
	-0.000000008450029	-0.011021435750441	-0.042091795469229	-0.050275933568072
	0.000842706502081	2.082254229279224	1.262763934032163	1.986631941279850
	0.000003380613805	0.518683805916161	0.236951727889957	0.401795113191295
	0.000765830073433	2.358928475400965	1.275578386157658	1.990133521011410
3	0.011852586275146	0.824234877079750	0.015761024578770	0.018219803954986
	-0.000000000010170	-0.000094702340326	-0.000000001009902	-0.000000000011993
	-0.000000127670282	-0.028631579042973	0.000003352260633	0.000000415967128
	-0.000000009201177	-0.132361287862244	-0.000000357691797	-0.000000057851651
	0.000837741714061	3.292185317940228	0.001492807494927	0.001843897234669
	0.000003335676158	0.949345451466997	0.000008012754072	0.000010596526875
	0.000766046471717	3.387481847877463	0.001362710085144	0.001742811083265
4	0.011852586275146	0.824234877079750	0.016517815226692	0.018877895873516
	-0.000000000010170	-0.000094702340326	0.00000000001462	-0.000000000083408
	-0.000000127670282	-0.028631579042973	0.000000221912964	-0.000000112901862
	-0.000000009201177	-0.132361287862244	-0.000000027936024	-0.000000048162932
	0.000837741714061	3.292185317940228	0.001492883914191	0.002018286168929
	0.000003335676158	0.949345451466997	0.000007784716513	0.000011901000068
	0.000766046471717	3.387481847877463	0.001422893370921	0.001886257202126
5	0.011902236299330	1.047253220596533	0.016882348909797	0.742944767969930
	0.000000000002038	0.001535196310304	0.000000000001113	-0.000529302124458
	0.000000030580648	-0.059744953141123	-0.000000145226731	0.005764521910379

	-0.000000010431468 0.000868450188919 0.000003530354809 0.000783462071787	-0.195844597317649 4.449055839835151 1.638975354045478 5.050103958743539	-0.000000005375542 0.001577755801432 0.000008404559577 0.001494382824752	-0.040607588870470 2.336715431137721 0.646660861094120 2.606602863736336
6	0.011902236299330 0.000000000002038 0.000000030580648 -0.000000010431468 0.000868450188919 0.000003530354809 0.000783462071787	1.047253220596533 0.001535196310304 -0.059744953141123 -0.195844597317649 4.449055839835151 1.638975354045478 5.050103958743539	0.738069521368109 -0.000848151048581 0.009808206738151 -0.092314512264840 2.613644910490540 0.706208436541494 2.716143729041522	0.761810288123128 0.000050191184781 -0.007904333941625 -0.013653859863284 2.389319275395741 0.622813705993259 2.681608101208411
7	0.011967816179323 -0.000000000004468 -0.000000210969369 -0.000000014423799 0.000842303921501 0.000003463020253 0.000777629584514	0.036048137760676 -0.000000018941604 0.000010473078258 -0.000003251598358 0.007482266792523 0.000082814083030 0.006930058834136	0.829018858621664 -0.006393154562545 -0.054004745269176 -0.156204657550485 3.265117843711622 0.923752918812653 3.392624756590505	0.436831000076246 -0.000561042741446 -0.006371629221403 -0.017476944907707 0.889289597050357 0.140076890276540 0.937219556091203
8	0.011967816179323 -0.000000000004468 -0.000000210969369 -0.000000014423799 0.000842303921501 0.000003463020253 0.000777629584514	0.036048137760676 -0.000000018941604 0.000010473078258 -0.000003251598358 0.007482266792523 0.000082814083030 0.006930058834136	0.748030689744988 -0.001154004349458 -0.019897884634065 -0.069252421673373 2.606943701472056 0.666949192734026 2.735886393629357	0.016991502227457 -0.00000000010031 0.000000268279777 -0.000000035075533 0.001588038337636 0.000008535594652 0.001509443675846
9	0.011610812803842 0.000000000000337 -0.000000128139514 -0.000000004258740 0.000757747526660 0.000002997862956 0.000716587440456	0.012921593737148 -0.000000000000312 0.000000005227437 -0.000000008063465 0.000998136122331 0.000004280523731 0.000910669479880	0.570338052359485 -0.000263933968603 -0.009137699370925 -0.031809119139758 1.502037071183368 0.302631149212260 1.589076364955273	0.017804319787362 0.000000000000013 0.000000005397983 -0.000000004328483 0.001709419817315 0.000009529654480 0.001640942372882
10	0.011610812803842 0.000000000000337 -0.000000128139514 -0.000000004258740 0.000757747526660 0.000002997862956 0.000716587440456	0.012921593737148 -0.000000000000312 0.000000005227437 -0.000000008063465 0.000998136122331 0.000004280523731 0.000910669479880	0.768843486284241 -0.001232893720506 -0.011345621529269 -0.053069059130237 2.761774535708577 0.683716802191635 2.881712246336336	0.016471584829626 -0.000000000023842 0.000000663394097 -0.00000066754384 0.001493617645509 0.000007801881734 0.001419279147229
11	0.008861145394483 0.000000000056964 -0.000000953745826 -0.000000026610658 0.000472421956640 0.000001575072729 0.000434460273271	0.013188620424661 0.000000000000380 -0.000000079443861 -0.000000002113441 0.001039381883336 0.000004500563092 0.000947552773352	0.670355190494087 -0.000478347168043 -0.037279549752287 -0.061183022401389 2.026134625951805 0.454570701640386 2.160746862801019	0.016792818684176 -0.00000000001062 -0.000000086937211 -0.000000011252715 0.001546465864425 0.000008131434568 0.001471061228432
	0.008861145394483	0.013188620424661	0.721920150255547	0.016023275837310

12	0.00000000056964 -0.000000953745826 -0.000000026610658 0.000472421956640 0.000001575072729 0.000434460273271	0.00000000000380 -0.000000079443861 -0.000000002113441 0.001039381883336 0.000004500563092 0.000947552773352	-0.000825802085796 -0.013092890792546 -0.041034596537982 2.419133920180517 0.537224957910426 2.516588817298634	-0.00000000002845 0.000000143288150 -0.000000022411448 0.001414886860029 0.000007227634747 0.001344304538787
13	0.033533908958805 -0.000000000014888 0.000001881314397 -0.000000425970260 0.005764652798292 0.000055044985504 0.005642423385666	0.012766621712786 -0.000000000000059 0.000000187672532 -0.000000014703056 0.000989601888942 0.000004155074020 0.000894660159857	0.517766710810814 -0.001190958058746 -0.007139240059844 -0.045924796734533 1.344635154491851 0.264093821310827 1.368781049845659	0.017561644513170 -0.000000000014957 -0.000000070707069 -0.000000023588102 0.001708528035644 0.00009397271377 0.001616246995199
14	0.033533908958805 -0.000000000014888 0.000001881314397 -0.000000425970260 0.005764652798292 0.000055044985504 0.005642423385666	0.012766621712786 -0.000000000000059 0.000000187672532 -0.000000014703056 0.000989601888942 0.000004155074020 0.000894660159857	0.563016100178967 -0.001998949053314 -0.037988808085330 -0.075417408422186 1.526184640070571 0.329377223761934 1.590571394438699	0.017723651205032 -0.000000000003737 0.000000470857102 -0.000000084225345 0.001765616142843 0.00009883346484 0.001658502291626
15	0.030807292185793 0.000000000003574 0.000000448464888 -0.000000137249958 0.004963089240462 0.000044759421151 0.004817127369038	0.013777401070152 -0.000000000010823 -0.000000025366031 -0.000000014297296 0.001148517355071 0.000005312409955 0.001041902465416	0.526833141803954 -0.000345193447936 -0.021682886962468 -0.030992901299287 1.242701410235964 0.243153446330334 1.342999518630088	0.017164528235205 -0.000000000004124 -0.000000076302574 -0.000000022562731 0.001650198474184 0.000008970730166 0.001553211446553
16	0.030807292185793 0.000000000003574 0.000000448464888 -0.000000137249958 0.004963089240462 0.000044759421151 0.004817127369038	0.013777401070152 -0.000000000010823 -0.000000025366031 -0.000000014297296 0.001148517355071 0.000005312409955 0.001041902465416	0.554173144092660 -0.002071207959426 -0.013618274901489 -0.051701823971749 1.484000791814413 0.294472234078678 1.532414372478852	0.017729983160517 -0.000000000039424 0.000000662965558 -0.000000079099658 0.001738937342232 0.000009726310540 0.001647373403124
17	0.037377508350382 -0.000000010660149 -0.000005129470223 -0.000001953148010 0.007343353785911 0.000083177920119 0.007130448638808	0.013850236647243 -0.000000000017411 0.000000124045721 -0.000000028507362 0.001183079333468 0.000005401336223 0.001060608163058	0.018974269271496 -0.000000006510813 0.000005637033682 -0.000000691530192 0.002117187343936 0.000012767204388 0.001945248855304	0.018108588048509 -0.000000000142218 0.000001162493895 -0.000000130636850 0.001853051476078 0.000010485860668 0.001733919954618
18	0.037377508350382 -0.000000010660149 -0.000005129470223 -0.000001953148010 0.007343353785911 0.000083177920119	0.013850236647243 -0.000000000017411 0.000000124045721 -0.000000028507362 0.001183079333468 0.000005401336223	0.023260825958168 -0.000000003307254 0.000005420232211 -0.000000812092546 0.003107511017844 0.000022817118813	0.019095311426178 -0.000000000125906 0.000000606334143 -0.000000096490828 0.002086057726650 0.000012521376816

	0.007130448638808	0.001060608163058	0.002891473628688	0.001940083496735
19	0.016958016429188 0.000000000003934 -0.000000310967546 -0.000000015014235 0.001640351514018 0.000008786451870 0.001528973499202	0.013590001776468 -0.000000000001971 0.000000223346184 -0.000000028348656 0.001158155964698 0.000005268990365 0.001030418877555	0.020899198707629 -0.000000005279075 0.000006661734471 -0.000000910867620 0.002553448496743 0.000016966503600 0.002353990575727	0.017550255907582 -0.00000000000245 0.000000021469200 -0.000000003358994 0.001677074349022 0.000009252145524 0.001602193679342
20	0.016958016429188 0.000000000003934 -0.000000310967546 -0.000000015014235 0.001640351514018 0.000008786451870 0.001528973499202	0.013590001776468 -0.000000000001971 0.000000223346184 -0.000000028348656 0.001158155964698 0.000005268990365 0.001030418877555	0.023250365285798 -0.000000004049138 0.000006652577617 -0.000000971671787 0.003138202162709 0.000022877507213 0.002898539107988	0.017707173467386 -0.000000000070585 0.000000636737672 -0.000000073974828 0.001749850025413 0.000009744322044 0.001649240248994
21	0.015608128026450 0.000000000000980 -0.000000157139612 -0.000000008510364 0.001417184506717 0.000006807637688 0.001303543482835	0.012491280382294 -0.000000000000694 0.000000030940222 -0.000000003214975 0.000894374916263 0.000003626880174 0.000833091124648	0.021275832368448 -0.000000003269519 0.000004658122504 -0.000000726464618 0.002619189531590 0.000017218681150 0.002420655347289	0.018910976828801 -0.00000000017758 0.000000576190012 -0.000000084079079 0.001992306581592 0.000011869087899 0.001879872216650
22	0.015608128026450 0.000000000000980 -0.000000157139612 -0.000000008510364 0.001417184506717 0.000006807637688 0.001303543482835	0.012491280382294 -0.000000000000694 0.000000030940222 -0.000000003214975 0.000894374916263 0.000003626880174 0.000833091124648	0.019219472858802 -0.000000002593497 0.000005544226464 -0.000000733033650 0.002202482461322 0.000013776875482 0.002012969188031	0.018045047562792 -0.00000000019241 0.000000150898199 -0.000000024032415 0.001812539751275 0.000010328957304 0.001711881067628
23	0.014728647787400 -0.000000000019433 0.000000244533597 -0.000000022494574 0.001186619988392 0.000005604405372 0.001132868851267	0.011777083506162 -0.000000000004610 0.000000103589167 -0.000000008959870 0.000788790691825 0.000003059632119 0.000738877539452	0.018546105298250 -0.000000004942894 0.000004217536895 -0.000000604932614 0.002001264753165 0.000012049352696 0.001852086715949	0.018230194191294 -0.00000000001052 0.000000219001484 -0.000000037340715 0.001823761472243 0.000010403674782 0.001734066565894
24	0.014728647787400 -0.000000000019433 0.000000244533597 -0.000000022494574 0.001186619988392 0.000005604405372 0.001132868851267	0.011777083506162 -0.000000000004610 0.000000103589167 -0.000000008959870 0.000788790691825 0.000003059632119 0.000738877539452	0.015569676473707 -0.000000002736295 0.000004811579849 -0.000000482453599 0.001494339263845 0.000007975602541 0.001347253030843	0.017122912376245 -0.000000000006104 0.000000182797094 -0.000000025415903 0.001591514919920 0.000008565425675 0.001522875856638
25	0.012815934262622 -0.000000000037448 0.000000251496415 -0.000000022314846	0.012476096843714 0.000000000000040 0.000000025071883 -0.000000002112788	0.017817436821298 -0.000000003888976 0.000004952100459 -0.000000583684632	0.016993435985189 -0.000000000020219 0.000000234620795 -0.000000031301893

	0.000975523535397 0.000004117002757 0.000892781548927	0.000892137267740 0.000003611397456 0.000830966390794	0.001885319953513 0.000011116718131 0.001729478001971	0.001571557689324 0.000008438267556 0.001502210227780
26	0.012815934262622 -0.000000000037448 0.000000251496415 -0.000000022314846 0.000975523535397 0.000004117002757 0.000892781548927	0.012476096843714 0.000000000000040 0.000000025071883 -0.000000002112788 0.000892137267740 0.000003611397456 0.000830966390794	0.020334116384696 -0.000000004237096 0.000005761074720 -0.000000737986685 0.002410137763797 0.000015595549783 0.002224003067049	0.018862339987587 -0.000000000005857 -0.000000014576191 -0.000000029918725 0.001961540632801 0.000011465642143 0.001858647329032
27	0.011609257148526 -0.000000000016288 0.000000159722781 -0.000000012968999 0.000790109678179 0.000003054103566 0.000728928245175	0.012251887878974 -0.000000000000219 0.000000035060227 -0.000000002577863 0.000857918866269 0.000003425331037 0.000800634964818	0.017154631030929 -0.000000002301908 0.000005000119654 -0.000000562702042 0.001754082874389 0.000010099095037 0.001608543538407	0.017165566435652 -0.00000000022360 0.000000392345093 -0.000000046227299 0.001609179093208 0.000008701233057 0.001534792841562
28	0.011609257148526 -0.000000000016288 0.000000159722781 -0.000000012968999 0.000790109678179 0.000003054103566 0.000728928245175	0.012251887878974 -0.000000000000219 0.000000035060227 -0.000000002577863 0.000857918866269 0.000003425331037 0.000800634964818	0.018853347323058 -0.000000005276028 0.000005409472142 -0.000000695947612 0.002093454518326 0.000012704260028 0.001923495784392	0.017823151793168 -0.00000000062438 0.000000859793113 -0.000000104187630 0.001767365844343 0.000009973106934 0.001669542244836
29	0.014475626666377 -0.000000000032777 0.000000433022717 -0.000000037970710 0.001205832835320 0.000006065948207 0.001128225745666	0.013348194863252 -0.000000000001694 0.000000125478983 -0.000000010862560 0.001013348594271 0.000004384197156 0.000947926242144	0.020497843040626 -0.000000006789533 0.000007558669593 -0.000001265151549 0.002594146585111 0.000018140139838 0.002335800450516	0.017983592793426 -0.000000000001179 -0.000000081771802 -0.00000008478227 0.001756854428049 0.000009862172091 0.001679354919052
30	0.014475626666377 -0.000000000032777 0.000000433022717 -0.000000037970710 0.001205832835320 0.000006065948207 0.001128225745666	0.013348194863252 -0.000000000001694 0.000000125478983 -0.000000010862560 0.001013348594271 0.000004384197156 0.000947926242144	0.018574799185025 -0.000000005802746 0.000007601718529 -0.000001009995355 0.002150771647729 0.000013865161069 0.001929916244264	0.017126226137892 -0.000000000019356 0.000000240680635 -0.000000029186745 0.001602066566722 0.000008720259629 0.001529302342418
31	0.012579445079322 -0.000000000008331 0.000000082071459 -0.000000013723136 0.000907858079834 0.000003722286752 0.000845618448515	0.013078306021625 0.000000000000000 -0.000000000147230 -0.000000000031656 0.000953556342569 0.000004039102638 0.000901588539017	0.019846003399617 -0.000000005716244 0.000007492034311 -0.000000981186092 0.002374241854378 0.000015622702460 0.002160008560594	0.018449931223668 0.000000000000154 0.000000013677450 -0.000000013298330 0.001862272950151 0.000010765407054 0.001773674809319
	0.012579445079322 -0.000000000008331	0.013078306021625 0.000000000000000	0.020349944768562 -0.000000001525062	0.018626916613783 -0.000000000036866

32	0.000000082071459 -0.000000013723136 0.000907858079834 0.000003722286752 0.000845618448515	-0.000000000147230 -0.000000000031656 0.000953556342569 0.000004039102638 0.000901588539017	0.000006306224906 -0.000001129466395 0.002547118704080 0.000017532389513 0.002296357484668	0.000000670808304 -0.000000085439257 0.001934184287470 0.000011277159619 0.001823457556127
33	0.011603148803824 0.000000000000034 -0.000000002509134 -0.000000003737291 0.000817966027971 0.000003198928776 0.000740612856722	0.012640747643937 -0.000000000000464 0.000000016551428 -0.000000002090183 0.000894342442906 0.000003654921572 0.000843741557980	0.022132980341826 -0.000000002321636 0.000006742756210 -0.000001213251736 0.002907112768187 0.000021305421202 0.002667294910125	0.018580300530629 -0.00000000017485 0.000000133109667 -0.000000023479501 0.001911778368374 0.000011173273181 0.001809785264405
34	0.011603148803824 0.000000000000034 -0.000000002509134 -0.000000003737291 0.000817966027971 0.000003198928776 0.000740612856722	0.012640747643937 -0.000000000000464 0.000000016551428 -0.000000002090183 0.000894342442906 0.000003654921572 0.000843741557980	0.023071686823899 -0.000000001849724 0.000006391246048 -0.000001112456281 0.003105548614448 0.000023095492652 0.002866008264969	0.017767521431241 -0.000000000075989 0.0000000313272217 -0.000000053615151 0.001762351743622 0.000009926470533 0.001662358841413
35	0.011219162459130 -0.000000000002429 0.0000000086117552 -0.000000006403329 0.000737282587888 0.000002762787122 0.000680491536730	0.013096942953479 -0.000000000003210 0.000000188817288 -0.000000015080338 0.000967276457921 0.000004094956381 0.000908694592786	0.021941115652623 -0.000000003021449 0.000006960013653 -0.000001041102205 0.002813442292894 0.000020025877154 0.002597016799547	0.016610576959323 -0.000000000008152 0.000000106591567 -0.000000026025253 0.001496638581603 0.000007852281784 0.001433093851963
36	0.011219162459130 -0.000000000002429 0.0000000086117552 -0.000000006403329 0.000737282587888 0.000002762787122 0.000680491536730	0.013096942953479 -0.000000000003210 0.000000188817288 -0.000000015080338 0.000967276457921 0.000004094956381 0.000908694592786	0.017262324047450 -0.000000006125904 0.000000926522210 -0.000000359389859 0.001682353086304 0.000009501650831 0.001582877946884	0.018113328583941 -0.00000000012774 0.000000029440715 -0.000000055268808 0.001828816680499 0.000010415600763 0.001724682569358
37	0.010836557779866 -0.000000000001434 0.000000088167066 -0.000000006132593 0.000674454497668 0.000002456337238 0.000629510599716	0.013423973944053 -0.000000000000438 0.000000057651526 -0.000000005257430 0.001004174421958 0.000004358369341 0.000949532180762	0.017873240974466 -0.000000002904471 0.000005860880855 -0.000000764093057 0.001956421317894 0.000012058736734 0.001771875123784	0.016048998338884 -0.000000000009874 0.000000259008213 -0.000000033172488 0.001413053819007 0.000007292028342 0.001347115298810
38	0.010836557779866 -0.000000000001434 0.000000088167066 -0.000000006132593 0.000674454497668 0.000002456337238 0.000629510599716	0.013423973944053 -0.000000000000438 0.000000057651526 -0.000000005257430 0.001004174421958 0.000004358369341 0.000949532180762	0.020486853425830 -0.000000007503729 0.000005609282213 -0.000000867822570 0.002469247633770 0.000016287323702 0.002269680215637	0.016767633256767 -0.000000000019572 0.0000000618869077 -0.000000090685555 0.001583741670447 0.000008607632418 0.001489051104493

39	0.009402333156081 -0.000000000006738 0.000000115060029 -0.000000006746779 0.000531245357423 0.000001717938615 0.000484783497222	0.012961625503261 -0.000000000001645 0.000000125715840 -0.000000010474061 0.000955807788989 0.000004003568599 0.000893599484492	0.023909250105936 -0.000000005437147 0.000003491992631 -0.000000674528204 0.003271453333191 0.000024779520418 0.003045085693397	0.017672678332005 -0.000000000032431 0.000000335661549 -0.000000059756429 0.001744016951614 0.000009725681815 0.001643673558602
40	0.009402333156081 -0.000000000006738 0.000000115060029 -0.000000006746779 0.000531245357423 0.000001717938615 0.000484783497222	0.012961625503261 -0.000000000001645 0.000000125715840 -0.000000010474061 0.000955807788989 0.000004003568599 0.000893599484492	0.012691413593611 -0.000000001448800 0.000002724181210 -0.000000226698137 0.000995822735819 0.000004499982014 0.000899344818994	0.016605582994733 -0.00000000010001 0.000000412859474 -0.000000069343908 0.001535629955965 0.000008209873202 0.001452040288127
41	0.009632050112551 -0.000000000008943 -0.000001067526186 -0.000000028005442 0.000538850270491 0.000001923025576 0.000504480153341	0.012801442186499 0.000000000000027 0.000000031363553 -0.000000002749792 0.000917408982265 0.000003802170322 0.000865462455017	0.015796172622433 -0.000000001637428 0.000003458847119 -0.000000335146552 0.001469625041002 0.000007721812220 0.001353316363145	0.016639144533012 -0.000000000096896 0.000001213324745 -0.000000151856577 0.001601830795933 0.000008727411202 0.001485665890112
42	0.009632050112551 -0.000000000008943 -0.000001067526186 -0.000000028005442 0.000538850270491 0.000001923025576 0.000504480153341	0.012801442186499 0.000000000000027 0.000000031363553 -0.000000002749792 0.000917408982265 0.000003802170322 0.000865462455017	0.019389504895710 -0.000000000168102 0.000002132391069 -0.000000386008342 0.002140278126611 0.000013532879920 0.002003479792572	0.017745940029604 -0.000000000013062 0.000000549366935 -0.000000092242937 0.001790844815675 0.000010126115216 0.001672682555925
43	0.010961076205340 0.000000000004448 -0.000000566570706 -0.000000014994552 0.000703465461185 0.000002757780282 0.000653503082392	0.013136925288587 -0.000000000001508 0.000000165126487 -0.000000013421549 0.000990516003332 0.000004177594621 0.000921086616835	0.014649019573465 -0.000000001908014 0.000002670440074 -0.000000258658627 0.001271764358304 0.000006180744706 0.001167077032796	0.016887874031918 -0.000000000195243 0.000000798951551 -0.000000105329628 0.001620756571971 0.000008827328076 0.001516161609225
44	0.010961076205340 0.000000000004448 -0.000000566570706 -0.000000014994552 0.000703465461185 0.000002757780282 0.000653503082392	0.013136925288587 -0.000000000001508 0.000000165126487 -0.000000013421549 0.000990516003332 0.000004177594621 0.000921086616835	0.016810682162214 -0.000000000590332 0.000003422613865 -0.000000525686261 0.001705661225605 0.000010051186400 0.001557746389944	0.017859528423904 0.00000000000928 -0.000000192532028 -0.000000014597751 0.001760765834339 0.000009908372699 0.001669779171752
45	0.011469831660203 0.000000000014620 -0.000000548752159 -0.000000015495787 0.000753394791561	0.011490769528779 -0.000000000000014 0.000000003065029 -0.000000000417375 0.000744890485756	0.014139124495738 -0.000000001753820 0.000002983988671 -0.000000254332036 0.001208847443489	0.017790689725693 -0.000000000457222 0.000002048098398 -0.000000235977888 0.001859786178237

	0.000003022841752 0.000707023508400	0.000002810613547 0.000700690373859	0.000005741796160 0.001098703961017	0.000010542150577 0.001706920102212
46	0.011469831660203 0.000000000014620 -0.000000548752159 -0.000000015495787 0.000753394791561 0.000003022841752 0.000707023508400	0.011490769528779 -0.000000000000014 0.000000003065029 -0.000000000417375 0.000744890485756 0.000002810613547 0.000700690373859	0.016285904671493 -0.000000003753930 0.000005138836123 -0.000000523232585 0.001645923864736 0.000009150841638 0.001478372724434	0.016527575673367 -0.000000000785703 0.000002121399599 -0.000000216981673 0.001592380978572 0.000008459022258 0.001468714225761
47	0.012713985605066 -0.000000000002389 -0.000000276527141 -0.000000012119987 0.000930321154187 0.000003999363105 0.000867936755478	0.012328791678303 -0.000000000000021 0.000000004279773 -0.000000000506565 0.000864099114524 0.000003461690309 0.000808648147618	0.018270802765785 -0.000000015648414 0.000006166545223 -0.000000804459922 0.002067880710309 0.000012633366796 0.001855007568831	0.016989990459896 -0.000000000000973 -0.000000122108194 -0.000000009152319 0.001591081939770 0.000008485343815 0.001509679267546
48	0.012713985605066 -0.000000000002389 -0.000000276527141 -0.000000012119987 0.000930321154187 0.000003999363105 0.000867936755478	0.012328791678303 -0.000000000000021 0.000000004279773 -0.000000000506565 0.000864099114524 0.000003461690309 0.000808648147618	0.012828953311248 -0.000000003944639 0.000003727133881 -0.000000298761060 0.001067089592105 0.000004869158491 0.000939577611814	0.017617273141005 0.000000000000465 0.000000132507953 -0.000000033993427 0.001730624197029 0.000009562146108 0.001631652956210
49	0.012214516137412 -0.000000000003452 -0.000000114046334 -0.000000022092542 0.000880534023159 0.000003724401051 0.000811959816171	0.012312681154014 -0.000000000000133 0.000000012966602 -0.000000001208720 0.000862525615496 0.000003474829855 0.000807269892354	0.017556401940140 -0.000000005116423 -0.000000388078094 -0.000000349174667 0.001576409257966 0.000009031791592 0.001564168439927	0.017580971143432 -0.000000000025233 0.000000654510699 -0.000000086399949 0.001726870334668 0.000009616719730 0.001627738555541
50	0.012214516137412 -0.000000000003452 -0.000000114046334 -0.000000022092542 0.000880534023159 0.000003724401051 0.000811959816171	0.012312681154014 -0.000000000000133 0.000000012966602 -0.000000001208720 0.000862525615496 0.000003474829855 0.000807269892354	0.020224750580057 -0.000000000958825 0.000000083943537 -0.000000178738674 0.002092130010665 0.000013197186955 0.002067942392898	0.016245097903667 -0.000000000004238 -0.000000031665720 -0.000000012863697 0.001452506912159 0.000007509113559 0.001380855676518

Priedas nr 9

Bruožai PCA

Kadr as	1 ląstelė	2 ląstelės	3 ląstelės	4 ląstelės
1	0.966528724530410 2.101065473429166 0.243029624857310 0.333735312207404 -0.045148905965369 -0.180562402568506 1.211690372874501 -0.291711394440801 -0.574417670144986 -0.445910863117401 -0.183026272293181 -0.116932051192127 -0.104844973663114 -0.127360773428061 0.306970697822589	-4.976067178381150 -0.184059373418128 -0.009289334005829 0.175145928932713 0.074732608555364 0.092201878370941 0.774217347483406 0.138230708903851 -0.098035839617935 0.141094411113032 0.263460218726084 0.121223791460348 -0.195455632577580 -0.183406826304695 -0.187375805876724	-2.801559613736563 -0.374099638491891 -0.069916477658810 0.069407364828431 0.051067194280684 0.097982836064425 0.053188691233873 0.039142313347159 0.047409957050647 0.194267217377151 0.019681578185135 -0.105155918897446 -0.111081563115564 -0.054576968865706 0.028480425357250	0.608240912646916 1.454199899734550 -0.523261179385246 -0.130874024256887 0.019438945638558 0.636911042890773 -0.429825764071519 0.376901846622636 -0.061297715215545 0.174465080383044 0.766869000146533 -0.040356129940736 -0.193918812112015 0.090087515777589 0.301221691408267 0.608240912646916
2	0.966528725 2.101065473 0.243029625 0.333735312 -0.045148906 -0.180562403 1.211690373 -0.291711394 -0.57441767 -0.445910863 -0.183026272 -0.116932051 -0.104844974 -0.127360773 0.306970698	-4.976067178 -0.184059373 -0.009289334 0.175145929 0.074732609 0.092201878 0.774217347 0.138230709 -0.09803584 0.141094411 0.263460219 0.121223791 -0.195455633 -0.183406826 -0.187375806	-2.596448302 -0.363791609 -0.005420299 0.24695822 -0.03312417 0.096434499 0.279364266 -0.127871829 -0.006579422 -0.083042913 -0.081883017 0.044071155 -0.230752762 -0.069149965 -0.061337912	-5.328489749 0.2041769 -0.129364825 -0.144152236 -0.211710418 -0.345574705 -0.209735553 0.131371198 0.024583809 0.118524839 0.362136117 0.033142982 0.008536774 0.047969186 -0.197481329
	0.807287208 1.839816249 0.06423277	-4.409046381 0.007816165 0.066436407	1.031837295 -0.512987498 1.761113873	0.519363676 0.187510491 -0.737808296

3	0.207727251 -0.170539666 0.728955235 0.647729405 -0.719351934 0.603624396 0.179120448 0.392368909 1.304734463 0.619193376 -0.386023328 -0.644980966	-0.145888135 0.152335042 0.046668899 0.116339232 -0.14743016 0.006772532 0.070191062 -0.244278266 0.10445194 0.075095683 0.053474406 0.181790874	-0.309956205 0.398734907 0.30032734 -0.696589919 -0.497049837 -0.131620454 0.454080872 -0.927405333 -0.049127791 0.341650582 0.161333828 -0.080345695	-1.359931238 0.042727257 -0.422157706 0.499183358 -0.468301034 -0.569757083 -0.048950751 -0.250318629 0.332162032 -0.083967193 -0.303331981 0.269826951
4	0.807287208 1.839816249 0.06423277 0.207727251 0.170539666 0.728955235 0.647729405 0.719351934 0.603624396 0.179120448 0.392368909 1.304734463 0.619193376 0.386023328 0.644980966	-4.409046381 0.007816165 0.066436407 -0.145888135 0.152335042 0.046668899 0.116339232 -0.14743016 0.006772532 0.070191062 -0.244278266 0.10445194 0.075095683 0.053474406 0.181790874	2.462688832 -1.656175065 -0.798776465 0.409815769 -0.221753367 0.963613295 1.174481712 -0.873683351 0.850312096 -0.241309442 -0.083672999 -0.229976291 -0.338189057 0.20456251 -0.445355176	-0.046848418 0.350333045 1.606657585 0.314989182 1.453583617 -0.291850543 -0.095287992 0.777119468 0.445582729 -0.159565533 -0.193103558 0.736934132 -0.219021809 -0.52452582 0.88962639
5	0.16157411 -0.10932027 -2.204507301 -1.146979519 -1.096127859 1.311614577 -0.658418543 -0.122431729 -0.634792358 1.063887454 -0.182185125 0.368945532 -0.2225831 -0.054989901 0.394649707	-4.791974903 -0.390303352 0.112986726 -0.023328796 -0.228441726 0.04681861 0.562231077 -0.079016631 -0.019038756 0.011682729 0.04433023 -0.250807982 0.037939874 0.246743469 0.11875957	2.481521757 -1.410501563 -0.835542634 0.370528997 -0.181775142 1.240663826 1.319782084 -1.356304216 0.352134087 -0.239204158 -0.601920565 0.47290978 0.040534704 -0.162618836 0.373769729	-5.512169655 -0.112676226 -0.1326326 -0.182304381 -0.150422486 0.436638332 -0.009956223 0.044740555 -0.062012586 -0.142522121 -0.047626465 -0.001762406 0.06011326 -0.115730609 -0.230646767
	0.16157411	-4.791974903	-2.841973564	-5.622363628

6	-0.10932027 -2.204507301 -1.146979519 -1.096127859 1.311614577 -0.658418543 -0.122431729 -0.634792358 1.063887454 -0.182185125 0.368945532 -0.2225831 -0.054989901 0.394649707	-0.390303352 0.112986726 -0.023328796 -0.228441726 0.04681861 0.562231077 -0.079016631 -0.019038756 0.011682729 0.04433023 -0.250807982 0.037939874 0.246743469 0.11875957	-0.363421458 -0.027305278 0.035295136 0.016884741 0.234062326 0.025322411 -0.044531888 0.03682109 0.125438833 -0.000641556 -0.129780768 -0.12553293 -0.18449103 -0.121108441	-0.298111341 -0.289639112 -0.176480732 -0.038384133 0.101054554 0.017794382 -0.154101984 -0.041935609 -0.110139565 -0.384936446 -0.013832483 -0.156615991 0.431579298 0.578284995
7	1.185941996165130 1.237250976857475 0.075941680031291 0.231892750836395 -0.361804335591121 -0.069514522503929 0.505362228476603 -0.624736552815194 -0.697559360658840 -0.017620679786779 -0.795940562644204 -0.978284758296553 -0.537957522119807 0.003596593766429 0.659190756232326	-1.959827537460349 -0.229837435097311 -0.093037129319657 -0.339409906839632 0.329274967099865 -0.424869517199255 -2.848168334236089 0.331470190580414 0.272401852330556 -0.576333339196236 -0.156101062493432 0.099818503091473 0.098028074524222 0.095538890120336 -0.211143963974044	2.681330996481 0.133549467601 0.143002748822 0.059543134550 0.103252608538 0.017515017915 0.128942878710 0.104824992902 0.132887984787 0.137793299630 0.158398553575 0.172810239142 0.061551313810 0.024072025367 0.066479959662	4.82434400164 0.07088155505 0.05317082839 0.17344551417 0.03463548043 0.18900383968 0.15375752628 0.05430138079 0.28330522665 0.14746808087 0.06875301970 0.13263568679 0.05846535452 0.35986864483 0.29387592261
8	1.185941996 1.237250977 0.07594168 0.231892751 -0.361804336 -0.069514523 0.505362228 -0.624736553 -0.697559361 -0.01762068 -0.795940563 -0.978284758 -0.537957522	-1.959827537 -0.229837435 -0.093037129 -0.339409907 0.329274967 -0.424869517 -2.848168334 0.331470191 0.272401852 -0.576333339 -0.156101062 0.099818503 0.098028075	-2.876719716 -0.345718359 -0.102238629 0.104167777 -0.092475143 0.114848279 0.103289383 0.00673475 -0.020355596 -0.097446811 -0.037989122 0.11125963 -0.173696001	0.637121026 -0.479655014 -0.24126069 -0.476295206 -0.311325576 0.944173275 0.304950842 -0.36777912 -0.360573093 -0.055810909 0.176126908 -0.165531857 0.38129979

	0.003596594 0.659190756	0.09553889 -0.211143964	0.144260103 0.195934063	-0.638601016 0.533347967
9	1.690921621 -0.531257851 -0.138948428 -0.025274582 2.441857329 1.348203898 -0.392351798 -0.48678672 0.904797432 0.107506222 -0.271641779 -0.55320679 0.023001294 -0.147398806 0.043728319	0.610520761 1.454182946 0.039795243 -0.566218105 -0.141866766 0.128389005 0.317731537 -0.872358302 -1.091883699 -1.825994103 -0.909379048 -0.553854732 -0.591260245 0.30207678 -0.093369709	-2.729862298 -0.349104793 -0.107911208 -0.000604837 0.098988947 0.192599361 -0.046300254 -0.015807835 0.138921418 0.062037422 0.032800237 -0.140444975 -0.012538907 -0.130020855 -0.182734996	0.544897821 -1.452811814 0.471005505 -0.079390102 -0.237310045 0.121326296 0.368879939 0.028827237 -0.122146873 -0.264185774 0.902914593 -0.628702014 0.181297181 -0.020701308 -0.154377746
10	1.690921621 -0.531257851 -0.138948428 -0.025274582 2.441857329 1.348203898 -0.392351798 -0.48678672 0.904797432 0.107506222 -0.271641779 -0.55320679 0.023001294 -0.147398806 0.043728319	0.610520761 1.454182946 0.039795243 -0.566218105 -0.141866766 0.128389005 0.317731537 -0.872358302 -1.091883699 -1.825994103 -0.909379048 -0.553854732 -0.591260245 0.30207678 -0.093369709	-3.000258445 -0.285019339 -0.096400544 -0.022700379 0.048316872 0.093539374 -0.176672337 -0.009835653 -0.004082776 0.009316499 -0.1438137 0.10428963 0.377754371 -0.078907152 0.077595453	0.36235915 0.36842985 0.52205205 1.15164551 1.46552901 0.07932232 0.15958130 0.87977644 0.72299521 1.15510776 0.71751893 0.56637547 -0.2356137 0.61971200 0.33880006
11	1.212609755 -0.147040517 -0.415593422 0.342696052 0.102745492 0.141992598 -0.311133277 -0.18454024 0.335081696 -0.225284381	0.594529392 1.326240707 -0.88671131 0.520578491 2.059680699 -0.018529961 -0.020273355 1.091979964 -1.362291895 0.745485004	-2.851090399 -0.195713874 -0.175712321 -0.013078429 -0.018078259 0.046788587 -0.140622255 0.055270862 0.071070265 -0.015367459	0.61419251 2 -1.15298734 0.27157801 6 0.15678521 7 1.19183707 6 -0.15061997 0.66139985 6

	0.190771205 -0.138802928 0.231348514 0.169687051 0.395916365	-0.133954936 -0.37064304 0.164661365 -0.315901496 0.255995164	-0.173348983 -0.028977679 0.166261243 0.077817933 -0.014637662	0.17935213 4 0.05465987 4 0.61585034 4 0.63415404 6 0.02865264 8 0.15468870 9 0.07204988 3 0.15927060 3
12	1.212609755 -0.147040517 -0.415593422 0.342696052 0.102745492 0.141992598 -0.311133277 -0.18454024 0.335081696 -0.225284381 0.190771205 -0.138802928 0.231348514 0.169687051 0.395916365	0.594529392 1.326240707 -0.88671131 0.520578491 2.059680699 -0.018529961 -0.020273355 1.091979964 -1.362291895 0.745485004 -0.133954936 -0.37064304 0.164661365 -0.315901496 0.255995164	-2.914198849 -0.257918216 -0.111941715 0.025813768 -0.003178534 0.101944247 -0.104790203 0.028434264 0.129778885 0.003034657 -0.10710588 -0.061721652 0.130590797 0.001601572 0.005361849	0.61335863 0.176590982 0.692762259 0.040857767 0.831711145 1.310007907 0.388464642 0.174359985 -0.00189135 0.142339432 0.391516155 0.07656733 0.322105577 0.116140967 0.511803203
13	3.0247894709801 0.2568640206314 0.9257615405802 0.1367540111455 0.4717671950868 0.3166692824649 0.7819584723655 0.1969237393799 0.4318695621343 0.0916668242743 0.1109937530525 0.1153560888074 0.1339085263999	0.477718787709214 1.546087134655684 0.169126867855291 1.004725433960205 0.750366654299771 0.166636868849786 0.007550902219637 0.241649024574292 0.678466277397208 0.172870801221445 1.447878239553890 0.997122646950589 0.096343321455024	-2.642548730560542 -0.376426512010183 -0.056002941760037 0.179688232319094 -0.104296467005490 0.101940234983503 0.229770966335956 -0.040830734299023 -0.016786691830122 -0.009001584762807 -0.069359240050058 -0.002675803383869 -0.080827464334366	0.564826217 1.077539019 0.169212767 0.197831723 0.643883716 0.198332127 0.327046790 0.056973647 0.459629281 0.261445930 0.352001436 0.534822871 0.350833738

	0.0519004768271 0.1157525077738	0.623970321684417 0.123884980088487	-0.013591858041739 0.065849515615094	0.547736693 0.252930856
14	-3.024789471 -0.256864021 -0.925761541 0.136754011 0.471767195 -0.316669282 0.781958472 -0.196923739 0.431869562 0.091666824 -0.110993753 0.115356089 0.133908526 0.051900477 0.115752508	0.477718788 1.546087135 -0.169126868 -1.004725434 -0.750366654 -0.166636869 -0.007550902 -0.241649025 -0.678466277 -0.172870801 1.44787824 0.997122647 0.096343321 -0.623970322 -0.12388498	0.074902305 -2.380356102 -0.337439943 -0.007307475 -0.012889317 -0.143268421 0.141596378 0.074902305 -0.032227063 0.038183911 -0.025341906 -0.021890189 -0.019429531 0.008029709 0.116535657 0.168658566	0.508570994 1.533340046 -0.301739462 0.434338044 0.062189615 0.64877857 -0.262149458 0.579948668 -0.138173537 0.211905118 0.85066519 0.296943737 0.255989417 0.61374409 0.21183784
15	-3.249367739 0.197893621 -1.20326933 0.110003809 0.624253198 -0.200812588 0.844658147 -0.149727681 0.311697201 -0.158502416 0.105603584 0.045999813 0.091467482 0.170252725 0.150384431	0.456537708 -0.285133191 -2.911656606 1.748037256 -1.433282748 0.279360427 -0.272403316 -0.473915135 -0.224671975 0.150884161 -0.159615378 0.125834516 0.160599238 0.011352179 0.119022523	-2.455602147 -0.12960712 -0.133987523 0.083467654 0.089614542 -0.055924458 -0.13329129 0.01486303 -0.023323968 -0.055428035 -0.019164179 -0.129212288 -0.056516745 0.111992044 -0.034219134	0.459486519 0.250441863 0.29493798 -0.084346319 -0.227841786 -0.703646706 -0.313341574 0.304075027 1.107957322 -0.308217795 -0.128323727 0.448771186 1.745854067 -0.160284795 -0.196123845
16	-3.249367739 0.197893621 -1.20326933 0.110003809 0.624253198 -0.200812588 0.844658147 -0.149727681 0.311697201 -0.158502416 0.105603584	0.395388511 2.402819257 -0.09845114 0.745254656 1.168571881 0.571325197 0.100011296 -0.912306776 1.757259735 0.018509935 0.363670225	-2.574079596 -0.322269586 -0.066500674 0.11450122 -0.129083573 0.056053938 0.079193441 -0.046183878 -0.009378095 -0.063638575 0.009818888	0.481173801 0.071694522 -1.013090066 -0.85530105 0.517803179 -0.189282972 0.458508195 -0.020327713 -0.832584352 -0.287034066 -0.514861432

	0.045999813 0.091467482 0.170252725 0.150384431	0.366919739 0.005888214 0.32270783 -0.156762635	-0.043659066 -0.133061771 0.158665835 0.048287286	0.449657655 0.06227063 0.352430217 -0.134478412
17	-2.055069572 1.948727104 1.207764265 0.574293858 -0.016751668 -0.225129321 -2.090955008 -0.144211345 0.326685138 0.881571603 -0.252809643 -0.079623098 -0.081498036 0.218000843 -0.210621507	0.395388511 2.402819257 -0.09845114 0.745254656 1.168571881 0.571325197 0.100011296 -0.912306776 1.757259735 0.018509935 0.363670225 0.366919739 0.005888214 0.32270783 -0.156762635	0.745322446 -0.360558431 0.241775901 0.416165397 0.448178126 -0.302876557 0.143711259 0.463490273 0.611784216 -0.87119869 0.460823501 0.858684046 -0.503345523 -0.352336164 0.240154487	0.287224261 0.274699064 -1.277214619 0.377100922 0.678516686 -0.742655183 -0.483712551 0.055180472 -0.89731389 -0.540684415 -0.119767239 -0.261355368 0.314344128 0.803651323 -0.469544192
18	-2.055069572 1.948727104 1.207764265 0.574293858 -0.016751668 -0.225129321 -2.090955008 -0.144211345 0.326685138 0.881571603 -0.252809643 -0.079623098 -0.081498036 0.218000843 -0.210621507	0.456537708 -0.285133191 -2.911656606 1.748037256 -1.433282748 0.279360427 -0.272403316 -0.473915135 -0.224671975 0.150884161 -0.159615378 0.125834516 0.160599238 0.011352179 0.119022523	0.371550721 -0.47704992 -0.100808262 -0.02428464 -0.719507941 -0.150238225 -0.776946469 -0.187708045 -0.592161054 -0.422739294 0.725994802 1.549453267 0.607662609 0.330773191 -2.030691155	0.0282663 0.572761594 1.329124718 0.29898123 0.386309443 1.105737907 0.617985186 0.237337433 -0.93027109 0.305474198 0.135879913 1.136896136 0.390830674 0.661432783 0.657193538
19	1.1021349034878 0.4872809332316 0.4160123534812 0.4459614236185 0.0971331938363 0.6832226185954 0.9257238320906 0.0328256318297 0.7883763563771	0.392752435617801 2.036508434423468 0.123462184657667 -1.245065839390418 -1.677775175242832 -0.084737589086245 -0.049313764152358 1.170992386210358 0.469079972551087	0.753040017470680 -0.368495226300948 -0.400228774540885 -1.208674021158228 0.224742299100008 -1.426651900237741 0.132157596742177 -0.172857608304612 0.015721836959007	0.229698482882526 -0.847791121547128 0.454490987815184 0.787776772009169 -0.333547056215465 -0.402984475340094 -0.259181357461900 0.156308631133919 -1.303076926247471

	1.9023733125307 0.8263531199784 0.6340258035697 0.4996270449224 0.0858950280489 0.4270961226005	1.028153122987428 -0.600372031466723 -0.430066785082344 0.014327403282643 0.230759941466316 0.010830367098233	0.091823475367027 -0.524551009330735 0.166036503921569 -1.092683152998787 -0.740815159376929 -0.294326437214739	1.011561584176320 0.243651296896033 0.739179784989673 -0.484515963487871 -0.708599500788093 -0.822744748681346
20	-1.102134903 0.487280933 -0.416012353 -0.445961424 0.097133194 0.683222619 -0.925723832 0.032825632 -0.788376356 -1.902373313 0.82635312 -0.634025804 -0.499627045 0.085895028 -0.427096123	0.392752436 2.036508434 0.123462185 -1.245065839 -1.677775175 -0.084737589 -0.049313764 1.170992386 0.469079973 1.028153123 -0.600372031 -0.430066785 0.014327403 0.230759941 0.010830367	0.42740101 0.30184539 0.31705369 1.32756536 0.70447225 0.94477137 0.57222366 1.08310960 0.93872848 0.97649664 1.20094250 0.28562725 0.17749019 0.06761784 0.61281796	0.441669638 -0.390783316 -1.505569965 -0.186321317 0.523439959 -0.569850917 0.314687657 -0.029440715 -0.164799657 -0.39464937 -0.286885208 0.515758853 -0.047766131 0.144879386 -0.278034469
21	-0.700167104 -0.448764809 1.022538973 -0.270159189 -1.499107304 1.44831466 0.454494254 0.986043118 1.121017112 -0.535259025 -0.966751873 -0.477769896 0.208032096 -0.260350352 -0.188726614	0.621313575 -0.660998544 0.569457188 -0.130308139 0.132531073 -0.003355299 -0.306444711 -0.633526452 -0.482831579 0.483836154 0.214983829 0.538731611 -0.680793903 -1.096893363 0.004938564	0.591370409 0.364930231 -0.690586198 -1.60417733 0.399435348 -1.10880122 0.226957659 -0.547339164 0.683670175 0.758855848 -0.275443243 -0.229170081 0.163772487 -0.021544444 -0.25444324	0.502329867 0.465110723 -0.621462136 -1.230180703 -0.440363684 -0.687623691 0.138995466 -0.505819156 -0.359514891 0.042389717 -0.318078875 0.337180599 -0.111285813 -0.485261845 0.492438898
22	-0.700167104 -0.448764809 1.022538973 -0.270159189 -1.499107304 1.44831466 0.454494254	0.621313575 -0.660998544 0.569457188 -0.130308139 0.132531073 -0.003355299 -0.306444711	0.63202561 0.312308865 0.239419347 0.304090368 -1.319078113 -0.813664423 0.91174494	-0.051338704 -0.145709281 1.472078765 0.496827816 1.076191445 -0.387083612 -0.297303652

	0.986043118 1.121017112 -0.535259025 -0.966751873 -0.477769896 0.208032096 -0.260350352 -0.188726614	-0.633526452 -0.482831579 0.483836154 0.214983829 0.538731611 -0.680793903 -1.096893363 0.004938564	0.372769542 -0.960720138 0.295695354 -0.207034268 0.36141466 -0.439159748 1.028947362 0.407491354	0.596992801 -0.562873872 -0.818694575 -0.03332795 -0.139591894 -0.648209067 -0.692056374 0.350991302
23	-0.552587749 -0.863815583 0.661038792 0.059247162 0.247856228 -0.199349307 0.271335246 0.019572706 -0.071160536 0.168460936 -0.534830761 -0.255281134 0.154164422 0.059971161 0.366543369	0.930693007 -0.687812183 -0.119033535 -0.226897789 0.125490483 -0.156520615 0.268961101 0.04599022 -0.216623522 0.161046053 -0.108252181 0.416889303 0.11928717 0.7155783 -1.088923871	0.886256893 -0.00290228 0.439474145 1.168535546 0.509248253 -0.314758428 0.051486999 0.507102598 1.339779546 -0.528037078 0.592060768 0.412102776 0.014276449 -0.093962203 0.137343072	0.51866228 -0.380926115 -0.028313161 -1.230673682 0.180265 0.140223849 0.759633582 -0.536719762 -0.222282623 -0.08564598 0.141144599 0.356345751 0.072347999 -0.224864604 0.037999988
24	-0.552587749 -0.863815583 0.661038792 0.059247162 0.247856228 -0.199349307 0.271335246 0.019572706 -0.071160536 0.168460936 -0.534830761 -0.255281134 0.154164422 0.059971161 0.366543369	0.930693007 -0.687812183 -0.119033535 -0.226897789 0.125490483 -0.156520615 0.268961101 0.04599022 -0.216623522 0.161046053 -0.108252181 0.416889303 0.11928717 0.7155783 -1.088923871	0.924317843 -0.213947432 1.072393757 -0.312001792 -0.077259007 0.01709012 -0.226175766 -0.10763262 -0.093475164 0.140805474 -1.083204073 0.295503214 0.049633757 -0.716190371 -0.403141941	0.422186249 -1.062126281 -0.865243336 1.047033647 -0.50022604 -0.203257733 0.443733061 0.710039528 -0.018401336 0.227889028 0.128595371 0.534802012 -0.119110743 0.477797749 0.078916885
	0.489594249933989 0.550564614288282 0.931603374566829 0.183059284958365 0.055040292789009	0.663249677013167 0.185056150116687 1.001897426552182 0.183297786410337 0.400916547389362	0.685786676417476 0.163622264002801 -0.114141840782834 0.007590893752406 -0.973528955047019	0.469313937071513 -1.062349758346847 -1.281088893966087 1.027973984601301 0.539366158306077

25	0.152377532540166 0.082724267190303 0.283506404301144 0.212446358463522 0.404315185503617 0.024430469926378 0.070730201015120 0.389870594876946 0.185816129020110 0.989548752543606	0.039885510031090 0.149050411838008 0.853922258529082 0.030840172232684 0.673705683092798 0.540438830515605 0.494704852953052 0.494613008537270 1.133417669507272 0.343111308542788	-0.720669790122735 0.353969936303215 -0.144187568271747 -0.627598538692679 -0.000679334178509 0.131770886381126 0.691100810371943 -0.094039853732969 1.151837812498337 0.768942956077052	0.043307464188127 0.897559850681532 0.328962894995008 0.417143982590118 -0.132780994208345 0.129633082962356 -0.060678761058447 -0.029336585719149 0.211435897784439 0.307486193961198
26	-0.48959425 -0.550564614 0.931603375 -0.183059285 -0.055040293 -0.152377533 0.082724267 0.283506404 0.212446358 0.404315186 -0.02443047 0.070730201 -0.389870595 -0.185816129 0.989548753	0.663249677 -0.18505615 1.001897427 0.183297786 -0.400916547 -0.03988551 -0.149050412 -0.853922259 0.030840172 0.673705683 -0.540438831 -0.494704853 0.494613009 -1.13341767 -0.343111309	0.840373303 0.853724351 -0.666110169 -0.253901135 0.843072331 -0.835883048 0.556343803 0.327099836 -0.002330834 -0.550289265 -0.944532717 -0.316014542 0.086217382 0.091648733 -0.577835901	0.418436771 -0.984780293 0.52652772 -0.439800151 0.01250855 -0.288319234 0.614395812 -0.248919078 0.492644815 0.185417909 1.313351244 0.180432497 -0.16454039 0.017674273 0.070565438
27	-0.100420418 -0.61638723 0.719042425 -0.531110633 0.285023363 -0.587680677 0.008277746 -0.273374851 -0.432379399 -0.275934063 -0.734364031 0.550652079 -0.24759698 0.088980023 -0.3768332	0.68865385 -0.070640217 0.383349157 0.643457406 0.140205838 -0.165103272 0.156096272 -0.097970176 0.667753769 0.004376307 -0.97649884 -0.298601999 -0.34696669 -0.696576327 -0.240810715	0.897429357 0.486913174 0.10992828 0.510221861 -0.582088432 -0.64132992 0.299887505 0.172675102 -0.470866113 -0.05074257 -0.152691493 0.139708995 -0.960312626 -0.511340064 -0.30662289	0.476169637 -1.024614497 -1.314364621 1.066592821 0.676679554 0.115190611 0.795592299 0.269085455 0.423998273 -0.080497701 -0.00462427 -0.370459879 -0.028914522 -0.078458163 0.301411427
	-0.100420418 -0.61638723 0.719042425	0.68865385 -0.070640217 0.383349157	0.868184951 0.979361903 -0.318628403	0.537855087 1.425284374 -0.369899366

28	-0.531110633 0.285023363 -0.587680677 0.008277746 -0.273374851 -0.432379399 -0.275934063 -0.734364031 0.550652079 -0.24759698 0.088980023 -0.3768332	0.643457406 0.140205838 -0.165103272 0.156096272 -0.097970176 0.667753769 0.004376307 -0.97649884 -0.298601999 -0.34696669 -0.696576327 -0.240810715	0.274610827 1.184906254 0.306107014 0.035512717 0.714074602 0.743012888 -0.198377438 0.02355563 0.304454636 0.065910232 0.719997916 -0.300556904	-0.278617905 -0.278639614 0.265334888 -0.215593218 0.197755789 -0.27824014 0.460477032 0.410626186 -0.303811814 -0.370551566 -0.333697925 0.187778396
29	-0.380911639 -0.786355652 0.076326693 0.642376909 -0.157149598 -0.501807334 -0.512684144 -0.071357296 -0.378563369 -0.313540498 0.315243085 0.187073391 0.280249393 -2.106292153 0.261761792	0.715643121 -0.026665669 0.956893014 0.692509977 -0.211342846 -0.266607806 0.294487276 0.392926317 -0.102192195 -0.915393583 0.254498346 -0.02016615 2.07116661 -0.010434988 0.205459549	0.665479917 1.225235958 -0.396180798 1.363545971 0.534089146 8.62386E-05 -0.629320756 -0.810778956 -0.465704121 0.486147544 0.015616263 0.150913073 -0.118323783 0.124982666 0.176027344	0.456735888 -1.362711125 0.649085794 0.389588149 -0.80981367 -0.735461976 -0.289819299 0.320864907 -0.180806387 0.365852596 0.34558402 0.105287296 -0.024236077 0.131658822 -0.260193123
30	-0.380911639 -0.786355652 0.076326693 0.642376909 -0.157149598 -0.501807334 -0.512684144 -0.071357296 -0.378563369 -0.313540498 0.315243085 0.187073391 0.280249393 -2.106292153 0.261761792	0.715643121 -0.026665669 0.956893014 0.692509977 -0.211342846 -0.266607806 0.294487276 0.392926317 -0.102192195 -0.915393583 0.254498346 -0.02016615 2.07116661 -0.010434988 0.205459549	0.624968075 1.856202442 0.049231915 0.557037263 0.383796647 1.000757714 -0.496591287 -0.03497789 0.24935809 0.85573421 0.303920084 0.583072048 -1.424277283 0.014287605 0.149656738	0.605558661 -0.432986539 0.728675839 -0.682827722 0.036244053 1.084461355 -0.01784626 -0.622914083 -0.25791347 0.04072078 -0.12269119 -0.461416382 0.549382116 -0.207647047 0.043093493
	-0.142951813587066	0.9269432432	0.6909003743	0.5443152288600

31	-0.334905692529121 0.709256294803198 -0.143501394124884 0.165249615493212 0.029716712426516 0.004546732993602 0.121577584437471 -0.288127108307594 -0.171089700321782 0.206911101875984 0.837398906194177 -0.420044001889693 1.022073306451722 0.742548080457529	0.9217607479 0.0291685382 0.2731744798 0.1398645389 1.5589274495 0.1637437768 0.4381652077 0.2228805078 0.1141967162 0.1059571322 0.2311758610 0.2903782366 0.2697282297 0.5737590582	0.597547318 0.6082393681 0.4331343467 0.3031217424 0.6462763886 0.4429827592 0.2764462670 0.2061526411 1.3652867354 0.5569204828 0.1470006381 0.8129240113 0.0171986362 0.2119111286	1.2024958209057 0.7099611173677 0.4502909915643 0.0130529894722 0.2711401407748 0.0677496366126 0.1983787841123 0.2450519895381 0.4274330409402 0.4375613537728 0.7737015851792 0.4881630581458 0.0589949513729 0.3589757268866
32	-0.142951814 -0.334905693 0.709256295 -0.143501394 0.165249615 0.029716712 0.004546733 0.121577584 -0.288127108 -0.1710897 0.206911102 0.837398906 -0.420044002 1.022073306 0.74254808	0.926943243 -0.921760748 -0.029168538 -0.27317448 0.139864539 1.55892745 0.163743777 0.438165208 0.222880508 -0.114196716 -0.105957132 -0.231175861 0.290378237 -0.26972823 -0.573759058	0.59194255 1.221627989 -0.42310637 1.104267174 -0.835989972 -0.183448052 -0.001390971 0.059786836 -0.327627845 -0.415065444 -0.006311984 -0.319915068 -0.03811856 -0.878757823 0.395039179	0.507337039 0.248279996 -0.982395628 -0.779344388 -0.169711018 -0.977079667 -0.233366549 0.144400404 0.395049724 0.183474704 0.188378337 -0.361872255 -0.127605355 -0.347674793 -0.260671078
33	-0.31261564 -0.741867491 0.199205455 -0.382576878 -0.037308809 -0.306752317 0.307253043 -0.507081867 -1.100688681 0.941590205 -0.058802624 -1.127513604 0.84272043 0.10346817	0.962800376 -0.607449288 -0.122940814 -0.70976789 0.344004599 -0.694275635 0.334719014 -0.267230591 0.185329364 0.229216782 -1.106323613 1.328341087 0.253524558 0.237061839	0.619355461 1.5314127 -0.819905105 0.773123902 0.206305969 0.179750082 -0.554547227 -0.541426195 -0.6378703 -0.141248981 -0.047721583 -0.024206027 0.787183166 0.068965722	0.217817312 -0.096009743 1.785874776 -0.251746813 1.146148826 -0.003523414 -0.280624843 0.133501434 -0.181319629 0.08699525 0.423376253 0.434448841 0.399236918 -0.138167548

	-0.938424767	1.389903389	0.38490214	-0.73969381
34	-0.31261564 -0.741867491 0.199205455 -0.382576878 -0.037308809 -0.306752317 0.307253043 -0.507081867 -1.100688681 0.941590205 -0.058802624 -1.127513604 0.84272043 0.10346817 -0.938424767	0.962800376 -0.607449288 -0.122940814 -0.70976789 0.344004599 -0.694275635 0.334719014 -0.267230591 0.185329364 0.229216782 -1.106323613 1.328341087 0.253524558 0.237061839 1.389903389	0.403326174 1.853388376 -0.711709044 -1.620580022 -0.031777638 1.350075254 0.048032627 0.400194551 -0.265328312 -0.676222098 0.212783287 -0.054368799 0.121863755 -0.099768727 0.220832065	0.33193037 0.89672095 1.21347945 -0.3572452 0.45991595 0.50573077 0.21061921 0.02194269 0.04662211 1.18093046 0.45848831 0.39199751 0.25295230 0.69996939 0.28872012
35	0.017282373 -0.462542645 1.304617683 -0.026219778 -0.277669922 0.695402692 0.678030769 0.196700896 -0.137986559 0.661466544 2.04949616 -0.333964297 -0.031619303 0.238915352 -0.0220253	0.871950344 -0.224766028 0.897838152 1.167658594 -0.372273759 -1.036627131 0.086048768 0.331897801 0.069053638 -0.359673715 0.263028045 0.170904378 -0.523457487 -0.084943141 0.022241348	0.522383162 1.539266414 -0.605432037 -1.825845559 -0.276230562 0.823817834 -0.198626497 0.236431857 0.553699921 -0.358367427 0.303966779 0.087458614 0.115883999 0.146872623 0.176143503	0.729959113 -0.596204856 -0.780565233 0.593661409 -0.346416413 0.794999183 -0.333393294 0.134784148 0.066381981 -0.033426355 0.078029263 -0.448089488 -0.115556259 -0.375449896 0.191074473
36	0.017282373 -0.462542645 1.304617683 -0.026219778 -0.277669922 0.695402692 0.678030769 0.196700896 -0.137986559 0.661466544 2.04949616 -0.333964297	0.871950344 -0.224766028 0.897838152 1.167658594 -0.372273759 -1.036627131 0.086048768 0.331897801 0.069053638 -0.359673715 0.263028045 0.170904378	0.997459435 -0.71314885 -0.145137529 -0.073755957 -0.115036165 0.809694557 0.611708486 -0.401753494 -0.888954085 0.643751941 1.058744707 -0.664593056	0.548795403 0.022288101 0.209329992 -1.190346369 -0.238268527 -0.784460146 -0.124495906 -0.181315508 1.094409187 0.463215307 -0.15975415 -0.091950428

	-0.031619303 0.238915352 -0.0220253	-0.523457487 -0.084943141 0.022241348	0.622155623 -0.110298149 -0.412855003	-0.223486317 0.045085936 -0.253578781
37	0.436683769044211 -0.739109264320882 0.383299416200831 -0.559100711795799 0.110054845748250 -0.031821482067414 -0.177710686451566 0.140292244125377 -0.380472784975737 -0.499557575309075 -0.273125662827943 1.095005568515494 -0.110502061452336 0.170760233243777 -0.385859483965032	0.946280093878295 -0.751248777877968 0.080067505039897 -0.239225854131589 0.011337493526882 1.478953720303840 0.056381702762951 0.629039846338087 -0.017483383703327 -0.319808637566069 0.010858334358050 0.048937905614624 -0.186627317288515 -0.118679570254939 0.149504602172408	0.7328130594747 0.5646560981582 0.5908120082228 0.8619887582254 1.2193633370539 0.3313543959796 0.4075187578068 0.5163161345905 0.5017194098806 0.1636468877033 0.2328471559123 0.5986879231151 0.4747909962121 1.0063125212275 0.3883215300324	0.73039103700 0.18588669949 0.92040363522 0.20694750298 0.50053312379 0.88286258849 0.0205038178 0.38119635789 0.13358427393 0.53932595639 0.50057910732 0.15741210806 0.71493334780 0.53406060610 0.54752339012
38	0.436683769 -0.739109264 0.383299416 -0.559100712 0.110054846 -0.031821482 -0.177710686 0.140292244 -0.380472785 -0.499557575 -0.273125663 1.095005569 -0.110502061 0.170760233 -0.385859484	0.946280094 -0.751248778 0.080067505 -0.239225854 0.011337494 1.47895372 0.056381703 0.629039846 -0.017483384 -0.319808638 0.010858334 0.048937906 -0.186627317 -0.11867957 0.149504602	0.812542706 0.56654206 -0.297816928 0.321165783 1.5369575 -0.123305629 -0.046075095 -0.08755429 -0.347591882 0.31525191 0.134092592 -0.04745374 0.140729002 -0.04269678 -0.186931842	0.544668115 1.686795724 0.372013438 0.423683612 -0.666310916 -0.337048589 0.537154704 -0.03960126 0.452477921 -0.282948507 -0.099634759 -0.156258809 -0.67684555 0.066689676 -0.50906398
39	0.609466599 -0.6031714 0.46852611 -0.536442386 0.228967852 -0.160005581 0.046153468 -0.290770967 -0.572213576 -0.016008752	0.87499041 -0.042864639 0.767880069 1.344130614 -0.249131445 -1.0500764 0.243669905 0.974411905 0.063264056 -0.136951914	0.433535536 -0.123125919 0.235417278 -0.249621077 1.716085385 -0.1627212 1.539857423 0.690661819 -1.241621922 1.129696934	0.580231471 0.483643063 -1.193104653 -0.682215936 0.396295637 -0.321842979 -0.518790197 0.546625551 0.196304569 -0.016649978

	-0.477049623 0.525462018 0.1274532 0.078143188 -0.709741393	0.309008221 -0.050146333 -0.810071722 0.404572519 -0.13097956	0.491565171 0.462078407 0.469531478 -0.571378791 0.150105898	-0.060007992 -0.549113055 -0.161098071 -0.004044426 -0.368438927
40	0.609466599 -0.6031714 0.46852611 -0.536442386 0.228967852 -0.160005581 0.046153468 -0.290770967 -0.572213576 -0.016008752 -0.477049623 0.525462018 0.1274532 0.078143188 -0.709741393	0.87499041 -0.042864639 0.767880069 1.344130614 -0.249131445 -1.0500764 0.243669905 0.974411905 0.063264056 -0.136951914 0.309008221 -0.050146333 -0.810071722 0.404572519 -0.13097956	1.19951898 -0.211329335 0.662193805 0.031714849 0.095980585 0.438778503 -1.305423533 -0.787305274 -0.287355014 -0.085802356 -0.803962225 -0.077713255 -0.098157247 -0.171232971 0.058739928	0.610224203 0.766529211 0.771242853 -0.307373134 -0.154373438 0.659157234 0.473968563 -0.502184162 0.528767746 -0.153368417 0.020026638 0.282496822 -0.815778057 0.387452882 -0.378269759
41	1.204997283 -0.3445566 -0.144894378 -0.316556508 -0.153654299 -0.83550327 -0.488086043 -0.152512171 0.18895626 -0.01076018 0.45525814 0.169478155 0.328969133 -0.113853118 0.906692194	1.009840912 0.623986429 0.463197073 0.028957289 0.209581924 1.379231935 0.159897774 0.570597959 0.313039747 0.399191086 0.47528793 0.137215621 0.598525761 0.184586908 0.963614579	1.126136001 -0.813296666 1.559778026 0.275186699 0.480659032 -0.438424675 0.124733108 0.672062641 0.947290449 -0.069916767 0.619729685 0.023637436 0.609743565 0.209469546 0.421756553	0.451492142 1.313790459 0.305184551 1.180466277 -0.821346242 -0.554630725 0.460482597 -0.352165366 0.245972115 -0.954497493 -0.408464567 -0.147846496 0.115777102 -0.467117245 -0.430320909
42	1.204997283 -0.3445566 -0.144894378 -0.316556508 -0.153654299 -0.83550327 -0.488086043 -0.152512171	1.009840912 -0.623986429 0.463197073 0.028957289 -0.209581924 1.379231935 -0.159897774 0.570597959	0.912961435 1.214063776 -0.310024411 1.166282489 -0.129095913 -0.761481748 -0.172423317 -0.571851705	0.508940284 1.392461608 -0.198264133 -0.078343242 -0.822799329 -0.257197485 -0.250924358 0.08968462

	0.18895626 -0.01076018 0.45525814 0.169478155 0.328969133 -0.113853118 0.906692194	0.313039747 -0.399191086 0.47528793 0.137215621 -0.598525761 0.184586908 0.963614579	0.900025949 0.67273061 -0.484587431 -0.667415968 0.676819311 0.745209532 -0.305785599	0.214158521 -0.021624147 0.239551973 -0.414168053 -0.138795668 -0.544740376 0.602840644
43	0.94822965965383 0.35571736549154 0.56017492232801 0.22323148785224 0.50524103431389 1.09781733158854 0.22050116215594 0.31961820322990 1.22494947347600 0.34881455836098 0.29395087669690 0.29958516135702 1.74446271260758 0.20961323286336 0.87957924817543	0.844219072021390 0.261792887919564 1.140870458435975 0.278998228785538 0.118495685719871 0.356619136389493 0.548712567042617 1.226441127573077 0.774573337151300 1.146328697815626 0.492886918954835 0.765274946452773 0.076738307428775 1.222591755423508 0.448439105702886	1.15582788455621 0.97981845554675 1.36098113406196 0.44599004129647 0.08858126377920 0.16493261120999 0.02257365448577 0.44364083921229 0.27432349097104 0.12329563110261 0.35394135582023 0.29452350472621 0.13207676597539 0.88468908879446 0.2183124758898	0.301397807674438 1.365308731940880 0.822606371455456 0.707986788759551 -0.567996077200415 0.039448788833502 0.919493722694744 0.416878584696241 -0.175622157107086 0.810278469269319 -0.363943757064850 -0.283643776322044 0.469650120036344 0.354856238680317 -0.155215054666650
44	0.94822966 -0.355717365 -0.560174922 -0.223231488 -0.505241034 -1.097817332 0.220501162 -0.319618203 1.224949473 0.348814558 0.293950877 -0.299585161 -1.744462713 -0.209613233 -0.879579248	0.844219072 -0.261792888 1.140870458 0.278998229 -0.118495686 0.356619136 -0.548712567 -1.226441128 -0.774573337 1.146328698 0.492886919 -0.765274946 0.076738307 1.222591755 0.448439106	0.675248953 1.349217088 1.519742445 -0.46959721 -1.312338877 1.100377583 0.521728181 1.017987072 0.466413666 0.889066191 -0.386398812 -0.143917724 -0.00323813 -0.015210484 -0.355982123	0.356758292 -0.808696805 1.506392512 -0.169477287 0.315485811 -0.327083782 -0.643851776 0.05335999 0.383599827 -0.81899388 -0.237738064 -0.201612773 -0.423873428 0.408821552 0.227348684
	1.097287454 -0.112616337 -0.61174485 -0.313434388 -0.882036074 -1.100125281	1.202027553 -0.901404772 -0.230162547 -0.622601674 0.371287431 -0.154253989	1.158501026 -0.839689136 0.992607284 -0.477173828 0.673048701 0.107136335	0.251985407 1.259725571 0.073910364 1.098766508 -0.626020725 0.533162573

45	-0.474058564 -0.361390266 0.999169378 -0.676565301 0.160783269 -0.399697804 1.253001701 0.734849917 0.042131394	0.284952146 -0.001301041 -0.130735122 0.293358004 -0.243822405 0.827026597 0.028701464 0.737257785 -1.130701149	-0.50286872 -0.174616219 -0.334751629 -0.610298311 -0.167686276 0.270810206 -0.117023897 0.138256455 0.729546526	0.297637557 -0.179256668 -0.307316175 -0.782436004 -0.080847444 0.733106766 0.566515319 -0.514349034 0.020685386
46	1.097287454 -0.112616337 -0.61174485 -0.313434388 -0.882036074 -1.100125281 -0.474058564 -0.361390266 0.999169378 -0.676565301 0.160783269 -0.399697804 1.253001701 0.734849917 0.042131394	1.202027553 -0.901404772 -0.230162547 -0.622601674 0.371287431 -0.154253989 0.284952146 -0.001301041 -0.130735122 0.293358004 -0.243822405 0.827026597 0.028701464 0.737257785 -1.130701149	0.89781925 -0.078751218 0.629050713 0.099436937 -0.197478175 -0.234812669 -0.415331703 -0.471043849 -0.486019592 -0.692316915 0.708320154 -0.303002129 0.412810514 -0.850587757 0.568730061	0.288102696 0.220178204 -0.50077822 1.390547158 0.340619415 -0.374673632 -1.281113495 -2.200174349 0.110022353 0.050610517 0.595349973 0.506468132 0.06844144 0.456319312 0.438222827
47	0.987319844 1.181728564 -0.643181664 -0.556207116 0.856394083 -0.704465797 0.101163699 2.581496315 -0.173051685 0.34677847 0.033185023 -0.091273704 0.212756782 -0.128599372 -0.245342046	1.001908212 -0.887870717 -0.957381133 -0.9967634 0.333109647 -0.819502968 0.366326845 -0.080476703 0.590254 -0.166810362 0.532532381 -0.869023398 -0.114727352 -0.127350556 0.264565317	0.923223288 -0.081955752 0.647966086 -0.194572193 0.428660566 -0.187404894 -0.073242918 -0.349179877 -0.461769344 -0.790369593 1.081328446 -1.79107916 -1.094567066 0.731291753 -0.705308818	0.654235533 -1.153620774 0.763795511 -0.247876405 -0.743609383 0.153757345 -0.748112274 0.068115361 0.009598026 -0.206611211 -0.65133877 -0.218678863 -0.056339111 0.354210717 0.15373557
	0.987319844 1.181728564 -0.643181664 -0.556207116	1.001908212 -0.887870717 -0.957381133 -0.9967634	1.176609934 -0.050224273 0.700947242 -0.376722674	0.652613412 -0.056530619 -0.055566627 -1.035075554

48	0.856394083 -0.704465797 0.101163699 2.581496315 -0.173051685 0.34677847 0.033185023 -0.091273704 0.212756782 -0.128599372 -0.245342046	0.333109647 -0.819502968 0.366326845 -0.080476703 0.590254 -0.166810362 0.532532381 -0.869023398 -0.114727352 -0.127350556 0.264565317	-0.313136251 -0.020578459 -0.284193213 -0.315103634 -0.255006696 -0.293606723 0.338641244 0.035788182 -0.174630969 -0.398579676 0.063634039	0.463209401 0.459201484 -0.09624445 0.319652278 0.411549482 0.045860564 -0.276109453 0.291335502 -0.069546492 0.326874809 -0.165749762
49	0.784479900360469 0.988905580238417 0.802335369513598 3.021088162934430 0.373722627187449 0.282971035464056 0.134757117895743 0.534512056299478 0.430504562616473 0.053228297410699 0.163972294294209 0.215124812608135 0.115660017890874 0.523803096445683 0.346587718286950	0.948954958778602 -0.830004242269713 -0.977171648881453 -1.004650784527757 0.411048975360179 -0.857513697084904 0.235897839346851 -0.228158128794742 0.550898233442230 -0.170643847667863 0.612570806856270 -0.948951559668523 0.060593581320734 -0.103000112211789 0.145757804096509	2.279686624525802 1.769175400759388 1.567864671218294 0.130322971108677 0.323367863038119 0.077861315358890 0.948701209443424 1.286060832122776 0.167074778988977 0.704531400175523 0.172867226295075 0.669574660214841 0.011638424941306 0.046882071192845 0.395287222741864	0.598679224171008 1.032761626910642 -1.093519626689292 -0.348082235611550 0.381308810452548 0.224308828363666 -0.877250437447124 0.533654171630440 -0.036221446940856 -0.005093037959273 0.216964579870096 -0.423348827611075 -0.089834622092388 0.072203378020084 -0.091999038184555
50	0.7844799 -0.98890558 -0.80233537 3.021088163 -0.373722627 0.282971035 -0.134757118 0.534512056 -0.430504563 0.053228297 -0.163972294 0.215124813 -0.115660018 0.523803096 -0.346587718	0.948954959 -0.830004242 -0.977171649 -1.004650785 0.411048975 -0.857513697 0.235897839 -0.228158129 0.550898233 -0.170643848 0.612570807 -0.94895156 0.060593581 -0.103000112 0.145757804	2.146681808 -1.880963279 -1.581892699 0.192351394 -0.200702948 0.419755421 -1.138911194 1.426681264 -0.142293826 0.239024912 -0.104556868 0.051233954 -0.113031928 -0.016401479 -0.055249077	0.667981729744931 -1.007665495957589 -0.491354791871801 0.348465749108704 -0.925108504101625 0.325812377408817 -0.538110086839397 0.408550873324427 -0.142431946570796 0.191103591148273 -0.810770024070186 0.164607862626619 -0.036131554719983 -0.126550984389947 0.500753474435491

Autoriaus publikacijos magistro darbo tema
Straipsniai magistro(vaizdo atpažinimo) tema

Straipsnis : "The method of human-computer interaction based on hand gesture recognition.
Žurnalas: Electrical and control technologies ECT 2013 ISSN 1822-5934

Straipnis: "Gesture sign language recognition Method using Artificial Neural Networ, as a translator tool of deaf people" Žurnalas: Electrical and control technologies ECT 2014 ISSN 1822-5934

Straipsnis : "Automatic detection and tracking of embryo development" Žurnalas: Biomedical engineering 2014 ISSN 2029-3380