



KAUNO TECHNOLOGIJOS UNIVERSITETAS
FUNDAMENTALIŲJŲ MOKSLŲ FAKULTETAS
TAIKOMOSIOS MATEMATIKOS KATEDRA

Gintarė Keršulytė

**ŠIRDIES SIGNALŲ ANALIZĖS METODŲ
PAIEŠKA IR KŪRIMAS**

Magistro darbas

Vadovai
prof. dr. Z. Navickas
dr. L.Gargasas

KAUNAS, 2007



KAUNO TECHNOLOGIJOS UNIVERSITETAS
FUNDAMENTALIŲJŲ MOKSLŲ FAKULTETAS
TAIKOMOSIOS MATEMATIKOS KATEDRA

TVIRTINU
Katedros vedėjas
prof. dr. J.Rimas
2007 06 05

ŠIRDIES SIGNALŲ ANALIZĖS METODŲ
PAIEŠKA IR KŪRIMAS

Taikomosios matematikos magistro baigiamasis darbas

Vadovai

prof. dr. Z. Navickas
2007 06 05

dr. L. Gargasas
2007 06 05

Recenzentas

prof. J. Sapagovas
2007 06 05

Atliko

FMMM-5 gr. stud.
G. Keršulytė
2007 06 05

KAUNAS, 2007

KVALIFIKACINĖ KOMISIJA

Pirmininkas: Leonas Saulis, profesorius (VGTU)

Sekretorius: Eimutis Valakevičius, docentas (KTU)

Nariai: Algimantas Jonas Aksomaitis, profesorius (KTU)

Vytautas Janilionis, docentas (KTU)

Vidmantas Povilas Pekarskas, profesorius (KTU)

Rimantas Rudzkis, habil.dr., banko „NORD/LB“ vyriausiasis analitikas

Zenonas Navickas, profesorius (KTU)

Arūnas Barauskas, UAB „Elsis“ generalinio direktoriaus pavaduotojas

Keršulytė K. The retrieval and creation of methods to heart signal analysis: Master's work in applied mathematics / supervisor prof. dr. Z. Navickas; Department of Applied mathematics, Faculty of Fundamental Sciences, Kaunas University of Technology; dr. L. Gargasas, Institute of Cardiology, Kaunas University of Medicine. – Kaunas, 2007. – 70 p.

SUMMARY

A big part of heart disease diagnostics criteria is collected by registration and analysis of cardio signals that reflect the disturbances of the electric heart activity – electrocardiogram (ECG), changes of hemodynamic - impedance cardiograms (ICG) and mechanic activity - seismocardiogram (SCG). ECG analysis is generally applying in clinic practice, but usually in visual way only. Due to the development of the technologies, the bigger amount of data could be stored and more exact analysis of information could be carried out. Therefore, a solution of problem of effective diagnostics of heart diseases is the creation of new technologies for analysis of cardio signals. Previously Fourier series were applied to frequency analysis of ECG, but this method was not applied for estimation of ICG and SCG frequency characteristics. In this thesis the frequency analysis method was applied to three cardio signals, because they reflect the electrical and mechanical work of the human heart better as entirely ECG signal. The main aim of this work was to adapt Fourier transformation to assessing and comparing some characteristics of hereinbefore signals, such as coherence and classify two searching groups - “healthy” and “sick”. Results showed that rating of coherence and spectral analysis could be useful for rightly analyzing and classifying the searching groups.

TURINYS

ĮVADAS	9
1. BENDROJI DALIS	10
1.1 MEDICININĖ DALIS	10
1.1.1 KARDIOSIGNALAI	10
1.1.1.1 ELEKTROKARDIOGRAMA, JOS KILMĖ IR REGISTRACIJA.....	10
1.1.1.2 SEISMOKARDIOGRAMA, JOS KILMĖ IR REGISTRACIJA	13
1.1.1.3 IMPEDANSKARDIOGRAMA, JOS KILMĖ IR REGISTRACIJA.....	14
1.1.2 KARDIOSIGNALŲ ANALIZĖS METODAI	16
1.2 MATEMATINĖ DALIS	17
1.2.1 FURJĖ TRANSFORMACIJA IR JOS SAVYBĖS	17
1.2.1.1 FURJĖ TRANSFORMACIJA	17
1.2.1.2 DISKREČIOSIOS FURJĖ TRANSFORMACIJOS APIBRĖŽIMAS	21
1.2.1.3 GREITA FURJĖ TRANSFORMACIJA	23
1.2.2 PARABOLIŲ (SIMPSONO) FORMULĖ	24
1.2.3 KOHERENCIJA	26
1.2.4 DIRBTINIS NEURONINIS TINKLAS.....	28
1.2.5 BATERVORTO FILTRAI	29
2. TIRIAMOJI DALIS.....	32
2.1 DUOMENŲ PARUOŠIMAS DARBUI.....	32
2.2 SPEKTRINIS PLOTŲ PALYGINIMAS.....	32
2.3 POLIKARDIOSIGNALŲ KOHERENTIŠKUMO TYRIMAS.....	34
2.4 EKG, IKG IR SKG SIGNALŲ SPEKTRAI.....	40
DISKUSIJA	46
IŠVADOS	47
PADĖKA	48
LITERATŪRA.....	49
1 PRIEDAS Programos tekstas.....	51
2 PRIEDAS Straipsnis: Polikardiosignalų skleidimo Furjė eilutė savybės.....	58
3 PRIEDAS Straipsnis: Polikardiosignals Coherence Evaluation Results for Patients with Cardiopulmonary Diseases	61
4 PRIEDAS Straipsnis: Polikardiosignalų koherentiškumo tyrimas	66

PAVEIKSLŲ SĄRAŠAS

1 pav. Elektrokardiograma.....	10
2 pav. Sujaudinimo plitimas širdyje.....	11
3 pav. EKG bangų priklausomybė nuo sujaudinimo plitimo širdyje.....	11
4 pav. Einthoveno trikampis.....	12
5 pav. Unipolinės galūnių derivacijos remiantis Goldbergeriu.....	13
6 pav. EKG užrašymas pagal Wilsoną.....	13
7 pav. Seismokardiograma.....	14
8 pav. SKG formuotuvo struktūrinė schema.....	14
9 pav. Impedanskardiograma.....	15
10 pav. IKG formuotuvo struktūrinė schema.....	15
11 pav. $x_p(t)$ signalas.....	18
12 pav. Furjė spektrų, amplitudinio ir fazinio, grafikai.....	18
13 pav. Signalas $x(t)$, apibrėžtas baigtiniame intervale.....	19
14 pav. Aprašančių kompleksinių skaičių z dedamųjų poros: realioji dalis a bei menamoji b , arba amplitudė r ir kampas Θ	20
15 pav. Impulso (a) ir periodinio svyravimo (b) spektrai (c) ir (d).....	21
16 pav. Baigtinio ilgio ($t \in [t_0, t_6]$) diskrečiojo signalo periodinis pakartojimas, naudojamas diskrečiojoje Furjė transformacijoje.....	22
17 pav. GFT „išretinto“ laiko algoritmo realizavimo struktūrinė schema.....	24
18 pav. EKG dantelių priklausomybė nuo sujaudinimo plitimo širdyje.....	24
19 pav. x_1 ir x_2 signalų koherencija.....	27
20 pav. Dirbtinio neurono sandara.....	28
21 pav. Žemutinių dažnių filtro Batervorto aproksimavimo kreivės.....	29
22 pav. Duomenų paruošimo metodas vidF.....	32
23 pav. Duomenų paruošimo metodas Fvid.....	33
24 pav. EKG, SKG ir IKG kanalų R-R intervalų spektras.....	33
25 pav. EKG spektro plotų palyginimas.....	33
26 pav. IKG spektro plotų palyginimas.....	34
27 pav. SKG spektro plotų palyginimas.....	34
28 pav. „Sveikų“ žmonių kardiosignalų koherencija.....	35
29 pav. „Ligonių“ kardiosignalų koherencija.....	35
30 pav. „Ligonių“ koherencija.....	36
31 pav. Koherencijos plotai.....	36
32 pav. Plotų po koherencijos kreivėmis santykinis plotas, 0-10 Hz.....	37
33 pav. Plotų po koherencijos kreivėmis santykinis plotas, 11-35 Hz.....	37
34 pav. Plotų po koherencijos kreivėmis santykinis plotas, 36-50 Hz.....	37
35 pav. Neuroninis tinklas su 9 įėjimais.....	38
36 pav. „Sveikųjų“ klasifikavimo rezultatai, priklausomai nuo neuronų tinklo dydžio.....	39
37 pav. „Ligonių“ klasifikavimo rezultatai, priklausomai nuo neuronų tinklo dydžio.....	39
38 pav. Tiriamųjų „ligonių“ ir „sveikų“ klasifikavimo rezultatai.....	40
39 pav. Sinchroniškai užregistruotų signalų (EKG, IKG ir SKG) spektrai. Dažnių juostoje nuo 0 Hz iki 100 Hz.....	41
40 pav. Sinchroniškai užregistruotų signalų (EKG, IKG ir SKG) spektrai. Dažnių juostoje nuo 0 Hz iki 1 Hz.....	41
41 pav. Sinchroniškai užregistruotų signalų (EKG, IKG ir SKG) spektrai. Dažnių juostoje nuo 0 Hz iki 0.1 Hz.....	42

42 pav. Neuroninio tinklo požymių išrinkimas.....	42
43 pav. Neuroninis tinklas su 120 įėjimų	43
44 pav. „Ligonių“ klasifikavimo rezultatai, priklausomai nuo neuronų skaičiaus įėjimo sluoksnyje ...	44
45 pav. "Ligonių " klasifikavimas, priklausomai nuo neuronų skaičiaus tinkle.....	44
46 pav. „Sveikų“ klasifikavimo rezultatai, priklausomai nuo neuronų skaičiaus tinkle	45

LENTELIŲ SĄRAŠAS

Lentelė 1 Panaudotų neuroninių tinklų struktūros	38
Lentelė 2 Panaudotų neuroninių tinklų struktūros signalų spektrams klasifikuoti	43

IVADAS

Širdies ir kraujotakos ligų savalaikė ankstyva diagnostika yra pagrindinė amžiaus sveikatos apsaugos problema. Spartėjant gyvenimo ritmui ir kylant pragyvenimo lygiui, šios ligos sparčiai progresuoja. Širdies kraujagyslių ligų sukeltos mirtys sudaro daugiau nei 50 proc. visų mirčių Lietuvoje. Daugeliu atvejų žmonės nežino, kad serga kraujotakos ar širdies ligomis, ir todėl labai svarbu kuo anksčiau nustatyti susirgimus ir pradėti pacientų gydymą.

Iš šiame darbe analizuojamų signalų - elektrokardiogramos (EKG), impedanskardiogramos (IKG) ir seismokardiogramos (SKG) - tik EKG tyrimas yra plačiai naudojamas klinikinėje praktikoje, nustatant širdies ritmo ir laidumo sutrikimus bei išeminius širdies pokyčius, tarp kurių ir miokardo infarktą. EKG dažniausiai analizuojama vizualiniu būdu, ir tik nuo praeito dešimtmečio pradžios buvo sukurtos ir pradėtos taikyti kompiuterinės EKG analizės sistemos, kurių daugumos sprendimo priėmimo algoritmai yra euristiniai ir sukurti imituojant gydytojo eksperto atliekamą vizualinę EKG analizę, ir tik atskiri specifiniai, kaip skilvelių vėlyvų potencialų, T bangos alternansų analizės algoritmai sukurti taikant šiuolaikines signalų analizės matematinės metodikas.

Tobulėjant skaičiavimo technologijoms atsiranda galimybė kaupti vis didesnius kiekius informacijos bei atlikti tikslesnę duomenų analizę. Naudojantis technikos laimėjimais tikslinga kurti EKG, SKG ir IKG specializuotus apdorojimo algoritmus, kurie palengvintų ir pagreitintų diagnozės nustatymą.

Šis magistro darbas yra skirtas naujų širdies signalų metodų paieškai ir kūrimui. Pagrindinės iškeltos magistro darbo užduotys:

- Trijų sinchroniškai užregistruotų signalų spektrinių dedamųjų palyginimas.
- Koherentiškumo tyrimas.
- Sukurti algoritmus, naudojant naujai sudarytus procesų sąsajas nusakančius dydžius, klasifikuojančius tiriamųjų grupes, t. y. sveikus asmenis bei sergančius išemine širdies liga su hipertenzija plaučių arterijoje.
- Tyrimų algoritmų realizavimas MatLab aplinkoje.

Magistro darbą sudaro du pagrindiniai skyriai. Pirmame skyriuje pateikiama trumpa bendra informacija apie kardiosignalus, jų prigimtį bei registravimo technologijas. Matematinėje dalyje aptariama Furjė transformacija, parabolių formulė, neuroninių tinklų konstravimo algoritmas, Batervorto filtras ir paaiškinama koherentiškumo sąvoka. Paskutiniame skyriuje yra pateikiami eksperimentų rezultatai ir išvados.

1. BENDROJI DALIS

1.1 MEDICININĖ DALIS


Skyriuje pateikiama trumpa bendra informacija apie kardiosignalus, jų prigimtį bei registravimo technologijas. Taip pat aptarsime matematinius metodus ir modelius, kurie naudojami kardiosignalų analizei Lietuvoje ir pasaulyje.

1.1.1 KARDIOSIGNALAI

Kardiosignalai atspindi širdyje vykstančius elektrinius bei mechaninius procesus. Elektrinius procesus registruoja elektrokardiograma (EKG), tuo tarpu seismokardiograma (SKG) registruoja susitraukinėjančios širdies sukeliamas bangas, kurios persiduoda į krūtinės sienelę. Impedanskardiograma (IKG) registruoja kūno varžos pokyčius, atsirandančius širdies sistolės ir diastolės metu, todėl pagal šiuos pokyčius galima įvertinti kai kurias širdies hemodinamines charakteristikas: širdies sistolės metu išmetamo kraujo tūrį ir etc.. Visi trys sinchroniškai užregistruoti signalai neša skirtingą informaciją, tačiau jie yra vienos sistemos dalis, kartu parodanti ir informuojanti apie žmogaus sveikatos būseną.

1.1.1.1 ELEKTROKARDIOGRAMA, JOS KILMĖ IR REGISTRACIJA

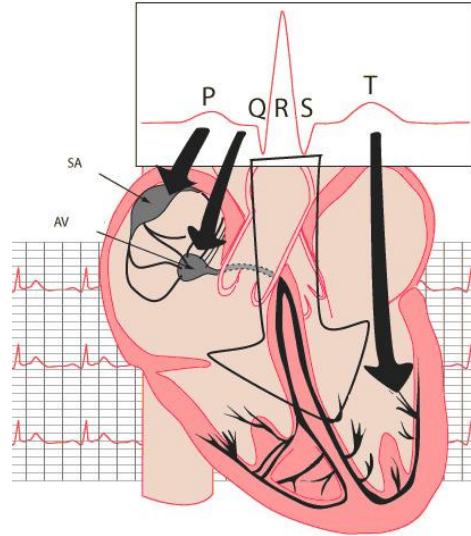
Elektrokardiograma (EKG) registruoja širdies elektrinius reiškinius, kurie per skystą ir laidžią vidinę terpę, silpnėdami išplinta į kūno paviršių (1 pav.). Signalai registruojami kūno paviršiuje naudojami diagnozuoti širdies būklę. Kiekviena ląstelė širdyje yra dipolio vektorius, turintis kryptį ir dydį. Kiekvienu laiko momentu visų širdies skaidulų vektoriai sumuojasi ir sudaro suminį dipolio vektorių [1].



1 pav. Elektrokardiograma


Širdžiai kaip ir siurblio funkcionavimui svarbiausia, kad skirtingos dalys susitrauktų laiku ir nuosekliai. Šis nuoseklumas yra kontroliuojamas elektrinių signalų. Signalas prasideda širdies dalyje,

atsakingoje už širdies darbo ritmą, vadinamu sinusiniu ar sinoatrialiniu mazgu (SA), besirandančiu prieširdyje (2 pav.). SA mazgas sudarytas iš stimuliuojančių skaidulų, kurių dažnis yra reguliuojamas autonominės nervų sistemos. Širdies raumuo yra sudarytas iš elektriškai viena su kita sujungtų skaidulų. Širdies skaidulų audinys tarp skilvelio ir prieširdžio sulaiko visas elektrines komunikacijas, išskyrus atrioventrikulinį (AV) mazgą, kur signalai yra uždeljami [1].



2 pav. Sujaudinimo plitimas širdyje


Kai abu prieširdžiai būna sujaudinti, tarp jų atsiranda potencialų skirtumas, o suminis vektorius tampa lygus nuliui. P banga registruoja sujaudinimo plitimą prieširdžiais (3 pav., a).



3 pav. EKG bangų priklausomybė nuo sujaudinimo plitimo širdyje


Elektrinis sujudinimas iš prieširdžių į skilvelius gali plisti tik per atrioventrikulinį mazgą (3 pav., b), nes kitas prieširdžių ir skilvelių dalis skiria nedirgus jungiamasis audinys. PQ segmento metu elektrinis sujudinimas plinta atrioventrikuliniu mazgu ir atrioventrikuliniu pluoštu (3 pav., c). Skilvelių miokardo Q banga parodo skilvelių miokardo sujudinimo pradžią. Susidaręs suminis vektorius būna mažas ir dažniausiai nukreiptas link skilvelių pagrindo. Bangai plintant skilvelių miokardu ir didėjant miokardo masei, integralinis vektorius didėja – registruojama R banga, kuri charakterizuoja sujudinimo plitimo kryptį skilveliuose (3 pav., d). Skilvelių sujudinimas plinta iš vidaus į išorę (3 pav., e, f). Vėliausiai sujudinami subepikardiniai sluoksniai kairiojo skilvelio pagrinde ir registruojama S banga (3 pav., g). ST segmento atveju abu prieširdžiai yra sujudinti, o suminis vektorius tampa lygus nuliui. Paskutinė T banga registruoja skilvelių miokardo repoliarizaciją (3 pav., h) [1].

Elektrokardiogramoje yra taikomos bipolinės ir unipolinės EKG derivacijos. Užrašant bipoliniu būdu, matuojamas potencialų skirtumas tarp dviejų aktyvių elektrodų. Unipolinio užrašymo metu naudojamas vienas bendras neaktyvus elektrodas, kurio atžvilgiu matuojamas aktyvaus elektrodo potencialas. Pagal elektrodų dėjimo vietas yra skiriamos galūnių ir krūtinės derivacijos. Galūnių derivacijos yra skirstomos į bipolines (I, II, III remiantis Einthovenu) (4 pav.) ir unipolines (aVR, aVL, aVF remiantis Goldbergeriu) (5 pav.). Dažniausiai, kaip ir šio tyrimo metu, taikomas EKG užrašymas remiantis Einthovenu. Šio užrašymo metu aktyvieji elektrodai tvirtinami prie dešinės rankos, kairės rankos ir kairės kojos, o prie dešinėsios kojos prijungiamas įžeminimo elektrodas. Užrašymo ašys sudaro Einthoveno trikampio kraštines, kuriose projektuojasi suminis vektorius, susidarantis jaudinimui plintant širdyje.




4 pav. Einthoveno trikampis

Visų derivacijų užrašomų EKG bangų amplitudė priklauso nuo suminio vektoriaus projekcijos derivacijos ašyje. Jaudinimui plintant širdies viršūnės link, susidaręs maksimalus suminis vektorius projektuojasi derivacijų ašyse skirtingai.



5 pav. Unipolinės galūnių derivacijos remiantis Goldbergeriu

Užrašant derivacijas remiantis Goldbergeriu, dviejų galūnių elektrodai sujungiami į indiferentinį elektrodą, kurio atžvilgiu matuojamas potencialų skirtumas aktyviuoju elektrodu nuo trečios galūnės (5 pav.). Šiuo metodu užrašomi didesnės amplitudės potencialai, negu indiferentinio elektrodo atžvilgiu. Derivacijos aVR aktyvusis elektrodas prijungiamas prie dešinės, derivacijos aVL – prie kairės rankos ir derivacijos aVF – prie kairės kojos (5 pav.).




6 pav. EKG užrašymas pagal Wilsoną

Unipolinės krūtinės derivacijos užrašomos remiantis Wilsonu. ($V_1 - V_6$) Jomis užrašomi suminio vektoriaus kitimai tik horizontalioje plokštumoje. Užrašant remiantis Wilsonu, trijų galūnių elektrodai sujungiami į indiferentinį elektrodą, o aktyvieji elektrodai dedami prie krūtinės laštos sienelės tam tikrų taškų (6 pav.). Remiantis susitarimu, QRS komplekso teigiama banga žymima R, o neigiama banga prieš R bangą Q, po R bangos – S banga.

1.1.1.2 SEISMOKARDIOGRAMA, JOS KILMĖ IR REGISTRACIJA


Seismokardiografija (SKG) yra neinvazinė technologija, skirta registravimui ir analizei širdies virpesių, įgalinančių atspindėti ir įvertinti širdies kontrakciją. Seismokardiograma registruoja ir matuoja bangas, persiduodančias į krūtinės sienelę, kurias sukelia judanti širdis (7 pav.).



7 pav. Seismokardiograma

SKG bangos koreliuoja su skilvelių sistole, ankstyvu diastoliniu skilvelių prisipildymu bei prieširdžių sistole. Ramybės būsenoje registruojamoje SKG galima nustatyti kreivės formos variantą, kuris pastebimai pakinta įvairių kairio skilvelio funkcijos sutrikimų atvejais, kurie susiję su kairio skilvelio pakitimu. Todėl šie pastebėjimai leidžia manyti, kad SKG gali būti naudingas įrankis surandant širdies susirgimus, apsprendžiančius kairio skilvelio veiklos sutrikimus. Apie širdies ligas iš SKG daugiausia informacijos gaunama, kai analizuojami pokyčiai po fizinio krūvio atsistatymo periode, lyginant šiuos pokyčius su ramybės būsenos SKG parametrais, nes seismokardiograma registruoja kūno ar jo dalių poslinkius kaip atsaką į širdies veiklą.


SKG registracijos struktūrinė schema pateikta 8 pav. SKG matavimui buvo panaudotas Kauno technologijos universiteto specialistų sukurtas piezoelektrinis keitiklis (PK). SKG signalas iš PK paduodamas į diferencinį stiprintuvą (DS). Sustiprintas SKG signalas iš DS išėjimo paduodamas į įtampos stiprintuvą (ITS). ITS praleidžiamų dažnių juosta yra lygi nuo 0,5 Hz iki 100 Hz. ITS schemeje yra stiprinimo koeficiento perjungiklis, su kuriuo įtampos stiprinimo koeficientas keičiamas santykiu 1:1, 1:2, 1:4 ir 1:8. ITS schemos išėjime galutinai suformuotas SKG signalas toliau paduodamas į aparatūros pagrindinę dalį įvedimui į asmeninį kompiuterį (AK).



8 pav. SKG formuotuvo struktūrinė schema

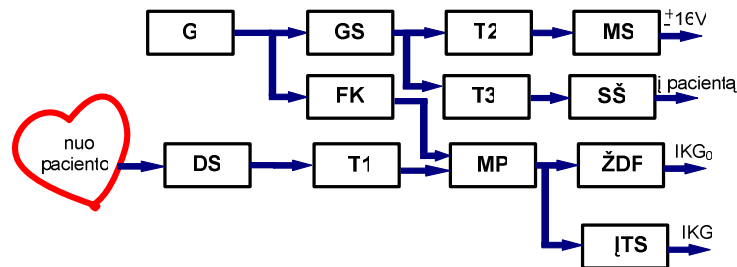
1.1.1.3 IMPEDANSKARDIOGRAMA, JOS KILMĖ IR REGISTRACIJA

Impedansinė kardiografija (IKG) naudojama kaip nežalingas paciento sveikatai ir nebrangiai kainuojantis metodas širdies išmetamojo kraujo tūriui ir kitiems hemodinaminiams rodikliams vertinti. Kadangi IKG (9 pav.) pagalba įmanoma įvertinti širdies smūginį tūrį kiekvieno ciklo metu, susidaro galimybės nepertraukiamai monitoriuoti sistolinio laiko intervalus, smūginį tūrį bei sisteminių kraujagyslių sistemos rezistentiškumą, kuris įvertinamas pagal IKG ir neinvazinio kraujo spaudimo matavimo duomenis. Tokiu būdu, IKG kaip hemodinaminių širdies parametrų monitoriavimo metodo vertė ypač reikšminga dozuoto fizinio krūvio diagnostikos efektyvumo didinimui.



9 pav. Impedanskardiograma

IKG registravimo struktūrinė schema pateikta 10 pav. Generatorius (G) generuoja stabilios amplitudės 80kHz dažnio signalą, kuris paduodamas į galios stiprintuvą (GS) bei į fazės koregavimo schemą (FK). GS išėjimo signalas paduodamas į aukšto dažnio transformatorius T2 ir T3. Transformatoriaus T3 antrinės apvijos signalas paduodamas į srovės šaltinį (SŠ), prie kurio išėjimo prijungiami išoriniai tetrapoliarinės IKG diržai-elektrodai. SŠ išduoda 2,5 mA dydžio IKG matavimo srovę, kuri teka per paciento kūno matuojamą impedansą. Šios srovės sukelta įtampa ant matuojamo impedanso nuimama su kitais dviem diržais-elektrodais ir paduodama į diferencialinį stiprintuvą (DS). Kadangi matavimo srovė yra stabili, DS įėjimo signalo amplitudė yra tiesiai proporcinga matuojamam impedansui. DS sustiprintas išėjimo signalas nuo aukšto dažnio transformatoriaus T1 antrinės apvijos paduodamas į signalų multiplekserį (MP). MP darbą valdo FK schemos išėjimo signalas. FK schemos parametrai parinkti taip, kad MP išėjimo signalas būtų proporcingas matuojamos paciento varžos aktyvinei dedamajai.



10 pav. IKG formuotuvo struktūrinė schema

MP schemos išėjimo signalas paduodamas į žemų dažnių filtrą (ŽDF) bei įtampos stiprintuvą (ITS). ŽDF schemos maksimalus praleidžiamas dažnis lygus 3,3 Hz, o jo įtampos stiprintuvo koeficientas parinktas toks, kad 1 V įtampa jo išėjime atitinka matuojamai paciento varžai. ITS schemos išėjime išduodamas impedanso kardiogramos kintamos dedamosios signalas. Aukšto dažnio signalas nuo transformatoriaus T2 antrinės apvijos paduodamas į maitinimo schemą (MS). MS išėjime išduodamos stabilizuotos 13 V dydžio įtampos DS ir SŠ schemų maitinimui.

1.1.2 KARDIOSIGNALŲ ANALIZĖS METODAI

Iš šiame darbe analizuojamų kardiosignalų (EKG, IKG, SKG) tik EKG tyrimas yra plačiai naudojamas klinikinėje praktikoje, nustatant širdies ritmo ir laidumo sutrikimus bei išeminius širdies pokyčius, tarp kurių ir miokardo infarktą. EKG dažniausiai analizuojama vizualiniu būdu, ir tik nuo praeito dešimtmečio pradžios buvo sukurtos ir pradėtos taikyti kompiuterinės EKG analizės sistemos, kurių daugumos sprendimo priėmimo algoritmai yra euristiniai ir sukurti imituoju gydytojo eksperto atliekamą vizualinę EKG analizę, ir tik atskiri specifiniai, kaip skilvelių vėlyvų potencialų, T bangos alternansų analizės algoritmai sukurti taikant šiuolaikines signalų analizės matematinės metodikas.

Dar 1990 metais D.M.Salerno ir J.M.Zaneti [2] pasiūlė naują seismokardiografijos metodą, atspindintį mechaninę širdies veiklą ir skirtą vienos iš dažniausių širdies patologijų – išeminės širdies ligos diagnostikai. R.A.Wilson su bendraautorais, naudodami penkių medicininių centrų duomenis, SKG diagnostinę vertę nustatant išeminę širdies ligą palygino su EKG. Šio tyrimo rezultatai leidžia daryti išvadą, kad SKG diagnostinis efektyvumas buvo didesnis (74proc.) nei krūvio metu registruotos EKG (55proc) [3]. D. M. Salerno su bendraautorais tyrė SKG koronarinės angioplastikos metu, kai balionėliu tam tikram laikotarpiui uždarius širdies kraujagyslės spindį, išsivysto miokardo išemija ir blogėja širdies susitraukimo galia. SKG pokyčiai buvo tris kartus ryškesni nei EKG ir išliko po procedūros vidutiniškai penkias minutes, kai EKG pokyčiai išnyko tuoj pat baigus procedūrą [4].

Tobulėjant skaičiavimo technologijoms atsiranda galimybė kaupti vis didesnius kiekius informacijos bei atlikti tikslesnę duomenų analizę. H.H.Woltjer ir bendraautorai [5], apžvelgdami IKG metodą teigia, kad reikalingi tolimesni šio metodo tyrimai tikslu išsiaiškinti IKG kilmę, pagerinti registravimo kokybę, parenkant šiam tikslui optimalius elektrodus, sumažinti kvėpavimo įtaką į IKG, išsiaiškinti kraujo varžos dydžio įtaką į impedansinį signalą, palyginti šiuo metu egzistuojančius IKG registravimo metodus toje pačioje tiriamųjų grupėje ir išrinkti optimaliausius. Kompiuterinė impedanskardiogramos analizė pradėta naudoti ir kurti prieš maždaug 20 metų, o šiuo metu yra jau kelios firmos, kaip CardioDynamics, Inmed ir kitos, kurios gamina komercines IKG kompiuterinės analizės sistemas, sudarančias galimybes automatiškai registruoti bei analizuoti IKG. Šios analizės rezultatas yra įvairūs širdies kraujagyslių sistemos hemodinamiką nusakantys parametrai: sistolinis ir minutinis širdies tūris, širdies indeksas, širdies kontraktiškumo koeficientas bei kiti svarbūs ir reikalingi diagnostikai širdies hemodinamikos parametrai.

Lietuvoje kompiuterinės kardiosignalų analizės metodai jau daugiau nei 30 metų kuriami KMU Kardiologijos instituto Kardiologinių tyrimų automatizacijos laboratorijoje. Sukurta keletas techninės ir algoritminės programinės įrangos versijų EKG registravimui ir analizei ramybės bei funkcinio mėginių metu. Be to, kuriama taip pat polikardiosignalų (EKG, IKG, SKG) analizės sistema, sudaryta

iš kardiosignalų registravimo aparatūros ir signalų analizės algoritmų ir programų, skirtų signalų įvedimui, filtravimui, charakteringų taškų radimui, parametrų skaičiavimui bei kompiuterinei širdies kraujagyslių sistemos susirgimų diagnostikai [6]. Laboratorijoje pradėtos kurti metodikos, skirtos širdies kraujagyslių sistemos kompleksiskumui vertinti, taikant kardiosignalų analizei netiesinės fraktalinės analizės, chaoso ir kompleksiskumo teorijų metodus. Tikimasi, kad tai leis atskleisti širdies signaluose esančią diagnostinę informaciją, kuri iki šiol buvo nepasiekiamo, kai kardiosignalų analizei buvo taikomi tiesinės analizės ar vizualiniai euristiniai metodai.

1.2 MATEMATINĖ DALIS

Signalai formuojami iš nuolatinės srovės ar įtampos, jų svyravimų, impulsų. Tai informacijos nešikliai, jie tarsi švarus paviršius, paruoštas reikiamiems duomenims užrašyti. Iš signalo, kaip laiko funkcijos, aprašo galima nustatyti tokius parametrus kaip trukmė, galia, energija [7]. Tačiau ne mažiau svarbios yra signalo dažninės charakteristikos. Norint jas išryškinti, naudojama spektrinė signalo aprašymo forma, t.y. tokia, kurioje figūruoja signalo dažninės dedamosios (harmonikos), signalo spektro plotis ir pan. Dažninėms charakteristikoms atvaizduoti naudojamos signalų spektrinės funkcijos – Furjė transformacijos. Furjė transformacijos galimybės apdorojant skaitmeninius signalus yra efektyvus skaitmeninės informacijos saugojimas, kodavimas bei perdavimas, skaitmeninių filtrų projektavimas ir etc. Šiame skyriuje aptarsime Furjė transformaciją, parabolų formulę, neuroninius tinklus, Batervorto filtrus ir koherentiškumą.


1.2.1 FURJĖ TRANSFORMACIJA IR JOS SAVYBĖS

1.2.1.1 FURJĖ TRANSFORMACIJA

Furjė transformacija yra viena iš transformacijų, turinti specifines, praktikoje naudingas bazines funkcijas. Tarkime, turime signalą $x(t)$, apibrėžtą:

$$x(t) = \begin{cases} A, & -\frac{\tau}{2} \leq t \leq \frac{\tau}{2} \\ 0 & \end{cases}$$

Tarkime, kad $x_p(t)$ yra signalo $x(t)$ T-periodinis tęsinys ($T > \tau$) (11 pav.).



11 pav. $x_p(t)$ signalas

Signalas $x_p(t)$ kompleksinė Furjė eilutė turės išraišką :


$$x_p(t) = \frac{1}{T} \sum_{n=-\infty}^{\infty} c_n \cdot e^{in\omega_0 t} \quad (1)$$

Rasime amplitudinį ir fazinį Furjė spektrus:

$$c_n = \int_{-\frac{\tau}{2}}^{\frac{\tau}{2}} A e^{-in\omega_0 t} dt = \frac{2A}{n\omega_0} \cdot \left(\frac{e^{i\frac{n\omega_0\tau}{2}} - e^{-i\frac{n\omega_0\tau}{2}}}{2i} \right) = A\tau \cdot \left(\frac{\sin \frac{n\omega_0\tau}{2}}{\frac{n\omega_0\tau}{2}} \right), n = 0, \pm 1, \pm 2, \dots \quad (2)$$

kur $\omega_0 = \frac{2\pi}{T}$ yra kampinis dažnis.

Žemiau pateikti abiejų Furjė spektrų, amplitudinio ir fazinio, grafikai:



12 pav. Furjė spektrų, amplitudinio ir fazinio, grafikai

Iš grafikų matyti, kad intervalų tarp gretimų $p_n = |c_n|$ ilgis lygus pagrindiniam kampiniam dažniui

$\omega_0 = \frac{2\pi}{T}$ ir fazinis spektras įgyja tik tris reikšmes $-0, \pi$ ir $-\pi$. Tarkime, kad $T \rightarrow \infty$.

Impulsų seka išsigimsta į vieną atskirą impulsą, kuris atitinka aperiodinę funkciją $x(t)$. Iš amplitudinio spektro galima matyti, kad didėjant T , spektrinės linijos susispaudžia, ir ribiniu atveju gaunama tolydi funkcija $\frac{\sin x}{x}$. Panagrinėkime kompleksinį Furjė koeficientą c_n . Kai $T \rightarrow \infty$, pagrindinis kompleksinis dažnis $w_0 = \frac{2\pi}{T}$ tampa lygus kampinio dažnio diferencialui, o $nw_0 = n\frac{2\pi}{T}$ įgyja visas reikšmes tarp $-\infty$ ir $+\infty$, kai n kinta $-\infty$ iki $+\infty$, t.y. tampa tolydžiu kampiniu dažniu w_0 . Vadinasi iš (2) išraiškos, gauname:

$$\lim_{T \rightarrow \infty} c_n = \int_{-\infty}^{+\infty} x(t) \cdot e^{-iwt} dt \quad (3)$$

Dešinioji (3) išraiškos pusė nusako funkcijos $x(t)$ Furjė transformaciją [8], kurią pažymėsime $F_x(w)$, t.y.

$$F_x(w) = \int_{-\infty}^{+\infty} x(t) \cdot e^{-iwt} dt \quad (4)$$

Panagrinėsime (1) išraiškos ribą, kai $T \rightarrow \infty$:

$$x_p(t) = \frac{1}{T} \sum_{n=-\infty}^{\infty} c_n \cdot e^{inw_0 t} = \frac{1}{2\pi} \sum_{n=-\infty}^{\infty} c_n \cdot e^{inw_0 t} w_0$$

Kai $T \rightarrow \infty$, harmonikų sumavimą pastarojoje išraiškoje galima pakeisti integravimu intervale $(-\infty, +\infty)$ [8], t.y.


$$\lim_{T \rightarrow \infty} x_p(t) = x(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} F_x(w) \cdot e^{-iwt} dw \quad (5)$$

Ši išraiška vadinama funkcijos $F_x(w)$ atvirkštine Furjė transformacija [8]. Norint, kad egzistuotų funkcijos $x(t)$ Furjė transformacija, pakanka, kad apriorinė funkcija $x(t)$ būtų absoliučiai integruojama,

$$\text{t.y. } \int_{-\infty}^{+\infty} |x(t)| dt < +\infty$$

Nustatysime Furjė transformacijos ryšį su Furjė eilute. Imkime signalą, apibrėžtą baigtiniame intervale

$$\left(-\frac{L}{2}, \frac{L}{2}\right) \quad (13 \text{ pav.})$$



13 pav. Signalas $x(t)$, apibrėžtas baigtiniame intervale

Atsižvelgdami į (4) išraišką, turime

$$F_x(w) = \int_{-\frac{L}{2}}^{\frac{L}{2}} x(t) \cdot e^{-iwt} dt$$

Pakeitę šioje išraiškoje w į nw_0 , t.y. imdami diskrečias w reikšmes, tolygiai išsidėsčiusias dažnių ašyje, gauname:

$$F_x(nw_0) = \int_{-\frac{L}{2}}^{\frac{L}{2}} x(t) \cdot e^{-inw_0 t} dt = \int_L x(t) \cdot e^{-inw_0 t} dt, n = 0, \pm 1, \pm 2, \dots; w_0 = \frac{2\pi}{L}$$


Kita vertus, pasinaudoję (1) ir (2) išraiškomis, užrašome:

$$x(t) = \frac{1}{L} \sum_{n=-\infty}^{\infty} c_n \cdot e^{inw_0 t}$$

$$c_n = \int_L x(t) \cdot e^{-inw_0 t} dt, n = 0, \pm 1, \pm 2, \dots$$


Taigi, galime daryti išvadą, kad jeigu signalas $x(t)$ apibrėžtas baigtiniame laiko intervale L , tai jo Furjė transformacija $F_x(w)$ taškuose, tolygiai išsidėsčiusiose w ašyje atstumu $\frac{2\pi}{L}$ vienas nuo kito, tiksliai nusakoma Furjė eilutės koeficientais.

Kompleksinį skaičių $z=a+ib$ galima interpretuoti kaip vektorių dvimatėje erdvėje, kurios baziniai vektoriai – realusis ir menamasis vienetai (14 pav.). Kaip vienareikšmiškai kompleksinį skaičių aprašome jo realiąja ir menamąją dedamosiomis a ir b , taip jį galime aprašyti ir kitomis dviem dedamosiomis: amplitudė r bei faze (kampu) Θ . Furjė transformacijos amplitudės dedamoji vadinama signalo spektru.



14 pav. Aprašančių kompleksinį skaičių z dedamųjų poros: realioji dalis a bei menamoji b , arba amplitudė r ir kampas Θ

Pateiksime keletą spektrų pavyzdžių. Impulso spektras yra pastovus visame dažnių diapazone. Periodiškai svyruojančiojo signalo spektras yra smailės formos. Smailės padėtis nurodo svyravimo dažnį, o smailės amplitudė atspindi svyravimo amplitudę (15 pav.).




15 pav. Impulso (a) ir periodinio svyravimo (b) spektrai (c) ir (d)

Signalų spektras yra simetriškas viduriniojo taško atžvilgiu, todėl užtenka nagrinėti tik pirmąją spektro pusę. Taigi, nors 15 paveikslo (d) dalyje (periodinio signalo spektre) matome dvi smailės, tačiau jos abi atitinka tą pačią dažnuminę dedamąją. Jeigu nagrinėjame laiko intervale tilptų tikslus periodų skaičius ir diskretizavimo dažnis būtų pakankamai didelis – smailės spektre būtų siauros, o jų plotis būtų artimas vienam taškui. Dėl netikslaus periodinio signalo periodų skaičiaus, patenkančio į nagrinėjamąjį intervalą ir nedidelio diskretizavimo dažnio svyravimą atitinkanti smailė spektre paplatėja.

1.2.1.2 DISKREČIOSIOS FURJĖ TRANSFORMACIJOS APIBRĖŽIMAS

Realiesiems diskrečiojo laiko signalams nagrinėti geriau tinka diskrečioji Furjė transformacija (DFT). Realieji signalai būna baigtinio ilgio, traktuojamo kaip diskrečiojo laiko periodinio signalo periodas (16 pav.).



16 pav. Baigtinio ilgio ($t \in [t_0, t_6]$) diskrečiojo signalo periodinis pakartojimas, naudojamas diskrečiojoje Furjė transformacijoje

Imkime seką $\{X(m)\}$, kai $X(m)$, $m=0,1,\dots,N-1$, yra realieji arba kompleksiniai skaičiai. Sekos $\{X(m)\}$ diskrečioji Furjė transformacija (DFT) apibrėžiama [8]:

$$C_x(k) = \frac{1}{N} \sum_{m=0}^{N-1} X(m) \cdot W^{km} = \frac{1}{N} [X(0) + X(1) \cdot W + X(2) \cdot W^{2k} + \dots + X(N-1) \cdot W^{(N-1)k}] \quad (6)$$

čia $W = e^{-j\frac{2\pi}{N}}$, $i^2 = -1$, $k = 0,1,\dots,N-1$.

Rodiklinės funkcijos W^{km} yra ortogonalios, t.y. tenkina sąlygą

$$\sum_{m=0}^{N-1} W^{km} \cdot W^{-lm} = \begin{cases} N \\ 0 \end{cases} \quad (7)$$

t.y. N , kai $(k-l)$ lygus 0 arba yra kartotinis skaičius N , o visais kitais atvejais – lygus 0 . Iš (6) išraiškos turime:

$$\sum_{m=0}^{N-1} C_x(k) \cdot W^{-km} = \frac{1}{N} \sum_{m=0}^{N-1} W^{-km} [X(0) + X(1) \cdot W^k + X(2) \cdot W^{2k} + \dots + X(N-1) \cdot W^{(N-1)k}]$$

Įvertinę ortogonalumo (7) sąlygą, iš pastarosios lygybės gauname atvirkštinę diskrečiąją transformaciją (ADFT):

$$X(m) = \sum_{k=0}^{N-1} C_x(k) \cdot W^{-km}, m = 0,1,\dots,N-1 \quad (8)$$

Kadangi (6) ir (8) išraiškos sudaro transformacijų porą:

$$C_x(k) = \frac{1}{N} \sum_{m=0}^{N-1} X(m) \cdot W^{km} = \frac{1}{N} [X(0) + X(1) \cdot W + X(2) \cdot W^{2k} + \dots + X(N-1) \cdot W^{(N-1)k}]$$

$$X(m) = \sum_{k=0}^{N-1} C_x(k) \cdot W^{-km}, m = 0,1,\dots,N-1$$

tai duomenų sekos $\{X(m)\}$, kai $X(m)$, $m=0,1,\dots,N-1$, vaizdavimas, panaudojant rodiklines funkcijas yra vienintelis.

1.2.1.3 GREITA FURJĖ TRANSFORMACIJA

Tarkime, diskretizavę signalą $x(t)$ su apribota dažnių juosta, gavome duomenų vektorių $X = (X(0)X(1)\dots X(N-1))^*$, kur $*$ žymi transponavimo veiksmą. Tiesioginė DFT šiam vektoriui nusakoma išraiška:

$$C_x(k) = \frac{1}{N} \sum_{m=0}^{N-1} X(m) \cdot W^{km}$$

kur $W = e^{-i\frac{2\pi}{N}}$, yra periodo 2π periodinė funkcija, $k=0,1,\dots,N-1$. Reikia pastebėti, kad praktinis šios transformacijos panaudojimas ribotas. Viena iš priežasčių – laiko sąnaudos, susietos su DFT koeficientų apskaičiavimu, ypač, kai N yra pakankamai didelis skaičius ($N \approx 2^{20}$). Ieškomas greitas DFT skaičiavimo algoritmas, vadinamas greita Furjė transformacija (GFT).

Kadangi $N = 2^r$, tai $X(m)$ išskaidome į 2 lygias dalis, sudarytas iš lyginių ir nelyginių atskaitų [9].

$$C_x(k) = \sum_{lyg} X(m) \cdot W^{km} + \sum_{nelyg} X(m) \cdot W^{km}$$

Pažymėję, kad lyginius $m=2n$, o nelyginius $m=2n+1$, gauname,

$$C_x(k) = \sum_{n=0}^{\frac{N}{2}-1} X(2n) \cdot W^{2nk} + \sum_{n=0}^{\frac{N}{2}-1} X(2n+1) \cdot W^{(2n+1)k} = \sum_{n=0}^{\frac{N}{2}-1} X(2n) \cdot W^{2nk} + W^k \sum_{n=0}^{\frac{N}{2}-1} X(2n+1) \cdot W^{2nk}$$

Kadangi $W^2 = e^{-i\frac{2\pi}{N}2} = e^{-i\frac{2\pi}{N/2}} = W_{\frac{N}{2}}$, tai


$$C_x(k) = \sum_{n=0}^{\frac{N}{2}-1} X(2n) \cdot W_{\frac{N}{2}}^{nk} + W^k \sum_{n=0}^{\frac{N}{2}-1} X(2n+1) \cdot W_{\frac{N}{2}}^{nk} = X_1(k) + W^k X_2(k)$$

čia $X_1(k)$ - lyginių sekos atskaitų $X(m)$ DFT, $X_2(k)$ - nelyginių sekos atskaitų $X(m)$ DFT.

Suprantama, kad jų periodas nebe N , o $N/2$. Taigi, $X_1(k + N/2) = X_1(k)$, o $X_2(k + N/2) = X_2(k)$.

Taigi,

$$C_x(k) = \begin{cases} X_1(k) + W^k X_2(k), 0 \leq k \leq \frac{N}{2} - 1 \\ X_1(k - \frac{N}{2}) + W^{(k - \frac{N}{2})} X_2(k - \frac{N}{2}), \frac{N}{2} \leq k \leq N - 1 \end{cases}$$




17 pav. GFT „išretinto“ laiko algoritmo realizavimo struktūrinė schema

Pavyzdžiui, kai $N=8$, pilna DFT skaičiavimo struktūrinė schema pavaizduota 17 paveiksle. Ši schema yra ir greitoji Furjė transformacija, sudaryta pagal „išretinto“ laiko algoritmą. Struktūrinėje schemoje yra $\log_2 N = \log_2 8 = 3$ skaičiavimų etapai.

1.2.2 PARABOLIŲ (SIMPSONO) FORMULĖ

Atkarpą $[a;b]$ daliname į lyginį skaičių $2n$ lygių dalių ir atitinkamas funkcijos reikšmes pažymime $y_0, y_1, y_2, \dots, y_{2n-2}, y_{2n-1}, y_{2n}$ [10]. Kreivinės trapezijos dalį, atitinkančią atkarpą $[x_0; x_2]$, pakeičiame kreivine trapezija, kuri apribota jau ne kreivės $y = f(x)$, o parabolės $y = Ax^2 + Bx + C$, einančios per tris taškus $M_0(x_0; y_0), M_1(x_1; y_1), M_2(x_2; y_2)$ (18 pav.).



18 pav. EKG dantelių priklausomybė nuo sujaudinimo plitimo širdyje

Apskaičiuosime tokios parabolinės trapezijos plotą.

$$S = \int_{x_0}^{x_2} (Ax^2 + Bx + C)dx = \left(\frac{Ax^3}{3} + \frac{Bx^2}{2} + Cx \right) \Big|_{x_0}^{x_2} = \frac{A}{3} \cdot (x_2^3 - x_0^3) + \frac{B}{2} \cdot (x_2^2 - x_0^2) + C \cdot (x_2 - x_0) =$$

$$= \frac{x_2 - x_0}{6} (2A \cdot (x_2^2 + x_2x_0 + x_0^2) + 3B \cdot (x_2 + x_0) + 6C).$$

Kadangi M_0, M_1, M_2 – parabolės taškai, tai jų koordinatės turi tenkinti parabolės lygtį. Turėdami galvoje, kad $x_1 = \frac{x_0 + x_2}{2}$, gauname tokias tris lygybes:

$$\begin{aligned} y_0 &= Ax_0^2 + Bx_0 + C, \\ y_1 &= Ax_1^2 + Bx_1 + C = A \cdot \left(\frac{x_0 + x_2}{2} \right)^2 + B \cdot \left(\frac{x_0 + x_2}{2} \right) + C = \\ &= \frac{A}{4} \cdot x_0^2 + \frac{A}{2} \cdot x_0 \cdot x_2 + \frac{A}{4} \cdot x_2^2 + \frac{B}{2} \cdot x_0 + \frac{B}{2} \cdot x_2 + C, \\ y_2 &= Ax_2^2 + Bx_2 + C. \end{aligned} \tag{9}$$

Padauginę (9) antrosios lygybės abi puses iš 4, po to sudėję ją su pirmąja ir trečiąja lygybėmis bei atlikę veiksmus, gausime:

$$y_0 + 4y_1 + y_2 = 2A \cdot (x_2^2 + x_2x_0 + x_0^2) + 3B \cdot (x_2 + x_0) + 6C$$

Vadinasi, parabolinės trapecijos plotas:

$$S = \frac{x_2 - x_0}{6} \cdot (y_0 + 4y_1 + y_2) = \frac{b - a}{6n} \cdot (y_0 + 4y_1 + y_2)$$

Todėl

$$\int_{x_0}^{x_2} f(x)dx \approx \frac{b - a}{6n} \cdot (y_0 + 4y_1 + y_2).$$

Analogiškai,

$$\int_{x_2}^{x_4} f(x)dx \approx \frac{b - a}{6n} \cdot (y_2 + 4y_3 + y_4);$$

.....

$$\int_{x_{2n-2}}^{x_{2n}} f(x)dx \approx \frac{b - a}{6n} \cdot (y_{2n-2} + 4y_{2n-1} + y_{2n})$$

Sudėję šiuos integralus, gauname parbolių (Simpsono) formulę [10]:

$$\int_a^b f(x)dx \approx \frac{b - a}{6n} \cdot ((y_0 + y_{2n}) + 4(y_1 + y_3 + \dots + y_{2n-1}) + 2(y_2 + y_4 + \dots + y_{2n-2})).$$

Paklaidą R_n apskaičiuosime pagal formulę:

$$R_n = -\frac{(b-a)^5}{180 \cdot (2n)^4} \cdot f^{(4)}(\zeta);$$

čia $a \leq \zeta \leq b$.

1.2.3 KOHERENCIJA

Spektrinė analizė vaidina didelę reikšmę signalų apdorojime. Šie metodai yra taikomi įvairiose srityse: komunikacijose, kalbos garsinio signalo apdorojime, biomedicinoje ar radarų technologijose ir t.t. [11,12,13]. Vienas iš geriausiai žinomų neparimetrinių spektrinės analizės algoritmų yra Capon'o metodas, kuris yra geriau žinomas kaip mažo jautrumo minimalios dispersijos išsibarstymo metodas (minimum variance distortion less response) (MVDR) [14,15]. Šis algoritmas pasižymi dideliu tikslumu analizuojant signalus dažnių srityje. MVDR spektras gali būti stebimas kaip filtrų išėties rezultatas. MVDR algoritmas gali būti interpretuojamas kaip juostinių filtrų bazė, kurių centrinė dažninė komponentė yra lygi analizuojamai dažnio komponentei. Kiekvienas juostinis filtras priklauso nuo metodui pateikiamų duomenų bei dažnių tuo skirdamasis nuo periodogramomis pagrįstu metodo, kur kiekvienas jo juostinis filtras yra diskretinė Furjė matrica, kuri nuo duomenų ir dažnių nėra priklausoma [13,16].

MSC (magnitude squared coherence) – koherencija, funkcija yra kaip alternatyva populiariam Welch'o metodui [17,18]. Koherencija parodo kaip $x_1(n)$ signalas atitinka $x_2(n)$ signalą prie tų pačių dažnių.

Tarkime, turime du signalus $x_1(n)$ ir $x_2(n)$. Galime sukonstruoti perdavimo funkciją

$$g_{p,k} = \frac{R_{x_p x_p}^{-1} \cdot f_k}{f_k^H R_{x_p x_p}^{-1} \cdot f_k}, p = 1, 2$$

kur $f_k = \frac{1}{\sqrt{L}} [1 \exp(jw_k) \dots \exp(jw_k(L-1))]^T$, H - transponuota konjunktija (sandauga).

bei rasti $x_1(n)$ ir $x_2(n)$ signalų spektrus tam tikruose dažniuose w_k , $w_k = 2\pi k / K, k = 0, 1, \dots, K - 1$.

$$S_{x_p x_p}(w_k) = \frac{1}{f_k^H R_{x_p x_p}^{-1} f_k}, p = 1, 2,$$

kur $R_{x_p x_p} = E[(x_p(n)x_p^H(n))]$ yra signalo $x_p(n)$ kovariacinė matrica ir $x_p(n) = [x_p(n) \ x_p(n-1) \ \dots \ x_p(n-L+1)]^T$.

Tegul $y_{1,k}(n)$ ir $y_{2,k}(n)$ atitinkamai filtrų $g_{1,k}$ ir $g_{2,k}$ perdavimo funkcijų išėjimai. Apibrėžkime spektrą tarp $x_1(n)$ ir $x_2(n)$ kiekvienam w_k dažniui:

$$S_{x_1 x_2}(w_k) = E\{y_{1,k}(n)y_{2,k}^*(n)\}$$

$S_{x_2x_1}(w_k) = E\{y_{2,k}(n)y_{1,k}^*(n)\} = S_{x_1x_2}^*(w_k)$, * - konjunkcijos (sandaugos) operatorius

$$S_{x_1x_2}(w_k) = g_{1,k}^H \cdot R_{x_1x_2} \cdot g_{2,k}, \text{ kur } R_{x_1x_2} = E\{x_1(n)x_2(n)\} \quad (10)$$

$$F = [f_0 \quad f_1 \quad \dots \quad f_{K-1}] \quad (11)$$

Perdavimo funkcijos koeficientai pasirenkami taip, kad minimizuotų filtro išėjimų pasiskirstymą, t.y.

$g_k^H f_k = f_k^H g_k = 1$. Pagal šią lygybę, $x(n)$, paveikiamas perdavimo funkcijos g_k be trikdžių kiekviename dažnyje w_k .

Pagal (10) ir (11):

$$S_{x_1x_2}(w_k) = \frac{f_k^H R_{x_1x_1}^{-1} R_{x_1x_2} R_{x_2x_2}^{-1} f_k}{\|f_k^H R_{x_1x_1}^{-1} f_k\| \cdot \|f_k^H R_{x_2x_2}^{-1} f_k\|} \quad (12 a)$$

(12 a) išraišką pakėlus kvadratu, gauname:

$$(S_{x_1x_2}(w_k))^2 = \frac{|f_k^H R_{x_1x_1}^{-1} R_{x_1x_2} R_{x_2x_2}^{-1} f_k|^2}{\|f_k^H R_{x_1x_1}^{-1} f_k\|^2 \cdot \|f_k^H R_{x_2x_2}^{-1} f_k\|^2} \quad (12 b)$$

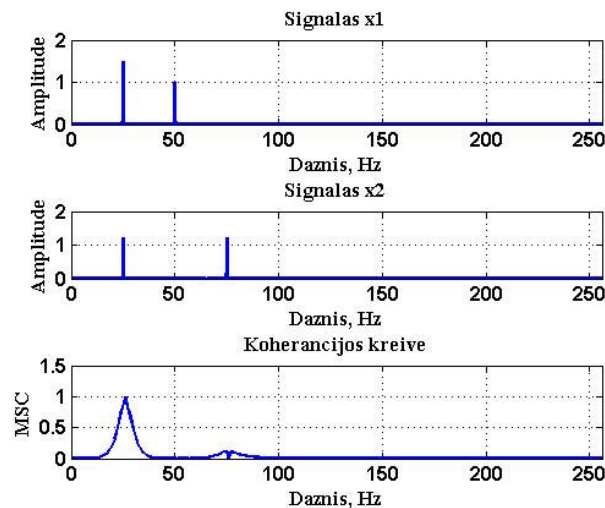
Koherencija išreiškiama:

$$\gamma_{x_1x_2}^2(w_k) = \frac{|S_{x_1x_2}(w_k)|^2}{S_{x_1x_1}(w_k)S_{x_2x_2}(w_k)} \quad (13)$$

Išraišką (12 b) įstačius į (13), gauname koherencijos išraišką:

$$\gamma_{x_1x_2}^2(w_k) = \frac{(f_k^H R_{x_1x_1}^{-1} R_{x_1x_2} R_{x_2x_2}^{-1} f_k)^2}{(f_k^H R_{x_1x_1}^{-1} f_k) \cdot (f_k^H R_{x_2x_2}^{-1} f_k)}$$

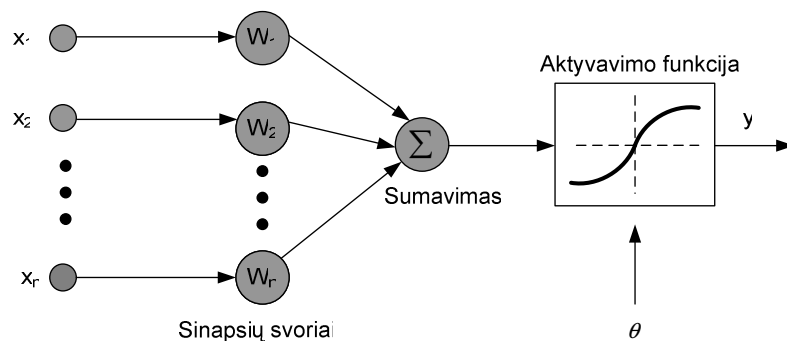
Koherencijos pavyzdys tarp dviejų signalų $x(1)$ ir $x(2)$ pavaizduotas 19 paveiksle.



19 pav. x_1 ir x_2 signalų koherencija

1.2.4 DIRBTINIS NEURONINIS TINKLAS

Dirbtiniai neuroniniai tinklai – tarpusavyje sujungtų dirbtinių neuronų grupė, kuriami specifinių užduočių vykdymui. Ši technologija mėgdžioja žmogaus galvos smegenų darbą – neuronų veikimą. Daugumą dirbtinių neuroninių tinklų ne tik galima apmokyti pradiniais duomenimis, bet jie taip pat keičia struktūrą pagal vėliau gautą informaciją, ir taip prisitaiko prie kintančios aplinkos. Tokie neuroniniai tinklai dar yra vadinami savireguliuojančiais. Daugelis kompiuterinių programų sugeba apdoroti tik tikslus duomenis, o dirbtiniai neuroniniai tinklai sugeba apdoroti duomenis, kurie pateikti su tam tikra paklaida.



20 pav. Dirbtinio neurono sandara

Dirbtinis neuronas (20 pav.) yra svarbiausias neuroninio tinklo elementas. Jį sudaro trys pagrindiniai komponentai: svoriai, slenksčiai ir viena aktyvavimo funkcija. $W = [W_1, W_2, \dots, W_n]$ yra svorio koeficientai, rodantys stiprumus atskirų įėjimų, aprašytų vektoriumi $X = [x_1, x_2, x_3, \dots, x_n]$. Kiekvienos įėjimo signalas dauginamas iš svorio koeficiento. Tokiu būdu gaunama neuroninė jungtis XW . Jei svorio koeficientas teigiamas, XW sužadina signalą išėjime y , o jei neigiamas – XW slopina išėjimų signalą. Vidinis neurono slenkstis veikia neurono y išvesties aktyvavimą tokiu būdu [19]:

$$y = f\left(\sum_{i=1}^n XW - \theta\right)$$

Aktyvavimo funkcija – tai matematinės operacijos su išvesties signalu. Kokio sudėtingumo aktyvavimo funkcija taikoma, priklauso nuo neuroninio tinklo sprendžiamo uždavinio. Populiariausios – sigmoidinė ir hiperbolinė tangento aktyvavimo funkcijos.

Sakykime reikia suskirstyti duomenis į klases. Tarkime, kad turime du požymius: x_1 – svoris, x_2 – ūgis. Norime atskirti berniukus nuo mergaičių. Tai gali padaryti vienas neuronas, tinkamai parinkus svorius w_i :

$$y = x_1 w_1 + x_2 w_2 + w_0$$

$y=0$ yra skiriamasis paviršius. $y>0$ – berniukai, $y<0$ – mergaitės. Jei įtrauksime sigmoidinę funkciją, tuomet $f(y) > 0.5$ – berniukai, $f(y)<0.5$ – mergaitės.

Dirbtinis neuroninis tinklas – rinkinys tarpusavyje sujungtų neuronų. Labiausiai paplitusios yra dvi dirbtinių neuroninių tinklų rūšys:


- vienasluoksnis perceptronas arba tiesiog perceptronas (angl. single layer perceptron; SLP) – tiesiog vienas neuronas.
- daugiasluoksnis perceptronas (angl. multilayer perceptron; MLP) – daug neuronų, išdėstytų sluoksniais. Kiekvieno sluoksnio neuronų išėjimai sujungti su kito iš eilės sluoksnio neuronų įėjimais. Įėjimo sluoksnis – pradiniai duomenys; išėjimo sluoksnis – paskutiniame sluoksnyje esantys neuronai ir jų išėjimai; visi kiti sluoksniai vadinami paslėptais. Didžioji dauguma dirbtinių neuroninių tinklų yra SLP arba MLP. MLP su vienu paslėptu sluoksniu gali modeliuoti bet kokio sudėtingumo atpažinimo paviršių.

1.2.5 BATERVORTO FILTRAI

Batervorto filtras gaunamas amplitudės dažninės charakteristikos kvadrata aproksimavus priklausomybe:

$$|H_a(j\Omega)|^2 = \frac{1}{1 + \left(\frac{\Omega}{\Omega_0}\right)^{2N}} \quad (14)$$

čia N – sveikasis skaičius, apibūdinantis filtro eilę. Antrosios ir šeštosios eilės filtrų aproksimavimo kreivės pavaizduotos 21 paveiksle. Reikalavimai filteriui išreikšti parametrais: pralaidumo, slopinimo juostų ribiniais dažniais Ω_p ir Ω_s , pralaidumo ir slopinimo juostose δ_1 ir δ_2 [9]. Pagal šiuos parametrus, apskaičiuojami aproksimavimo parametrai – dažnis Ω_0 ir filtro eilė N . Kuo aukštesnės eilės filtras, tuo gali būti mažesnės δ_1 ir δ_2 arba siauresnė pereinamoji juosta (21 pav.)



21 pav. Žemutinių dažnių filtro Batervorto aproksimavimo kreivės

Išraišką (14) perrašykime skaitmeninio filtro dažniams $\omega = \Omega R$, čia T – diskretizavimo periodas. Tada

$$|H_a(j\omega)|^2 = \frac{1}{1 + \left(\frac{\omega}{\omega_0}\right)^{2N}} \quad (15)$$

Paprastai išreiškiama logaritminiu masteliu:

$$20\lg|H_a(j\omega)| = 20\lg \frac{1}{\sqrt{1 + \left(\frac{\omega}{\omega_0}\right)^{2N}}} \quad (16)$$

Slopinimas matuojamas decibelais (dB). Tada pralaidumo juostoje leistinas slopinimas yra $20\lg(1 - \delta_1) = -\Delta_1$ dB, o slopinimo juostoje – ne mažesnis kaip $20\lg \delta_2 = -\Delta_2$ dB.

Kadangi Baterforto filtrų aproksimavimo parametrai N ir ω_0 nustatomi iš sąlygų, kad (16) charakteristika tenkintų reikalavimus pralaidumo ir slopinimo juostų kraštiniam dažniams ω_p ir ω_s .

Taigi

$$20\lg|H_a(j\omega_p)| = 20\lg \frac{1}{\sqrt{1 + \left(\frac{\omega_p}{\omega_0}\right)^{2N}}} = -\Delta_1$$

$$20\lg|H_a(j\omega_s)| = 20\lg \frac{1}{\sqrt{1 + \left(\frac{\omega_s}{\omega_0}\right)^{2N}}} = -\Delta_2.$$

Gauname,

$$\left(\frac{\omega_p}{\omega_0}\right)^{2N} = 10^{0.1\Delta_1} - 1$$

$$\left(\frac{\omega_s}{\omega_0}\right)^{2N} = 10^{0.1\Delta_2} - 1 \quad (17)$$

Iš santykio $\left(\frac{\omega_s}{\omega_p}\right)^{2N} = \frac{10^{0.1\Delta_2} - 1}{10^{0.1\Delta_1} - 1}$ išreiškiame filtro eilę:

$$N = \frac{1}{2} \cdot \frac{\lg(10^{0.1\Delta_2} - 1) - \lg(10^{0.1\Delta_1} - 1)}{\lg \frac{\omega_s}{\omega_p}}$$

Kadangi N gali būti tik sveikas teigiamas skaičius, tai gautąjį N reikšmę padidiname iki artimiausio sveiką skaičių. Antrąjį parametą ω_0 apskaičiuojame įrašę filtro eilės N reikšmę į (17) išraišką:

$$\omega_0 = 10^{\left(\lg \omega_p - \frac{1}{2N} \lg(10^{0.1\Delta_1} - 1)\right)}$$

Reikalavimai tenkinami pralaidumo juostos kraštiniam dažniui ω_p ir viršijami reikalavimai nepralaidumo juostai.

Turėdami aproksimavimo parametrus N ir ω_0 , galime nustatyti analoginio filtro sistemos funkciją $H_0(p)$. Remdamiesi (15), užrašome [9]:

$$H_a(p)H_a(-p) = \frac{1}{1 + \left(\frac{p}{j\omega_0}\right)^{2N}} = \frac{(j\omega_0)^{2N}}{p^{2N} + (j\omega_0)^{2N}},$$

kur $p_i = \omega_0 e^{j\left(\frac{\pi}{2} + \frac{\pi(2i+1)}{2N}\right)}$ yra išdėstyti kampais $\frac{\pi}{N}$ vienas kito atžvilgiu ant apskritimo, kurio spindulys ω_0 . Stabilios sistemos poliai yra kompleksinės plokštumos p kairėje pusėje, todėl sistemos funkcijai $H_a(p)$ ir priskiriami šie poliai. Taigi,

$$H_a(p) = \frac{\omega_0^N}{\prod_{k=1}^N (p - p_k)}$$

p_k - poliai, esantys kairėje kompleksinės plokštumos pusėje [9].

2. TIRIAMOJI DALIS

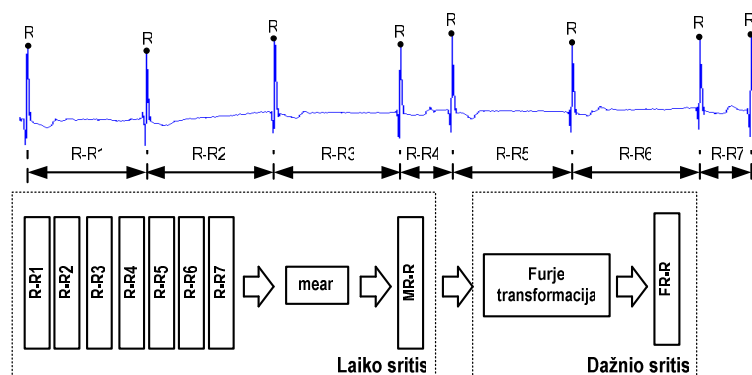
2.1 DUOMENŲ PARUOŠIMAS DARBUI

Darbe naudojome dešimties sekundžių ir vienos minutės įrašus, kurių struktūra: 512 simbolių – informacija apie žmogų ir 15 derivacijų po 5120 simbolius int16 formatu bei 15 derivacijų po 30720 simbolius int16 formatu. Informacijos apie žmogų darbe nenaudojome. Įrašuose užregistruotos derivacijos: I, II, III, aVR, aVL, aVF, V₁, V₂, V₃, V₄, V₅, V₆. Kardiosignalai užrašyti 512 Hz diskretizavimo dažnumu.

Analizavome tris skirtingą informaciją apimančius kardiosignalus: elektrokardiograma (EKG), impedanskardiograma (IKG) ir seismokardiograma (SKG). Analizės metu suformavome matricą iš n stulpelių, kur skaičių n apsprendė bangų skaičius analizuojamame signale.

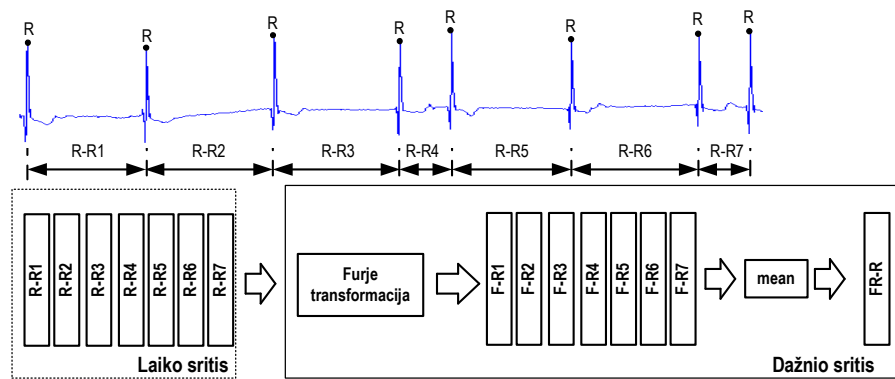
2.2 SPEKTRINIS PLOTŲ PALYGINIMAS

Tradiciskai, Furjė transformacija taikoma EKG dažnumų analizei, tuo tarpu IKG ir SKG dažnio charakteristikų vertinimui šis metodas nebuvo naudojamas. Darbo tikslas buvo pritaikyti Furjė analizę įvertinant bei palyginant trijų sinchroniškai užregistruotų signalų - EKG, IKG ir SKG dažnio charakteristikas. Tyrimui panaudojome du skirtingus duomenų paruošimo metodus. Taikant abu metodus, pirmiausia elektrokardiograma suskirstyta į R-R intervalus. Pirmojo (vidF) metodo schema pateikta 22 pav.




22 pav. Duomenų paruošimo metodas vidF

Tolimesnėje analizėje naudojamos vidutinės intervalų R-R reikšmės, t.y. MR-R. Furjė transformacija taikoma MR-R intervalui.



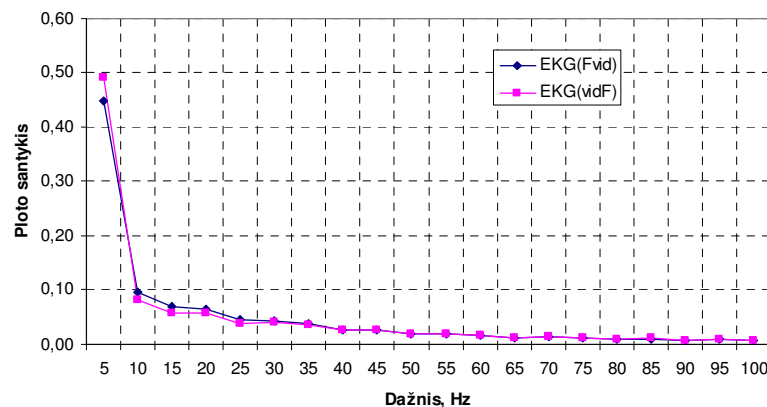
23 pav. Duomenų paruošimo metodas Fvid

Antrojo (Fvid) metodo esmė – Furjė transformacija taikoma kiekvienam R-R intervalui atskirai gavus R-R spektrus, jie yra suvidurkinami (FR-R). Duomenų paruošimo procedūra pateikta 23 pav.



24 pav. EKG, SKG ir IKG kanalų R-R intervalų spektras

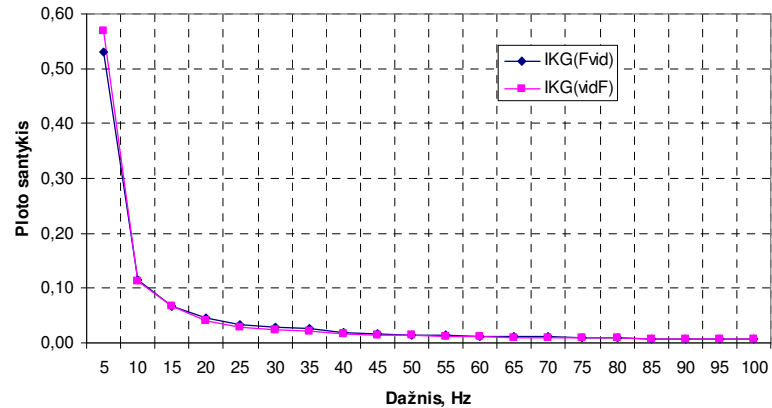
Atlikus duomenų paruošimo procedūras, gaunami EKG, IKG ir SKG signalų spektrai (24 pav.)



25 pav. EKG spektro plotų palyginimas

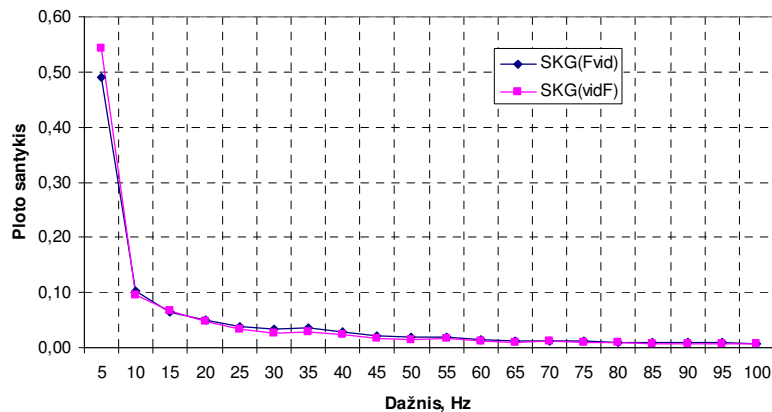
Signalai, pervesti į dažnių sritį, padalinti į 20 atkarpėlių, 5 Hz juostomis. Pagal Simpsono metodą, apskaičiuojame kiekvienos juostos plotą. Grafikuose pateiktos kreivės vaizduoja 5 Hz juostos ploto santykį su visu signalo plotu. Vaizduojamos tik vidutinių reikšmių kreivės, nes reikšmių išsibarstymas apie vidutinę reikšmę yra tik apie 2 %. Nors duomenų paruošimo procedūros gana

skirtingos, tačiau lyginant EKG, IKG ir SKG spektrų juostų plotų santykius, skirtingais metodais gaunami gana panašūs rezultatai. Rezultatai grafiškai pateikti 25-27 paveikslėliuose.



26 pav. IKG spektro plotų palyginimas

Nors metodų palyginimo grafikai pateikti tiriant vieną pacientą, panašūs rezultatai gaunami tiriant ir kitus ligonius. Tai patvirtina apskaičiuoti koreliacijos koeficientai: tiriant EKG spektro plotų santykius, $R=0.9981$, IKG atveju $R=0.997$ ir SKG atveju $R=0.9994$.




27 pav. SKG spektro plotų palyginimas

Visuose signaluose didžiausią santykinę plotą užima pirmosios dvi atkarpos, t.y. 0-10 Hz. IKG signalas, lyginant su EKG ir SKG, turi didžiausią santykinę plotą. Visi kiti santykiniai plotai eksponentiškai artėja prie 0. Signalai turi mažą amplitudę ir stiprią nuolatinę dedamąją.


2.3 POLIKARDIOSIGNALŲ KOHERENTIŠKUMO TYRIMAS

Visi trys kardiosignalai užregistruoti sinchroniškai, t.y. tuo pačiu metu. Ištyrėme 30 asmenų. Tiriamieji padalinti į dvi grupes. Iš anksto buvo žinoma, kad 20 iš jų turi sveikatos sutrikimų, o 10 – sveikata nesiskundžia.



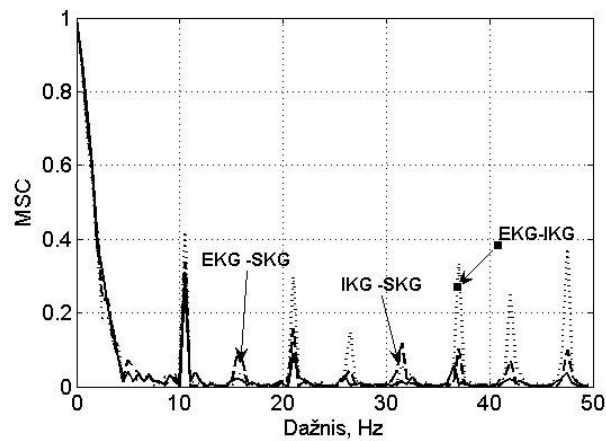
28 pav. “Sveikų” žmonių kardiosignalų koherencija

Rezultatai rodo, kad tiriamųjų grupių koherencijos kreivės skirtingos. “Sveikų” žmonių koherencijos kreivės panašios: tuose pačiuose kreivių pikuose koherencijos reikšmės beveik sutampa ir visų trijų signalų koherencijos pikų skaičius vienodas (28 pav.). Vidutinė koherencijos reikšmė apie 0.4-0.5. Antras pagal dydį koherencijos kreivės pikas (0.68-0.72) išryškėja atitinkamai ties 11 Hz ir 32 Hz.



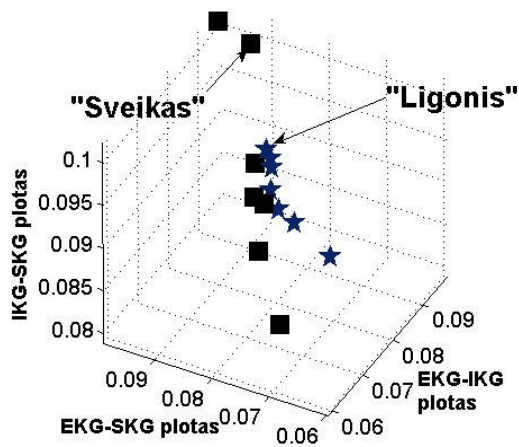
29 pav. “Ligonių” kardiosignalų koherencija

Priešingai nei “sveikų” tiriamųjų, “ligonių” kardiosignalų koherencija maža (29 pav.) ir turi gana skirtingas reikšmes tuose pačiuose pikuose (30 pav.). Vidutinė “ligonių” koherencijos vertė yra apie 0.30-0.38.



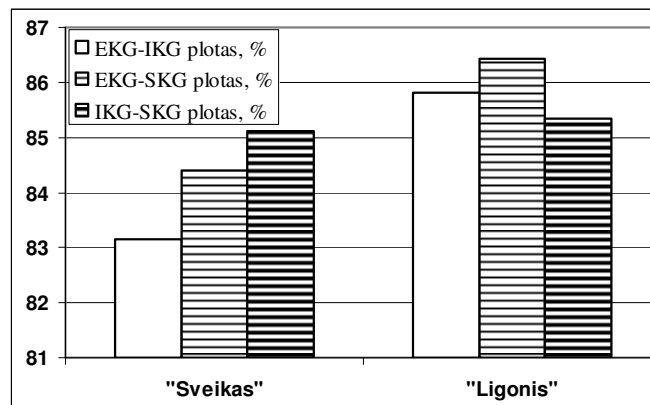
30 pav. „Ligoniu“ koherencija

Simpsono metodu buvo suskaičiuoti plotai po kiekviena koherencijos kreive ir atvaizduoti trimatėje erdvėje (31 pav.). Rezultatai rodo, kad požymiai gali būti atskirti hyperplokštuma, kuria būtų galima klasifikuoti tiriamuosius į dvi klases, t.y., į „sveikus“ ir „ligonius“.




31 pav. Koherencijos plotai

Koherencijos kreivės buvo padalintos į 3 skirtingas zonas: 0-10 Hz., 11-35 Hz. ir 35-50 Hz. Simpsono metodu suskaičiuotas kiekvienos dalies plotas po koherencijos kreive. Rezultatai pateikiami stulpelinėmis diagramomis, kurios parodo vienos zonos apibrėžtos koherentiškumo kreive santykį su visos koherentiškumo kreivės apibrėžiamu plotu, %.




32 pav. Plotų po koherencijos kreivėmis santykinis plotas, 0-10 Hz

Lyginant pirmosios zonos 0-10 Hz rezultatus, „sveikų“ tiriamųjų didžiausias santykinis plotas yra po IKG-SKG koherencijos kreive, o „ligonių“ – po EKG-SKG koherencijos kreive, atitinkamai apie 85% ir apie 86,50% (32 pav.).



33 pav. Plotų po koherencijos kreivėmis santykinis plotas, 11-35 Hz


Antroje zonoje 11-35 Hz, santykiniai plotai po koherencijos kreivėmis gana panašūs: „sveikų“ tiriamųjų apie 10%, o „ligonių“ – apie 6% (33 pav.).



34 pav. Plotų po koherencijos kreivėmis santykinis plotas, 36-50 Hz

Lyginant paskutinės zonos 36-50 Hz rezultatus, santykiniai plotai po koherencijos kreivėmis „ligonių“ siekia apie 7.8-8 % ir 5-6% „sveikų“ tiriamųjų (34 pav.). Tiek „sveikų“, tiek „ligonių“, didžiausias koherencijos santykinis plotas pasiskirstęs I zonoje, i.e. 0-10 Hz. Pirmosios zonos didžiausias koherencijos santykinis plotas: „sveikų“ – IKG-SKG, „ligonių“ – EKG-SKG. Visų kitų zonų plotai eksponentiškai artėja prie nulio.

Tolimesniame tyrime, apmokėme neuroninius tinklus klasifikuoti dvi skirtingas klases, t.y. klasę „sveikas“ ir klasę „nesveikas“. Neuroninis tinklas klasifikavimą atliko pagal EKG, IKG ir SKG 3 skirtingų zonų santykinis plotus po koherencijos kreivėmis: 0-10 Hz 11-35 Hz ir 35-50 Hz. Naudojamo neuroninio tinklo schema pateikta 35 paveiksle.



35 pav. Neuroninis tinklas su 9 įėjimais

Apmokėme 3 neuroninius tinklus, kuriuose kinta įėjimų sluoksnio neuronų skaičius, atitinkamai nuo 5 iki 20. Kiekvieno neuroso aktyvavimo funkcija buvo pasirinkta sigmoidinė, t.y. neuronų išėjimų reikšmė kinta intervale $[0 \div 1]$. Lentelėje Nr.1 pateikta informacija apie klasifikavimui panaudotus neuroninius tinklus.


Lentelė 1

Panaudotų neuroninių tinklų struktūros

Tyrimo Nr.	Įėjimų skaičius	Įėjimų sluoksnio neuronų skaičius	Išėjimų sluoksnio neuronų skaičius	Aktyvavimo funkcija	Išėjimai
1	9	5	1	sigmoidinė	$[0 \div 1]$
2	9	15	1	sigmoidinė	$[0 \div 1]$
3	9	20	1	sigmoidinė	$[0 \div 1]$


Analizuojami duomenys buvo suskirstyti į dvi grupes: mokymui ir testavimui. Didžioji dalis naudojama mokymui, t.y. apie 80% visų duomenų „sveikųjų“ ir „ligonių“ klasėje. Didėjant neuronų

skaičiui, tinklų apmokymo procesas ilgėja. Pastebėta, kad neuronų tinklas, kuriame įėjimų sluoksnyje yra 20 neuronų, klasifikavimo rezultatai buvo geriausi lyginant su kitomis neuronų tinklo struktūromis, klasifikuojant „sveikųjų“ tiek mokymo grupę, tiek ir testavimo grupę. Visi klasifikavimo rezultatai buvo ne mažesni nei 0,9952 (36 pav.).



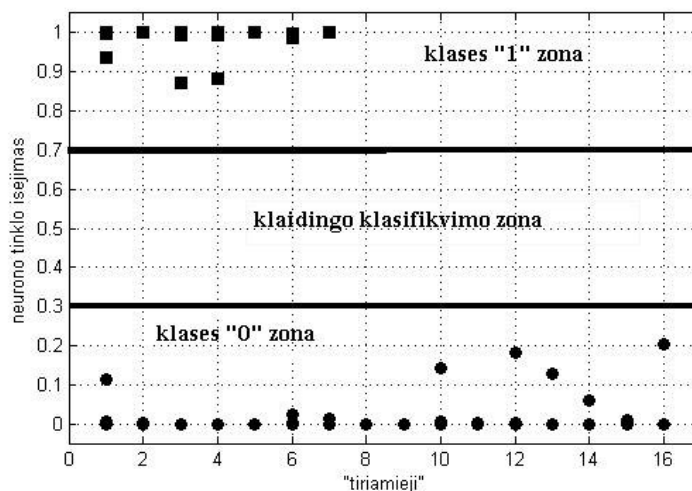
36 pav. „Sveikųjų“ klasifikavimo rezultatai, priklausomai nuo neuronų tinklo dydžio

Esant 5 neuronų tinklui, klasifikavimo rezultatai buvo blogiausi, klasifikuojant „sveikųjų“ testavimo grupę. Esant 15 neuronų tinklui, klasifikavimo rezultatai buvo blogiausi, klasifikuojant „sveikųjų“ tiek mokymo grupę, tiek ir testavimo grupę. Visi klasifikavimo rezultatai buvo ne mažesni nei 0,8728 (36 pav.).



37 pav. „Ligonių“ klasifikavimo rezultatai, priklausomai nuo neuronų tinklo dydžio

Neuronų tinklas, kuriame įėjimų sluoksnyje yra 5 neuronai, klasifikavimo rezultatai buvo blogiausi, klasifikuojant ir „ligonių“ testavimo grupę, t.y. ne didesni nei 0,2044. Esant neuronų tinklui, kuriame įėjimų sluoksnyje yra 15 neuronų, klasifikavimo rezultatai buvo blogiausi, klasifikuojant „ligonių“ tiek mokymo grupę, tiek ir testavimo grupę. Visi klasifikavimo rezultatai buvo ne mažesni nei 0,1432 (37 pav.). Pastebėta, kad esant 20 neuronų tinklui, klasifikavimo rezultatai buvo geriausi, klasifikuojant „ligonių“ tiek mokymo grupę, tiek ir testavimo grupę. Visi klasifikavimo rezultatai buvo ne didesni nei 0,0062 (37 pav.).



38 pav. Tiriamųjų „ligonių“ ir „sveikųjų“ klasifikavimo rezultatai

Atvaizdavus visus „sveikųjų“ ir „ligonių“ klasifikavimo rezultatus, matome, kad neuronų tinklai (su 20-čia neuronų) teisingai klasifikuoja tiriamuosius (38 pav.). Visos „sveikųjų“ klasifikavimo reikšmės patenka į klasės „1“ zoną, kurios reikšmės kinta nuo 0,7-1,0; „ligonių“ klasifikavimo reikšmės patenka į klasės „0“ zoną, kurios reikšmės kinta nuo 0-0,3. Klasifikavimo reikšmės nepateko į klaidingo klasifikavimo zoną, todėl galime teigti, kad pasirinkti požymiai buvo reikšmingi. Tai nurodo, jog tarpsignalinis koherentiškumas gali būti ypač svarbus diagnozuojant ligos pasireiškimą, mūsų atveju, išeminę širdies ligą.

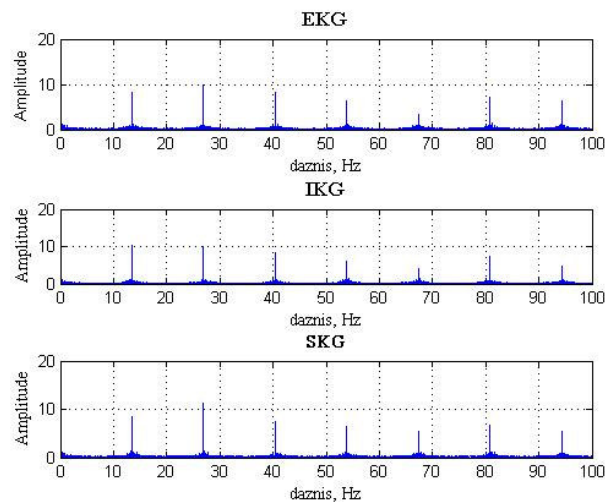
2.4 EKG, IKG IR SKG SIGNALŲ SPEKTRAI

Lyginant signalus laiko ašyje būtų sunku rasti matematinę priklausomybę. Tiek tiriant koherentiškumą, tiek lyginant plotus po spektrinėmis kreivėmis, pastebėjome, kad signalų informatyvumas didesnis analizuojant signalų dažnines charakteristikas.

Visų tyrimų metu buvo taikoma Furjė transformacija. Analizei panaudoti 50 asmenų kardiosignalai. Tiriamieji padalinti į dvi grupes. Iš anksto buvo žinoma, kad 40 iš jų turi sveikatos

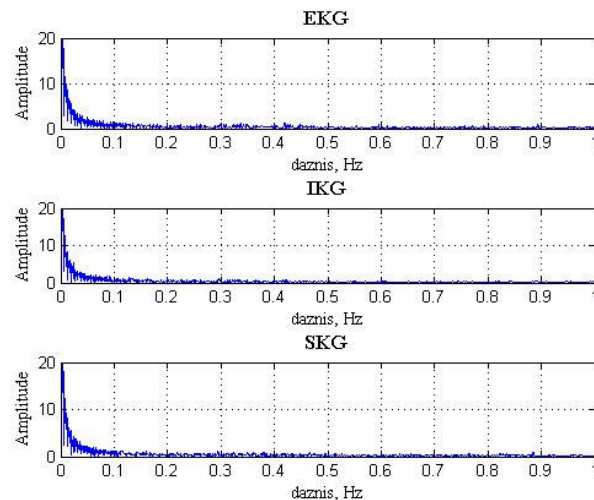
sutrikimų, o 10 – sveikata nesiskundžia. Pervedus signalus iš laiko srities į dažnių sritį, EKG, IKG ir SKG signalai yra išskaidomi į dažnines komponentes, todėl juos galima lyginti tarpusavyje.

Analizuojant dažnius iki 100 Hz, ties 10-14 Hz išryškėja alfa ritmas (žr. 39 pav.). Alfa bangos – ramybės, ir negilus miego bangos. Jos atsiranda atsipalaidavus, esant užmerktoms akims bei nusiraminus. Alfa bangos atitinka budrios sąmonės, esant atsipalaidavus, būseną. Būdinga gera savijauta, ramus ir sklandus mąstymas, teigiama nuotaika. Alfa bangas generuoja sveikas organizmas. Esant sumažėjusiam alfa bangų aktyvumui, atsiranda streso, susirūpinimo požymiai, smegenų veiklos sutrikimų bei ligų indikacijos. Alfa ritmas aptinkamas ne tik pas „sveikuosius“, bet ir „ligonius“, tačiau „ligonių“ alfa ritmas yra skirtingas lyginant visų trijų sinchroniškai užregistruotų signalų alfa ritmo komponentių amplitudes.




39 pav. Sinchroniškai užregistruotų signalų (EKG, IKG ir SKG) spektrai. Dažnių juostoje nuo 0 Hz iki 100 Hz.

Komponentės su didžiausiomis galiomis yra pasiskirsčiusios dažnių juostoje nuo 0 iki 1 Hz (40 pav.).




40 pav. Sinchroniškai užregistruotų signalų (EKG, IKG ir SKG) spektrai. Dažnių juostoje nuo 0 Hz iki 1 Hz.

Signalų spektre galime aptikti komponentių, kurios į signalą įrašomos žmogui kvėpuojant. Atvaizdavus EKG, IKG ir SKG signalų spektrus yra matomi skirtumai, kuriuos būtų sunku pastebėti jei signalai būtų nagrinėjami laiko srityje. 41 paveikslėlyje pateikti minėtų trijų signalų spektrai dažnių juostoje nuo 0 iki 0.1 Hz, kur komponentės ties atitinkamais dažniais turi skirtingas amplitudes.




41 pav. Sinchroniškai užregistruotų signalų (EKG, IKG ir SKG) spektrai. Dažnių juostoje nuo 0 Hz iki 0.1 Hz.

Kadangi buvo pastebėta, kad kardiosignalų spektrai skiriasi, tolimesniame tyrime apmokome neuroninius tinklus klasifikuoti dvi skirtingas klases, t.y. klasė „sveikas“ ir klasė „nesveikas“. Neuroninis tinklas klasifikavimą turi atlikti pagal EKG, IKG ir SKG 40 skirtingų zonų maksimalias reikšmes, kurios buvo atrinktos pagal 42 paveikslėlį.



42 pav. Neuroninio tinklo požymių išrinkimas

Naudojamo neuroninio tinklo schema pateikta 43 paveiksle.



43 pav. Neuroninis tinklas su 120 įėjimų


Apmokome 4 neuroninius tinklus, kuriuose kinta įėjimų sluoksnio neuronų skaičius, atitinkamai nuo 5 iki 25. Kiekvieno neurono aktyvavimo funkcija buvo pasirinkta sigmoidinė, t.y. neuronų išėjimų reikšmė kinta intervale $[0 \div 1]$. Lentelėje Nr.2 pateikta informacija apie panaudotus klasifikavimui neuroninius tinklus.

Lentelė 2
Panaudotų neuroninių tinklų struktūros signalų spektrams klasifikuoti

Tyrimo Nr.	Įėjimų skaičius	Įėjimų sluoksnio neuronų skaičius	Išėjimų sluoksnio neuronų skaičius	Aktyvavimo funkcija	Išėjimai
1	120	5	1	sigmoidinė	$[0 \div 1]$
2	120	15	1	sigmoidinė	$[0 \div 1]$
3	120	20	1	sigmoidinė	$[0 \div 1]$
4	120	25	1	sigmoidinė	$[0 \div 1]$


Analizuojami duomenys buvo suskirstyti į dvi grupes: mokymui ir testavimui. Didžioji dalis naudojama mokymui, t.y. 70% visų duomenų „sveikųjų“ ir „ligonių“ klasėje. Didėjant neuronų skaičiui, tinklų apmokymo procesas ilgėja. Kiekvienas neuroninis tinklas buvo apmokytas 10 kartų, todėl rezultate pateikiamos vidutinės reikšmės.

Pastebėta, kad neuronų tinklo klasifikavimo rezultatai buvo geriausi klasifikuojant „ligonių“ tiek mokymo grupę, tiek ir testavimo grupę. „Ligonių“ klasę sudarė 40 tiriamųjų, kurių klasifikavimo rezultatai buvo ne didesni nei 0,313998. Neuronų tinklas, kuriame įėjimų sluoksnyje yra 5 neuronų pagal „lm“ apmokymų funkciją, kuri apmoko tinklą pagal Levenbergo – Marquardto algoritimą. Greito apmokymo algoritmas pritaikymas vidutinio dydžio tinklams. Šie klasifikavimo rezultatai buvo geriausi lyginant su kitomis neuronų tinklo struktūromis bei klasifikavimo funkcijomis, klasifikuojant „ligonių“ tiek mokymo grupę, tiek ir testavimo grupę. (44 pav.).




44 pav. „Ligonių“ klasifikavimo rezultatai, priklausomai nuo neuronų skaičiaus įėjimo sluoksnyje

Tačiau apmokant neuronų tinklą pagal „lm“ funkciją, apmokymo procesas užtrunka ilgiausiai, todėl įvertinus „ligonių“ klasifikavimo rezultatus ir laiko sąnaudas, geriausi rezultatai gaunami apmokant pagal „gdx“ funkciją. Tai gradientinio nusileidimo funkcija, jautri apmokymų parametru dažniams. Jeigu apmokymų dažnis per mažas, tinklas per ilgai apsimokys. Optimalus apmokymų dažnis pasikeičia apmokymo proceso metu kai algoritmas kerta našumo paviršių. Pirmiausia yra suskaičiuojami pradinio tinklo išėjimai ir klaidos. Įvertinant esamą apmokymų dažnį, kiekvienoje epochoje yra suskaičiuojami nauji svoriai ir biasas. Vėliau nauji išėjimai bei klaidos yra perskaičiuojamos.



45 pav. "Ligonių" klasifikavimas, priklausomai nuo neuronų skaičiaus tinkle

Neuronų tinklas, kuriame įėjimų sluoksnyje yra 20 neuronų, klasifikavimo rezultatai buvo geriausi lyginant su kitomis neuronų tinklo struktūromis bei klasifikavimo funkcijomis, klasifikuojant „ligonių“ tiek mokymo grupę, tiek ir testavimo grupę. (45 pav.).



46 pav. „Sveikų“ klasifikavimo rezultatai, priklausomai nuo neuronų skaičiaus tinkle

Pastebėta, kad neuronų tinklas, kuriame įėjimų sluoksnyje yra 25 neuronų, klasifikavimo rezultatai buvo geriausi lyginant su kitomis neuronų tinklo struktūromis, klasifikuojant „sveikųjų“ tiek mokymo grupę, tiek ir testavimo grupę. Mokymų grupės visi klasifikavimo rezultatai buvo ne mažesni nei 0,9026 (46 pav.). Geriausi rezultatai gaunami tinklą vėl apmokant pagal „gdx“ funkciją. Dėl labai mažos „sveikųjų“ apmokymo grupės, testavimo grupės tiriamieji nebuvo priskirti „sveikųjų“ grupei. Klasifikavimo reikšmės kinta intervale [0.038; 0.5501].

DISKUSIJA

Buvo analizuoti trys skirtingą informaciją apimantys kardiosignalai: elektrokardiograma (EKG), impedanskardiograma (IKG) ir seismokardiograma (SKG). Tradiciškai, spektrinė analizė taikoma EKG dažnumų analizei, tuo tarpu IKG ir SKG dažnio charakteristikų vertinimui šis metodas nebuvo naudojamas. Visi trys kardiosignalai užregistruoti sinchroniškai, t.y. tuo pačiu metu. Buvo iširta 50 asmenų. Tiriamieji padalinti į dvi grupes. Iš anksto buvo žinoma, kad 40 iš jų turi sveikatos sutrikimų, t.y. serga išemine širdies liga su hipertenzija plaučių arterijoje, o 10 – sveikata nesiskundžia. „Sveikųjų“ grupei priklausė neištirti, šiuo metu nesergantys, tačiau senyvo amžiaus tiriamieji. Dėl „sveikųjų“ grupės neištyrimo ir gana garbaus amžiaus, tiriamieji gali priklausyti ir „ligonių“ grupei. Tiriamoji imtis labai maža, klasifikatorius gali būti apmokytas netiksliai, todėl klasifikatoriaus tikslesniam apmokymui reikalinga daug didesnė tiriamųjų imtis.

Kardiosignalai užrašyti 512 Hz diskretizavimo dažnumu. Darbe naudojome vienos minutės įrašus, kurių struktūra: 15 derivacijų po 30720 simbolių int16 formatu. Tačiau kiekvieno tiriamojo kardiosignalo signalo trukmė buvo skirtinga. Skirtumas tarp signalų vidutiniškai yra 512 reikšmių.

EKG dažniausiai analizuojama vizualiniu būdu, tačiau tobulėjant skaičiavimo technologijoms atsiranda galimybė kaupti vis didesnius kiekius informacijos bei atlikti tikslesnę duomenų analizę. Naudojantis technikos laimėjimais tikslinga kurti EKG, SKG ir IKG specializuotus apdorojimo algoritmus, kurie palengvintų ir pagreitintų diagnozės nustatymą. Magistro darbas skirtas naujų širdies signalų metodų paieškai ir kūrimui, o pagal gautus rezultatus galime teigti, kad polikardiosignalų koherencijos vertinimas ir spektrinis klasifikavimas gali būti naudingas širdies kraujagyslių bei plaučių sistemų ligų diagnostikai.

IŠVADOS

1. Tiriant signalų spektrines dedamąsias, „ligonių“ IKG signalas, lyginant su EKG ir SKG, turi didžiausią santykinį plotą.
2. Dažnių zonoje 0-10 Hz didžiausias santykinis plotas po koherencijos kreivėmis buvo gautas „sveikų“ grupėje – IKG-SKG, „ligonių“ grupėje – EKG-SKG.
3. Atvaizdavo „sveikųjų“ ir „ligonių“ klasifikavimo rezultatus pagal visų kardiosignalų trijų dažnio zonų plotų santykius po koherencijos kreivėmis, nustatėme, kad neuronų tinklai teisingai klasifikuoja tiriamuosius.
4. Pastebėjus kardiosignalų spektrų skirtumus, tiriamuosius klasifikuojame pagal EKG, IKG ir SKG 40 skirtingų zonų maksimalias reikšmes. Klasifikuojant tiek mokymo, tiek testavimo „ligonių“ grupes neuroniniu tinklu, kuriame įėjimų sluoksnyje yra 25 neuronai, klasifikavimo rezultatai buvo geriausi lyginant su kitomis neuronų tinklo struktūromis.
5. Polikardiosignalų koherencijos vertinimas ir spektrinis klasifikavimas gali būti naudingas širdies kraujagyslių bei plaučių sistemų ligų diagnostikai.
6. Visi duomenų apdorojimo, klasifikavimo algoritmai ir funkcijos buvo realizuoti MatLab programinėje aplinkoje. Sukurta programinė įranga bus įjungta į KMU Kardiologijos institute kuriamą klinikinių sprendimų palaikymo sistemą, skirtą lėtinio širdies nepakankamumo bei išeminės širdies ligos diagnostikai.

PADĖKA

Magistrinio darbo rašymas būtų neįmanomas be kitų pagalbos, asmeninių patarimų ir pastabų. Pirmiausia, norėčiau padėkoti vadovui prof. Zenonui Navickui už raiškios ir aiškios matematinės idėjos kuravimą. Medicininės idėjos ir kardiosignalų panašumo tyrimas kilo iš daugelio diskusijų su dr. Liudu Gargasu, siekiant pagrindinio tikslo – atskirti ligonius ir sveikuosius. Taip pat labai norėčiau padėkoti prof. Alfonsui Vainorui. Manau, kad be prof. Alfonso Vainoro mano magistro darbas būtų dukart siauresnis. Ačiū visiems už palaikymą ir kantrybę.

LITERATŪRA

1. Lipman B. S. and Massie E. Clinical Scalar Electrocardiography. Year Book Medical Publishers, Chicago, USA, 1975.
2. Salerno D. M. and Zanetti J. Seismocardiography: A New Technique for Recording Cardiac Vibrations. Concept, Method, and Initial Observations. J Cardiovasc Technol 1990; 9: 111-118.
3. Wilson R.A., Bamrah V.S., Linsay J et al. Diagnostic Accuracy of Seismocardiography Compared with Electrocardiography for the Anatomie and Physiologie Diagnosis of Coronary Artery Disease During Exercise Testing. J Cardiol 1993; 71: 536-545.
4. Salerno D.M., Zanetti J.M., Green L.A. et al. Seismocardiographic Changes Associated with Obstruction of Coronary Blood Flow During Ballon Angioplasty. Am J Cardiol 1991; 68: 201-207.
5. Woltjer H. H., Bogaard H. J., de Vries P. M. The technique of impedance cardiography. Am Heart J 1997; 18: 1396-1403.
6. Gargasas L., Janušauskas A., Lukoševičius A., Vainoras A., Ruseckas R., Korsakas S., Miškinis V. Development of methods for monitoring of electrocardiograms, impedance cardiograms and seismocardiograms. Studies in health technology and informatics 2004; 105: 131-141.
7. Švėgžda O. Taikomoji informacijos teorija. Mokslas, 1980; 160 p.
8. Valantinas J. Diskrečiosios transformacijos. Technologija, 1992; 79 p.
9. Krivickas R. Skaitmeninis signalų apdorojimas. Mokslas, 1984; 126 p.
10. Pekarskas V. Diferencialinis ir integralinis skaičiavimas (I dalis). 2000, 239 p.
11. Marple S. L. Jr. Digital Spectral Analysis with Applications. Prentice Hall, Englewood Cliffs, NJ, 1987
12. Kay S. M. Modern Spectral Estimation: Theory and Application. Prentice Hall, Englewood Cliffs, NJ, 1988.
13. Stoica P. and Moses R. L. Introduction to Spectral Analysis. Prentice Hall, Upper Saddle River, NJ, 1997.
14. Capon J. High resolution frequency-wave number spectrum analysis. Proc IEEE 1969; 57: 1408–1418.
15. Lacoss R. T. Data adaptive spectral analysis methods. Geophysics 1971; 36: 661–675.
16. Stoica P., Jakobsson A. and Li J. Matched-filter bank interpretation of some spectral estimators. Signal Processing 1998; 66: 45–59.

17. Welch P. D. The use of fast Fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms. *IEEE Trans Audio Electroacoust* 1967; AU-15: 70–73.
18. Carter G. C., Knapp C. H. and Nuttall A. H. Estimation of the magnitude-squared coherence function via overlapped fast Fourier transform processing. *IEEE Trans Audio Electroacoust* 1973; AU-21: 337–344.
19. Verikas A., Gelžinis A. Neuroniniai tinklai ir neuroniniai skaičiavimai. *Technologija*, 2003; 175 p.

1 PRIEDAS Programos tekstas

```

% Dskretizavimo daznis kaskek lako nuimamas sgnalas
Fs = 512;
% Duomenu failo pavadinimas
duom_failas = '38kks-3';
% Atdaromas failas ir is failo istraukimi reikalingi duomenys
failas = fopen(duom_failas,'r');
fseek(failas, 0, 'eof');
failo_dydis = ftell(failas);
%fclose(failas);
der_sk = (failo_dydis - 512)/10240;

failas = fopen(duom_failas,'r');
for j = 1:der_sk
    fseek(failas, 512 + 10240 * (j-1), 'bof');
    duom = fread(failas, 5120, 'int16');
    duom = duom - min(duom);
    duom = duom / max(duom);
    for i =1:length(duom)
        duoml(i,j) = duom(i);
    end;
end;
% Uzdaromas atidarytas failas
fclose(failas);

% Issirenkami reikalingi duomenys 2, 12, 13, 15 kanalai
% Is 12 kanalo duomenu yra nustatoma R danteliu padetis
X12 = duoml(:,12);
X2 = duoml(:,2);
X13 = duoml(:,13);
X15 = duoml(:,15);

% delta X pastovus intervalas
SegmentLength = 420;
% epsilon
epsilon = 170;
% Tarpiniai kintamieji
n = 1;
i = SegmentLength;
m = i + epsilon;
AA = 0;
ii = 0;
% Pirmo intervalo maksimumas maksimumas
X1max = 0;
% Antro intervalo maksimumas maksimumas
X2max = 0;
% rasto pirmojo maksimumo indeksas
inX1max = 0;
% rasto antrojo maksimumo indeksas
inX2max = 0;

while (i < length(X12))
    ii = ii + 1;
    X1max = max(X12(n:i));
    inX1max = find(X12(n:i)==X1max);
    X2max = max(X12(n:m));
    inX2max = find(X12(n:m)==X2max);
    if (X1max > X2max)
        AA(ii) = inX1max + n - 1;
    end
    if (X1max == X2max)
        AA(ii) = max(inX1max) + n - 1;
    end
end

```

```

end
if (X1max < X2max)
    AA(ii) = inX2max + n - 1;
end
n = m;
i = n + SegmentLength;
m = i + epsilon;
% salyga naudoja kadangi paskutinis intervalas yra trumpesnis
% nei delta x + epsilon tai paskutinis intervalas lygus lkusiam ilgiui
if m > length(X12)
    m = length(X12);
end
end
end
% maksimalus skirtumas tarp R danteliu naudojamas pradiniam matricos ilgiui
% nusistatyti
maxDiff = max(abs(diff(AA)));

% pradines matricos kuriose bus saugomos reikšmes 2, 13 15 kanalu
X2s = zeros(maxDiff,length(AA)-1);
X13s = zeros(maxDiff,length(AA)-1);
X15s = zeros(maxDiff,length(AA)-1);

% ciklas sukaidantis duomenis nuo R iki R
for j=1:length(AA)-1
    Diff = abs(AA(j) - AA(j+1));
    for i = 1:Diff
        if (AA(j)+i-128 <= 0)
            X2s(i,j) = 0;
            X13s(i,j) = 0;
            X15s(i,j) = 0;
        else
            X2s(i,j) = X2(AA(j)+i-128);
            X13s(i,j) = X13(AA(j)+i-128);
            X15s(i,j) = X15(AA(j)+i-128);
        end
    end
end
end

% furje transformacija suvidurkintu duomenu
[f, av_mX2s] = FFT_transf(Fs,mean(X2s,2));
[f, av_mX13s] = FFT_transf(Fs,mean(X13s,2));
[f, av_mX15s] = FFT_transf(Fs,mean(X15s,2));
a111=0;
a222=0;
a333=0;

a111=av_mX2s; % EKG
a222=av_mX13s; % Reograma
a333=av_mX15s; % Seismograma

%a111 = smooth(av_mX2s, 'lowess');
%a222 = smooth(av_mX13s, 'lowess');
%a333 = smooth(av_mX15s, 'lowess');

% furje transformacija nesuvidurkintu duomenu
[f, mX2s] = FFT_transf(Fs,X2s);
[f, mX13s] = FFT_transf(Fs,X13s);
[f, mX15s] = FFT_transf(Fs,X15s);

% Vaizdavimas

figure(1)
plot(f, av_mX2s,'b'), grid on, title('2, 13, 15 kanalu R - R atkarpu spektras');

```

```

hold on
plot(f, av_mX13s,'r');
hold on
plot(f, av_mX15s,'g');
hold on
plot(f, a111,'y');
hold on
plot(f, a222,'c');
hold on
plot(f, a333,'m'), xlabel('Hz'), ylabel('Amplitude'), legend('EKG', 'reograma',
'seismograma', 'EKG_1', 'reograma_1', 'seismograma_1'),axis tight;
hold on

figure(2)
plot(f, a111,'b'), grid on, title('2, 13, 15 kanalu R - R atkarpu spektras');
hold on
plot(f, a222,'r');
hold on
plot(f, a333,'g'), xlabel('Hz'), ylabel('Amplitude'), legend('EKG_1',
'reograma_1', 'seismograma_1'),axis tight;
hold on

figure(3)
subplot(221),plot(f, mX2s),grid on,title('2 kanalo R - R atkarpu spektrai'),
xlabel('Hz'), ylabel('Amplitude'), axis tight;
subplot(222),plot(f, mX13s),grid on,title('13 kanalo R - R atkarpu spektrai'),
xlabel('Hz'), ylabel('Amplitude'), axis tight;
subplot(223),plot(f, mX15s),grid on,title('15 kanalo R - R atkarpu spektrai'),
xlabel('Hz'), ylabel('Amplitude'), axis tight;

figure(4)
plot(f, av_mX2s,'b'), grid on, title('2, 13, 15 kanalu R - R atkarpu spektras');
hold on
plot(f, av_mX13s,'r');
hold on
plot(f, av_mX15s,'g'), xlabel('Hz'), ylabel('Amplitude'), legend('EKG-250ms',
'reograma-250ms', 'seismograma-250ms'),axis tight;
hold on

=====
y=a111;
y=y(1:100);
A = reshape(y, [5,20]);
s= simpsum(y);
A1=simpsum(A(:,1)); A2=simpsum(A(:,2)); A3=simpsum(A(:,3)); A4=simpsum(A(:,4));
A5=simpsum(A(:,5)); A6=simpsum(A(:,6)); A7=simpsum(A(:,7)); A8=simpsum(A(:,8));
A9=simpsum(A(:,9)); A10=simpsum(A(:,10)); A11=simpsum(A(:,11));
A12=simpsum(A(:,12)); A13=simpsum(A(:,13)); A14=simpsum(A(:,14));
A15=simpsum(A(:,15)); A16=simpsum(A(:,16)); A17=simpsum(A(:,17));
A18=simpsum(A(:,18)); A19=simpsum(A(:,19)); A20=simpsum(A(:,20));

XX = [A1;A2;A3;A4;A5;A6;A7;A8;A9;A10;A11;A12;A13;A14;A15;A16;A17;A18;A19;A20];
sumaA=sum(XX);

AS11=A1/sumaA; AS22=A2/sumaA; AS33=A3/sumaA; AS44=A4/sumaA; AS55=A5/sumaA;
AS66=A6/sumaA; AS77=A7/sumaA; AS88=A8/sumaA; AS99=A9/sumaA;
AS101=A10/sumaA; AS111=A11/sumaA; AS121=A12/sumaA; AS131=A13/sumaA;
AS141=A14/sumaA; AS151=A15/sumaA; AS161=A16/sumaA; AS171=A17/sumaA;
AS181=A18/sumaA; AS191=A19/sumaA; AS100=A20/sumaA;

y=a222;
y=y(1:100);
B = reshape(y, [5,20]);
s= simpsum(y);

```

```

B1=simpsum(B(:,1)); B2=simpsum(B(:,2)); B3=simpsum(B(:,3)); B4=simpsum(B(:,4));
B5=simpsum(B(:,5)); B6=simpsum(B(:,6)); B7=simpsum(B(:,7)); B8=simpsum(B(:,8));
B9=simpsum(B(:,9)); B10=simpsum(B(:,10)); B11=simpsum(B(:,11));
B12=simpsum(B(:,12));
B13=simpsum(B(:,13)); B14=simpsum(B(:,14)); B15=simpsum(B(:,15));
B16=simpsum(B(:,16)); B17=simpsum(B(:,17));
B18=simpsum(B(:,18));B19=simpsum(B(:,19)); B20=simpsum(B(:,20));

YY = [B1;B2;B3;B4;B5;B6;B7;B8;B9;B10;B11;B12;B13;B14;B15;B16;B17;B18;B19;B20];
sumaB=sum(YY);
BS11=B1/sumaB; BS22=B2/sumaB; BS33=B3/sumaB; BS44=B4/sumaB; BS55=B5/sumaB;
BS66=B6/sumaB; BS77=B7/sumaB; BS88=B8/sumaB; BS99=B9/sumaB; BS101=B10/sumaB;
BS111=B11/sumaB; BS121=B12/sumaB; BS131=B13/sumaB;
BS141=B14/sumaB; BS151=B15/sumaB; BS161=B16/sumaB; BS171=B17/sumaB;
BS181=B18/sumaB; BS191=B19/sumaB; BS100=B20/sumaB;

y=a333;
y=y(1:100);
C = reshape(y,[5,20]);
s= simpsum(y);
C1=simpsum(C(:,1)); C2=simpsum(C(:,2));C3=simpsum(C(:,3)); C4=simpsum(C(:,4));
C5=simpsum(C(:,5));C6=simpsum(C(:,6)); C7=simpsum(C(:,7)); C8=simpsum(C(:,8));
C9=simpsum(C(:,9)); C10=simpsum(C(:,10)); C11=simpsum(C(:,11));
C12=simpsum(C(:,12)); C13=simpsum(C(:,13)); C14=simpsum(C(:,14));
C15=simpsum(C(:,15)); C16=simpsum(C(:,16)); C17=simpsum(C(:,17));
C18=simpsum(C(:,18));
C19=simpsum(C(:,19)); C20=simpsum(C(:,20));

ZZ = [C1;C2;C3;C4;C5;C6;C7;C8;C9;C10;C11;C12;C13;C14;C15;C16;C17;C18;C19;C20];
sumaC=sum(ZZ);
CS11=C1/sumaC; CS22=C2/sumaC; CS33=C3/sumaC; CS44=C4/sumaC; CS55=C5/sumaC;
CS66=C6/sumaC; CS77=C7/sumaC; CS88=C8/sumaC; CS99=C9/sumaC; CS101=C10/sumaC;
CS111=C11/sumaC; CS121=C12/sumaC; CS131=C13/sumaC; CS141=C14/sumaC;
CS151=C15/sumaC; CS161=C16/sumaC; CS171=C17/sumaC; CS181=C18/sumaC;
CS191=C19/sumaC; CS100=C20/sumaC;

XXX=[AS11 AS22 AS33 AS44 AS55 AS66 AS77 AS88 AS99 AS101 AS111 AS121 AS131 AS141
AS151 AS161 AS171 AS181 AS191 AS100 BS11 BS22 BS33 BS44 BS55 BS66 BS77 BS88 BS99
BS101 BS111 BS121 BS131 BS141 BS151 BS161 BS171 BS181 BS191 BS100 CS11 CS22 CS33
CS44 CS55 CS66 CS77 CS88 CS99 CS101 CS111 CS121 CS131 CS141 CS151 CS161 CS171
CS181 CS191 CS100];

```

```
function [MSC]=coherence_MVDR(x1,x2,L,K);
```

```

xx1      = zeros(L,1);
xx2      = zeros(L,1);
r11      = zeros(L,1);
r22      = zeros(L,1);
r12      = zeros(L,1);
r21      = zeros(L,1);

F        = zeros(L,K);
l        = [0:L-1]';
f        = exp(2*pi*l*j/K);
for k = 0:K-1
    F(:,k+1) = f.^k;
end
F        = F/sqrt(L);

n        = length(x1);

for i = 1:n
    xx1 = [x1(i);xx1(1:L-1)];
    xx2 = [x2(i);xx2(1:L-1)];

```

```

    r11 = r11 + xx1*conj(xx1(1));
    r22 = r22 + xx2*conj(xx2(1));
    r12 = r12 + xx1*conj(xx2(1));
    r21 = r21 + xx2*conj(xx1(1));
end
r11 = r11/n;
r22 = r22/n;
r12 = r12/n;
r21 = r21/n;
%
R11 = toeplitz(r11);
R22 = toeplitz(r22);
R12 = toeplitz(r12,conj(r21));
%
Dt1 = 0.01*r11(1)*diag(diag(ones(L)));
Dt2 = 0.01*r22(1)*diag(diag(ones(L)));
%
Ri11 = inv(R11 + Dt1);
Ri22 = inv(R22 + Dt2);
Rn12 = Ri11*R12*Ri22;
%
Si11 = real(diag(F'*Ri11*F));
Si22 = real(diag(F'*Ri22*F));
S12 = diag(F'*Rn12*F);
%
MSC = real(S12.*conj(S12))./(Si11.*Si22);

K = 5120;
L = 1000;
[MSC]=coherence_MVDR(x1,x2,L,K);
%
MSCf = MSC(1:K);
wwf = [0:10/K:10-10/K]';
%
plot(wwf ,MSCf)
grid on;
ylabel('MSC');
xlabel('Daznis, Hz');

clear all

Fs = 512;

FileName1 = 'cc5.ilg';

duom_failas = FileName1;

failas = fopen(duom_failas,'r');
data = fread(failas);
fclose(failas);
[n m] = size(data);

delta = 512;

der_ilgis = round((n - 512)/15);

A = data(513:der_ilgis - delta);
B = data(der_ilgis+512:der_ilgis*2 - delta);
C = data(der_ilgis*2+512:der_ilgis*3 - delta);
D = data(der_ilgis*3+512:der_ilgis*4 - delta);
E = data(der_ilgis*4+512:der_ilgis*5 - delta);
F = data(der_ilgis*5+512:der_ilgis*6 - delta);
G = data(der_ilgis*6+512:der_ilgis*7 - delta);

```

```

H = data(der_ilgis*7+512:der_ilgis*8 - delta);
I = data(der_ilgis*8+512:der_ilgis*9 - delta);
K = data(der_ilgis*9+512:der_ilgis*10 - delta);
L = data(der_ilgis*10+512:der_ilgis*11 - delta);
M = data(der_ilgis*11+512:der_ilgis*12 - delta);
N = data(der_ilgis*12+512:der_ilgis*13 - delta);
P = data(der_ilgis*13+512:der_ilgis*14 - delta);
R = data(der_ilgis*14+512:der_ilgis*15 - delta);

% Issirenkami reikalingi duomenys 2, 12, 13, 15 kanalai
% Is 12 kanalo duomenu yra nustatoma R danteliu padetis
EKG = M;
IKG = N;
SKG = R;

    x = [EKG IKG SKG];
% x = [EKG];
% x = [IKG];
% x = [SKG];

[a aa]=FFT_transf(512, x);

figure(1)

subplot(3,1,1), plot(a(find(a<=0.1)),aa(find(a<=0.1),1)),title('EKG'),axis([0 0.1
0 20]), grid on, xlabel('daznis, Hz'), ylabel('Amplitude');
subplot(3,1,2), plot(a(find(a<=0.1)),aa(find(a<=0.1),2)),title('IKG'),axis([0 0.1
0 20]), grid on, xlabel('daznis, Hz'), ylabel('Amplitude');
subplot(3,1,3), plot(a(find(a<=0.1)),aa(find(a<=0.1),3)),title('SKG'),axis([0 0.1
0 20]), grid on, xlabel('daznis, Hz'), ylabel('Amplitude');

figure(2)
grid on
subplot(3,1,1), plot(a(find(a<=1)),aa(find(a<=1),1)),title('EKG'),axis([0 1 0
20]), grid on, xlabel('daznis, Hz'), ylabel('Amplitude');
subplot(3,1,2), plot(a(find(a<=1)),aa(find(a<=1),2)),title('IKG'),axis([0 1 0
20]), grid on, xlabel('daznis, Hz'), ylabel('Amplitude');
subplot(3,1,3), plot(a(find(a<=1)),aa(find(a<=1),3)),title('SKG'),axis([0 1 0
20]), grid on, xlabel('daznis, Hz'), ylabel('Amplitude');

figure(3)
grid on
subplot(3,1,1), plot(a(find(a<=10)),aa(find(a<=10),1)),title('EKG'),axis([0 10 0
20]), grid on, xlabel('daznis, Hz'), ylabel('Amplitude');
subplot(3,1,2), plot(a(find(a<=10)),aa(find(a<=10),2)),title('IKG'),axis([0 10 0
20]), grid on, xlabel('daznis, Hz'), ylabel('Amplitude');
subplot(3,1,3), plot(a(find(a<=10)),aa(find(a<=10),3)),title('SKG'),axis([0 10 0
20]), grid on, xlabel('daznis, Hz'), ylabel('Amplitude');

figure(4)
grid on
subplot(3,1,1), plot(a(find(a<=100)),aa(find(a<=100),1)),title('EKG'),axis([0 100
0 20]), grid on, grid on, xlabel('daznis, Hz'), ylabel('Amplitude');
subplot(3,1,2), plot(a(find(a<=100)),aa(find(a<=100),2)),title('IKG'),axis([0 100
0 20]), grid on, grid on, xlabel('daznis, Hz'), ylabel('Amplitude');
subplot(3,1,3), plot(a(find(a<=100)),aa(find(a<=100),3)),title('SKG'),axis([0 100
0 20]), grid on, grid on, xlabel('daznis, Hz'), ylabel('Amplitude');

function    s=simpsum(y,DEL)

```



```

[a,b]=size(y);
if a==1
    y=y(:);
end
[N,b]=size(y);
if nargin<2,DEL=1;
else
    if length(DEL)==size(y,2)
        DEL=DEL(:).';
    end
end
h=DEL/(N-1);
if rem(N,2)==0
s=sum(y)-5/8*(y(1,:)+y(N,:))+(y(2,:)+y(N-1,:))/6-(y(3,:)+y(N-2,:))/24;
s=s.*h;
else
s=(2*sumv(y(3:2:N-2,:))+4*sumv(y(2:2:N-1,:))+y(1,:)+y(N,:)).*h/3;
end
function s=sumv(V)
a=size(V,1);
if a==1
    s=V;
else
    s=sum(V);
end
end

```

2 PRIEDAS Straipsnis: Polikardiosignalų skleidimo Furjė eilute savybės

Publikacijos rūšis: Straipsnis recenzuojamoje Lietuvos tarptautinės konferencijos medžiagoje
Leidinyje: Biomedicininė inžinerija = Biomedical engineering : tarptautinės konferencijos pranešimų medžiaga / Kauno technologijos universitetas. ISBN 9955-25-151-4. Kaunas, 2006, p. 53-56

Polikardiosignalų skleidimo Furjė eilute savybės

G.Keršulytė¹, Z.Navickas¹, A.Vainoras², L.Gargasas²

¹Kauno Technologijos universitetas, ²KMU Kardiologijos institutas


Ižanga. Efektyvus širdies kraujagyslių susirgimų diagnostikos problemų sprendimas įmanomas kuriant ir taikant naujas kardiosignalų analizės informacines technologijas, nes nemaža dalis širdies susirgimų diagnostinių kriterijų gaunama registruojant ir analizuojant kardiosignalus, kurie atspindi tiek elektrinės širdies veiklos sutrikimus (EKG), tiek ir hemodinaminės bei mechaninės veiklos pokyčius, t.y. impedanskardiograma (IKG) ir seismokardiograma (SKG) [1]. Jau kelis dešimtmečius Furjė transformacija taikoma EKG dažnumų analizei, tuo tarpu kai IKG ir SKG dažnio charakteristikų vertinimui šis metodas nebuvo naudojamas. Darbo tikslas buvo pritaikyti Furjė analizę įvertinant bei palyginant trijų sinchroniškai užregistruotų signalų - EKG, IKG ir SKG dažnio charakteristikas.

Metodika. Norint signalą analizuoti dažnių srityje, jį reikia konvertuoti iš laiko srities į dažnių sritį. Šiam tikslui yra naudojama Furjė transformacija, o tiksliau, diskretinė Furjė transformacija, nes signalas yra ne tolydinis, o diskretinis. Diskretinė Furjė transformacija išreiškiama (1) formule, kuri atspindi informaciją apie kiekvieną dažnį.


$$C_x(k) = \frac{1}{N} \sum_{m=0}^{N-1} X(m) \cdot W^{km} = \frac{1}{N} [X(0) + X(1) \cdot W + X(2) \cdot W^{2k} + \dots + X(N-1) \cdot W^{(N-1)k}] \quad (1)$$

čia $W = e^{-i\frac{2\pi}{N}}$, $i^2 = -1$, $k = 0, 1, \dots, N-1$.

Darbe buvo analizuojami trys skirtingą informaciją nešantys kardiosignalai: elektrokardiograma (EKG), impedanskardiograma (IKG) ir seismokardiograma (SKG). Analizės metu buvo suformuotas matrica iš n stulpelių, kurių skaičių n apsprendė bangų skaičius analizuojamame signale. Tolimesnėje analizėje naudojamos vidutinės intervalų R-R reikšmės, t.y. MR-R. Furjė transformacija yra pritaikoma MR-R intervalui. Duomenų paruošimo procedūra pateikta 1 pav. Atlikus paruošimo procedūrą, gaunami EKG, SKG, IKG signalų spektrai, t.y. Furjė transformacijos, pateiktos 2 pav. Signalas turi mažą amplitudę ir stiprią nuolatinę dedamąją, yra pasiskirstęs dažnių srityje 0-60 Hz. Spektras primena triukšmingą impulsinę charakteristiką. Signalai, pervesti į dažnių sritį, buvo padalinti į 20 atkarpėlių, 5 Hz juostomis. Pagal Simpsono metodą, apskaičiavome kiekvienos dalelės plotą. Tolimesniuose grafikuose pavaizduotos kreivės vaizduoja dalelės ploto santykį su visu signalo plotu. Duomenys buvo analizuojami Matlab paketu. Buvo iširta 16 asmenų EKG, IKG ir SKG.




1 pav. Duomenų paruošimo metodas




2 pav. EKG, SKG, IKG signalų Furjė transformacijos

Rezultatai ir jų aptarimas. EKG maksimalių plotų santykių kreivė maksimalias reikšmes pasiekia pirmoje atkarpoje. Plotas sudaro 52-58% viso signalo ploto. IKG ir SKG maksimalių plotų santykių kreivės maksimalias reikšmes taip pat pasiekia pirmoje atkarpoje. Plotai svyruoja atitinkamai 57-61% ir 51-58%. Lyginant signalų maksimalių plotų santykius, didžiausią plotų santykį turi IKG. EKG vidutinių plotų santykių kreivė reikšmes pasiekia taip pat pirmoje atkarpoje (3 pav.). Plotas sudaro 46-53% viso signalo ploto. IKG (4 pav.) ir SKG (5 pav.) plotų santykių kreivės vidutinių plotų reikšmės svyruoja atitinkamai 54-56% (4 pav.) ir 45-49% (5 pav.). Lyginant signalų plotų santykius, didžiausią plotų santykį turi IKG.




3 pav. EKG vidutinis plotas



4 pav. IKG vidutinis plotas

EKG minimalių plotų santykių kreivė maksimalias reikšmes pasiekia pirmoje atkarpoje. Ir jų plotas sudaro 36-50% viso signalo ploto. IKG ir SKG minimalių plotų santykių kreivės maksimalias reikšmes pirmoje atkarpoje užima atitinkamai 50-52% ir 37-42%. Lyginant signalų plotų santykius, didžiausią plotų santykį turi IKG.



5 pav. SKG vidutinis plotas

Išvados: Visuose signaluose didžiausią santykinę plotą užima pirmosios dvi atkarpos, t.y. 0-10 Hz. IKG signalas, lyginant su EKG ir SKG, turi didžiausią santykinę plotą. Visi kiti santykiniai plotai eksponentiškai artėja prie 0. Signalai turi mažą amplitudę ir stiprią nuolatinę dedamąją. Tęsiant darbą, galima ieškoti būdų apskaičiuoti signalo charakteristikas, pagal kurias būtų įvertintas širdies darbas ir sutrikimai.

LITERATŪRA:

1. Gargasas L., Janušauskas A., Lukoševičius A., Vainoras A., Ruseckas R., Korsakas S., Miškinis V. Development of methods for monitoring of electrocardiograms, impedance cardiograms and seismocardiograms // Studies in health technology and informatics. ISSN 0926-9630. 2004; vol. 105: 131-141.
2. Pekarskas V. Diferencialinis ir integralinis skaičiavimas ISBN 9986-13-416-1 (I dalis) 2000; P.239.

Features of Furje transform applied to polycardiosignals

G.Keršulytė, Z.Navickas, A.Vainoras, L.Gargasas

Kaunas University of Technology, Institute of Cardiology, Kaunas University of Medicine, Lithuania

Previously Fourier series were applied to frequency analysis of EKG, but this method was not applied to estimation of IKG and SKG frequency characteristics. In this paper, the frequency analysis method was applied to three cardio signals, because they reflect the electrical and mechanical work of the human heart better as one EKG signal. The purpose is to adapt Fourier transformation to assessing and comparing the characteristics of hereinbefore signals. Signals transformed into frequency domain, were divided into 20 zones and were evaluated the area of each zone. In all signals, the biggest comparative area occupied the first two zones, i.e., 0-10 Hz. IKG signal has the biggest comparative area. All other comparative areas approach zero by exponent.

3 PRIEDAS Straipsnis: Polycardiosignals Coherence Evaluation Results for Patients with Cardiopulmonary Diseases

Publikacijos rūšis: Straipsnis LMT patvirtintose DB.

Leidinyje: Electronics and Electrical Engineering = Электроника и электротехника = Elektronika ir elektrotechnika. ISSN 1392-1215. Kaunas. 2007, nr. 5(77), p. 41-44

ELECTRONICS AND ELECTRICAL ENGINEERING
 ISSN 1392 – 1215 ————— 2007. No. 5(77)
ELEKTRONIKA IR ELEKTROTECHNIKA

MEDICINE TECHNOLOGY
 T 115 —————
MEDICINOS TECHNOLOGIJA

Policardiosignals Coherence Evaluation Results for Patients with Cardiopulmonary Diseases

G. Keršulytė, Z. Navickas

Kaunas University of Technology,

Studentų st. 50, LT-51368 Kaunas, Lithuania, tel.: +370 650 81853; e-mail: gintarei2001@yahoo.com

J. Blužas, L. Gargasas, A. Vainoras, R. Ruseckas

Sukilėlių st.,17,LT-50009 Kaunas, Lithuania, tel.:+ 370 687 92517; e-mail: liudas.gargasas@med.kmu.lt

S. Sadauskas, A. Naudžiūnas

Josvainių st.,2,LT-47144 Kaunas, Lithuania, tel.:+ 370 610 01665; e-mail: 0917@one.lt

Introduction

The spectral estimation plays a major role in signal processing. It has numerous applications in diversified fields such as radar, sonar, speech, communications, biomedical, etc [1,2,3]. One of the most well-known non-parametric spectral estimation algorithms is the Capon's approach, which is also known as minimum variance distortion less response (MVDR) [4,5]. This technique was extensively studied and is considered as a high-resolution method. The MVDR spectrum can be viewed as the output of a bank of filters, with each filter centered at one of the analysis frequencies. Its band pass filters are both data and frequency dependent which is the main difference with a periodogram-based approach where its band pass filters are a discrete Fourier matrix, which is both data and frequency independent [3,6].

The objective of this paper is to adapt Fourier transformation to assessing and comparing the characteristics of hereinbefore signals and coherence between each of signal.

Theoretical Background

There were analyzed 3 different information carrying cardiosignals: electrocardiogram (ECG), impedance

cardiogram (ICG) and seismocardiogram (SCG). All these cardio signals different: ECG shows electric heart activity, ICG – hemodynamic activity disturbance and SCG - mechanic activity changing. These three signals were recorded at the same time, so they describe the activity of person heart from three different sides.

The magnitude squared coherence (MSC) function is as an alternative to the popular Welch's method [7,8]. We define the magnitude squared coherence (MSC) function between two signals $x_1(n)$ and $x_2(n)$ as

$$\gamma_{x_1, x_2}^2(w_k) = \frac{|S_{x_1, x_2}(w_k)|^2}{S_{x_1, x_1}(w_k) S_{x_2, x_2}(w_k)}, \quad (1)$$

$$S_{x_1, x_2}(w_k) = \frac{f_k^H R_{x_1, x_1}^{-1} R_{x_1, x_2} R_{x_2, x_2}^{-1} f_k}{\left[f_k^H R_{x_1, x_1}^{-1} f_k \right] \cdot \left[f_k^H R_{x_2, x_2}^{-1} f_k \right]}. \quad (2)$$

We deduce the magnitude-squared cross spectrum:

$$S_{x_1, x_2}(w_k) = \frac{\left[f_k^H R_{x_1, x_1}^{-1} R_{x_1, x_2} R_{x_2, x_2}^{-1} f_k \right]^2}{\left[f_k^H R_{x_1, x_1}^{-1} f_k \right]^2 \cdot \left[f_k^H R_{x_2, x_2}^{-1} f_k \right]^2}. \quad (3)$$

using expressions

$$S_{x_p x_p}(w_k) = \frac{1}{f_k^H R_{x_p x_p}^{-1} f_k}, p = 1, 2, \quad (4)$$

where $R_{x_p x_p} = E\{x_p(n)x_p^H(n)\}$ is the covariance matrix of the signal $x_p(n)$ and

$$x_p(n) = [x_p(n) \quad x_p(n-1) \quad \dots \quad x_p(n-L+1)]^T. \quad (5)$$

Consider the $(L \times K)$ matrix

$$F = [f_0 \quad f_1 \quad \dots \quad f_{K-1}], \quad (6)$$

where

$$f_k = \frac{1}{\sqrt{L}} [1 \quad \exp(jw_k) \quad \dots \quad \exp(jw_k(L-1))]^T, \quad (7)$$

where $w_k = 2\pi k / K; k = 0, 1, \dots, K-1$. For $K=L$, F is called the Fourier matrix and is unitary, i.e. $F^H F = F F^H = I$ and (2) in (1), the MSC becomes

$$\gamma_{x_1 x_2}^2(w_k) = \frac{[f_k^H R_{x_1 x_1}^{-1} R_{x_1 x_2} R_{x_2 x_2}^{-1} f_k]^2}{[f_k^H R_{x_1 x_1}^{-1} f_k] \cdot [f_k^H R_{x_2 x_2}^{-1} f_k]}. \quad (8)$$

Results

The training and testing sets were received from the data base, accumulated in the Institute of Cardiology and in the Clinic of Internal Diseases of Kaunas University of Medicine. This data base contains five groups of persons: 35pts with cardiovascular diseases and hypertension in pulmonary artery; 74pts with cardiovascular diseases but without hypertension in pulmonary artery; 15pts with pulmonary diseases but without hypertension in pulmonary artery; 20pts with pulmonary diseases and hypertension in pulmonary artery; 10 persons without cardiopulmonary diseases.




Fig. 1. Coherence of "healthy" persons

From this database 30 persons were recruited for experimental testing. These persons were divided into 2 groups: 20 of them had cardiovascular diseases and hypertension in pulmonary artery, 10 others – hadn't any big gripe about the health.




Fig. 2. Coherence of "sick" persons

Three cardiosignals were recorded at the same time. Results show, that coherence curves are different between recruited groups. All coherences of "healthy" persons are similar: they have the same number of peaks and coherence between all three signals are big and almost the same (Fig.1). Mean value of coherence curve varies around 0.4-0.5 in the peaks. The second maximum value of coherence curve is around 0.68-0.72 at frequency 11 Hz or 32 Hz.

Conversely, the coherence of all cardiosignals of patient is low (Fig.2) and has very different meaning in the same peak (Fig.3). Mean value of "sick" coherence curve varies around 0.30-0.38 in the peaks. The second maximum value of coherence curve is around 0.72-0.42 at frequency 11 Hz or 32 Hz.




Fig. 3. Coherence of "sick" persons

Using method of Simpson the areas of each coherence curve were calculated. The areas of three different coherence curves of each person are shown in the figure 4. The results shows that a certain hyper plane can be drawn which divides a space in two parts. Moreover, a classification can be done from estimated coherence parameters.




Fig. 4. Coherence areas

Finally, all coherence curves were splitted into three different size zones: 0-10 Hz, 11-35 Hz and 36-50 Hz.




Fig. 5. Relative area of coherence curve, 0-10 Hz

Comparing relative areas of coherence curves of the first part was mentioned, that the biggest area of “healthy” people took ICG-SCG coherence and of “sick” people – ECG-SCG coherence, accordingly about 85% and about 86,50% (Fig.5).

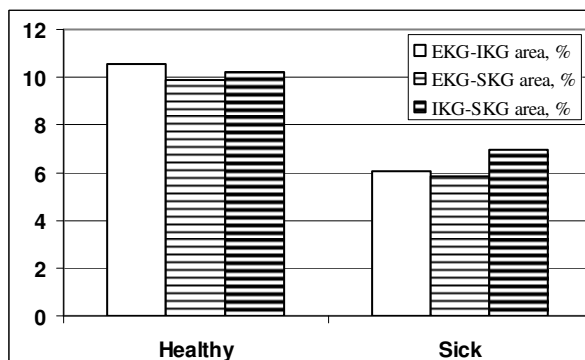


Fig. 6. Relative area of coherence curve, 11-35 Hz

In the second part (11-35 Hz) was mentioned, that relative areas of coherences curves took rather similar parts: relative area of coherence curves of “healthy” people

was about 10% and relative area of coherence curves of “sick” people was about 6% only (see Fig.6).




Fig. 7. Relative area of coherence curve, 36-50 Hz

Conversely, in the last part relative area of coherence curves of “sick” people was about 7.8-8 % and 5-6% of “healthy” people only (Fig.7).

Comparing “healthy” and “sick” persons in all signals, the biggest comparative area occupied the first zone, i.e., 0-10 Hz. ICG-SCG coherence area of “healthy” people and ECG-SCG of “sick” had the biggest comparative areas. All other comparative areas approach zero by exponent.

Conclusions

1. All coherences of “healthy” persons are similar – they have the same number of peaks and coherence between all three signals are big and almost the same.
2. The coherence of all cardio signals of patient is low and has very different meaning in the same peak.
3. Comparing “healthy” and “sick” persons in all signals, the biggest comparative area occupied the first zone, i.e., 0-10 Hz.
4. Comparing “healthy” and “sick” persons in all signals, the biggest comparative area occupied the first zone, i.e., 0-10 Hz. ICG-SCG coherence area of “healthy” people and ECG-SCG of “sick” had the biggest comparative areas.

Acknowledgements

This work was supported by Grant from the Agency for International Science and Technology Development Programs in Lithuania within the EUREKA Project E!3489 “Heart Guard. Mobile Personal ECG Monitor”.

References

1. **Marple S. L. Jr.** Digital Spectral Analysis with Applications. – Prentice Hall, Englewood Cliffs, NJ, 1987.
2. **Kay S. M.** Modern Spectral Estimation: Theory and Application. – Prentice Hall, Englewood Cliffs, NJ, 1988.

3. **Stoica P., Moses R. L.** Introduction to Spectral Analysis. – Prentice Hall, Upper Saddle River, NJ, 1997.
4. **Capon J.** High resolution frequency-wavenumber spectrum analysis // Proc. of the IEEE. – Aug. 1969. – Vol. 57. – P. 1408–1418.
5. **Lacoss R. T.** Data adaptive spectral analysis methods // Geophysics. – Aug. 1971. – Vol. 36. – O. 661–675.
6. **Stoica P., Jakobsson A., Li J.** Matched-filter bank interpretation of some spectral estimators // Signal Processing. – Apr. 1998. – Vol. 66. – P. 45–59.
7. **Welch P. D.** The use of fast Fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms // IEEE Trans. AudioElectroacoust. – June 1967. – Vol. AU-15. – P. 70–73.
8. **Carter G. C., Knapp C. H., Nuttall A. H.** Estimation of the magnitude-squared coherence function via overlapped fast Fourier transform processing // IEEE Trans. Audio Electroacoust. – Aug. 1973. – Vol. AU-21. – P. 337–344.
9. **Gargasas L., Janušauskas A., Lukoševičius A., Vainoras A., Ruseckas R., Korsakas S., Miškinis V.** Development of methods for monitoring of electrocardiograms, impedance cardiograms and seismocardiograms // Studies in health technology and informatics. ISSN 0926-9630. – 2004. – Vol. 105. – P. 131–141.

Submitted for
publication 2006 02 28

G. Keršulytė, Z. Navickas, J. Blužas L. Gargasas, A. Vainoras, R. Ruseckas, S. Sadauskas, A. Naudžiūnas. Polycardiosignal Coherence Evaluation Results for Patients with Cardiopulmonary Diseases // Electronics and Electrical Engineering. – Kaunas: Technologija, 2007. – No. 5(77). – P. 41–44.

A big part of heart disease diagnostics criteria is collected by registration and analysis of cardio signals that show electric heart activity disturbance (ECG) and hemodynamic and mechanic activity changing, as impedance cardiograms (ICG) and seismocardiograms (SCG). Therefore, a solution of problem of effective heart disease diagnostic is the creation of new cardiosignals analysis technologies. Previously Fourier series were applied to frequency analysis of ECG, but this method was not applied to estimation of ICG and SCG frequency characteristics. In this paper, the frequency analysis method was applied to three cardio signals, because they reflect the electrical and mechanical work of the human heart better as one ECG signal. The main aim of this work is to adapt Fourier transformation to assessing and comparing the characteristics of hereinbefore signals and coherence. Il. 7, bibl. 9 (in English; summaries in English, Russian and Lithuanian).

Г. Кершулите, З. Навицкас, И. Блуžas, Л. Гаргасас, А. Вайнорас, Р. Русяцкас, С. Садаускас, А. Науджюнас. Свойства когеренции поликардиоосигналов // Электроника и электротехника. – Каунас: Технология, 2007. – № 5(77). – С. 41–44.

Большую часть диагностических критериев сердечных заболеваний получаем путем регистрации и анализа кардиосигналов, которые отражают как электрические нарушения работы сердца (ЭКГ), так и изменения в гемодинамической и механической работе, т.е. импеданскардиограмма (ИКГ) и сейсмокардиограмма (СКГ). Более того, эффективным решением проблем диагностики сердечных заболеваний является создание новых технологий анализа кардиосигналов. Уже несколько десятилетий трансформация Фурье применяется для частотного ЭКГ анализа, в тоже время этот метод небыл использован при интерпретации частотных характеристик ИКГ и СКГ. Целью работы было попытаться применить Фурье анализ при оценке и сравнении трех синхронно зарегистрированных кардиосигналов, так как они отражают электрическую работу сердца, гемодинамические и механические изменения более точно чем один ЭКГ сигнал, а также оценить и сравнить три синхронно зарегистрированные кардиосигналы – ЭКГ, ИКГ и СКГ по частотным характеристикам и когеренции. Ил. 7, библи. 9 (на русском языке; рефераты на английском, русском и литовском яз.).

G. Keršulytė, Z. Navickas, J. Blužas L. Gargasas, A. Vainoras, R. Ruseckas, S. Sadauskas, A. Naudžiūnas. Polikardiosignalų koherencijos savybės // Elektronika ir elektrotechnika. – Kaunas: Technologija, 2007. Nr. 5(77). – P. 41–44.

Didelė dalis širdies susirgimų diagnostinių kriterijų gaunama registruojant ir analizuojant kardiosignalus, kurie atspindi tiek elektrinės širdies veiklos sutrikimus (EKG), tiek ir hemodinaminės bei mechaninės veiklos pokyčius, t.y. impedanskardiograma (IKG) ir seismokardiograma (SKG). Dar daugiau, efektyvus širdies susirgimų diagnostikos problemų sprendimas yra naujų kardiosignalų analizės technologijų kūrimas. Jau kelis dešimtmečius Furjė transformacija taikoma EKG dažnumų analizei, tuo tarpu kai IKG ir SKG dažnio charakteristikų vertinimui šis metodas nebuvo naudojamas. Darbo tikslas buvo pritaikyti Furjė analizę įvertinant bei palyginant tris sinchroniškai užregistruotus kardiosignalus, nes jie atspindi elektrinės širdies, hemodinaminės bei mechaninės širdies veiklos pokyčius geriau nei vienas EKG signalas. Kitas darbo tikslas buvo pritaikyti Furjė analizę įvertinant bei palyginant trijų sinchroniškai užregistruotų signalų - EKG, IKG ir SKG dažnio charakteristikas ir koherenciją. Il. 7, bibl. 9 (lietuvių kalba; santraukos anglų, rusų ir lietuvių k.).

4 PRIEDAS Straipsnis: Polikardiosignalų koherentiškumo tyrimas

Publikacijos rūšis: Straipsnis atiduotas spaudai.

Leidinyje: Konferencijos medžiaga „Matematika ir matematikos dėstymas – 2007“

POLIKARDIOSIGNALŲ KOHERENTIŠKUMO TYRIMAS

Gintarė Keršulytė, Z.Navickas

Kauno technologijos universitetas

A.Vainoras, L.Gargasas

KMU kardiologijos istitutas

[ivadas

Efektyvus širdies kraujagyslių susirgimų diagnostikos problemų sprendimas įmanomas kuriant ir taikant naujas kardiosignalų analizės informacines technologijas, nes nemaža dalis širdies susirgimų diagnostinių kriterijų gaunama registruojant ir analizuojant kardiosignalus, kurie atspindi tiek elektrinės širdies veiklos sutrikimus (EKG), tiek ir hemodinaminės bei mechaninės veiklos pokyčius, t.y. impedanskardiograma (IKG) ir seismokardiograma (SKG) [7].

Spektrinė analizė vaidina didelę reikšmę signalų apdorojime. Šie metodai yra taikomi įvairiose srityse: komunikacijose, kalbos garsinio signalo apdorojime, biomedicinoje, radarų technologijose, etc [1,2,3]. Vienas iš geriausiai žinomų neparimetrinių spektrinės analizės algoritmų yra Capon'o metodas, kuris yra geriau žinomas kaip mažo jautrumo minimalios dispersijos išsibarstymo metodas (*minimum variance distortion less response*) (MVDR) [4,5]. Šis algoritmas pasižymi dideliu tikslumu analizuojant signalus dažnių srityje. MVDR spektras gali būti stebimas kaip filtrų išėjimų rezultatas. MVDR algoritmas gali būti interpretuojamas kaip juostinių filtrų bazė, kurių centrinė dažninė komponentė yra lygi analizuojamai dažnio komponentei. Kiekvienas juostinis filtras priklauso nuo analizuojamų duomenų bei jų dažnių tuo skirdamasis nuo periodogramomis pagrįstu metodo, kur kiekvienas jo juostinis filtras yra diskretinė Furjė matrica, kuri nuo duomenų ir dažnių nėra priklausoma [3,6].

Dar vienas metodas, naudojamas signalų analizei dažnių srityje - MSC (magnitude squared coherence) - alternatyva populiariam Welch'o metodui[7,8].

MSC metodas koherentiškumo tyrimui

Tarkime, turime du signalus $x_1(n)$ ir $x_2(n)$. Galime sukonstruoti perdavimo funkciją

$$g_{p,k} = \frac{R_{x_p x_p}^{-1} \cdot f_k}{f_k^H R_{x_p x_p}^{-1} \cdot f_k}, p = 1, 2$$

$$\text{kur } f_k = \frac{1}{\sqrt{L}} [1 \quad \exp(jw_k) \quad \dots \quad \exp(jw_k(L-1))]^T,$$

bei rasti $x_1(n)$ ir $x_2(n)$ signalų spektrus tam tikruose dažniuose w_k , $w_k = 2\pi k / K, k = 0, 1, \dots, K-1$.

$$S_{x_p x_p}(w_k) = \frac{1}{f_k^H R_{x_p x_p}^{-1} f_k}, p = 1, 2,$$

kur $R_{x_p x_p} = E\{x_p(n)x_p^H(n)\}$ yra signalo $x_p(n)$ kovariacinė matrica ir

$$x_p(n) = [x_p(n) \quad x_p(n-1) \quad \dots \quad x_p(n-L+1)]^T.$$

Tegul $y_{1,k}(n)$ ir $y_{2,k}(n)$ atitinkamai filtrų $g_{1,k}$ ir $g_{2,k}$ išėjimai. Apibrėžkime spektrą tarp $x_1(n)$ ir $x_2(n)$ kiekvienam w_k dažniui:

$$S_{x_1 x_2}(w_k) = E\{y_{1,k}(n)y_{2,k}^*(n)\},$$

$$S_{x_2 x_1}(w_k) = E\{y_{2,k}(n)y_{1,k}^*(n)\} = S_{x_1 x_2}^*(w_k), * - \text{konjungcijos operatorius}$$

$$S_{x_1 x_2}(w_k) = g_{1,k}^H \cdot R_{x_1 x_2} \cdot g_{2,k} \quad (1)$$

$$F = [f_0 \quad f_1 \quad \dots \quad f_{K-1}] \quad (2)$$

Perdavimo funkcijos koeficientai pasirenkami taip, kad minimizuotų filtro išėjimų pasiskirstymą, t.y. $g_k^H f_k = f_k^H g_k = 1$. Pagal šią lygybę, $x(n)$, paveikiamas perdavimo funkcijos g_k be trikdžių kiekviename dažnyje w_k . Pagal (1) ir (2):

$$S_{x_1 x_2}(w_k) = \frac{f_k^H R_{x_1 x_1}^{-1} R_{x_1 x_2} R_{x_2 x_2}^{-1} f_k}{\left[f_k^H R_{x_1 x_1}^{-1} f_k \right] \cdot \left[f_k^H R_{x_2 x_2}^{-1} f_k \right]}$$

$$\left| S_{x_1 x_2}(w_k) \right|^2 = \frac{\left| f_k^H R_{x_1 x_1}^{-1} R_{x_1 x_2} R_{x_2 x_2}^{-1} f_k \right|^2}{\left[f_k^H R_{x_1 x_1}^{-1} f_k \right]^2 \cdot \left[f_k^H R_{x_2 x_2}^{-1} f_k \right]^2} \quad (3)$$

$$\gamma_{x_1 x_2}^2(w_k) = \frac{\left| S_{x_1 x_2}(w_k) \right|^2}{S_{x_1 x_1}(w_k) S_{x_2 x_2}(w_k)} \quad (4)$$


Kai $K=L$, F yra unitari Furjė matrica, i.e. $F^H F = F F^H = I$, kur F^H - matricos F transponuota konjuncija, išraišką (3) įstačius į (4), gauname MSC:

$$\gamma_{x_1 x_2}^2(w_k) = \frac{\left[f_k^H R_{x_1 x_1}^{-1} R_{x_1 x_2} R_{x_2 x_2}^{-1} f_k \right]^2}{\left[f_k^H R_{x_1 x_1}^{-1} f_k \right] \cdot \left[f_k^H R_{x_2 x_2}^{-1} f_k \right]}$$

Toliau aptartas koherentiškumo įvertinimo metodas buvo pritaikytas realiems kardiosignalams.


Tyrimo rezultatai

Visi trys kardiosignalai užregistruoti sinchroniškai, t.y. tuo pačiu metu. Buvo ištirti 30 asmenų. Tiriamieji padalinti į dvi grupes. Iš anksto buvo žinoma, kad 20 iš jų turi sveikatos sutrikimų, o 10 – sveikata nesiskundžia.




1 pav. "Sveikų" žmonių kardiosignalų koherencija

Rezultatai rodo, kad tiriamųjų grupių koherencijos kreivės skirtingos. "Sveikų" žmonių koherencijos kreivės panašios: tuose pačiuose kreivių pikuose koherencijos reikšmės beveik sutampa ir visų trijų signalų koherencijos pikų skaičius vienodas. Vidutinė koherencijos reikšmė apie 0.4-0.5. Antras pagal dydį koherencijos kreivės pikas (0.68-0.72) išryškėja atitinkamai ties 11 Hz ir 32 Hz.




2 pav. "Ligoniu" koherencija

Priešingai nei "sveiku" tiriamuju, "ligoniu" kardiopsigalų koherencija maža (žr. 2 pav.) ir turi gana skirtingas reikšmes tuose pačiuose pikuose (žr. 3 pav.). Vidutinė "ligoniu" koherencijos vertė yra apie 0.30-0.38. Antras pagal dydį koherencijos kreivės pikas (0.72-0.42) išryškėja atitinkamai ties 11 Hz ir 32 Hz.



3 pav. "Ligoniu" koherencija


Simpsono metodu buvo suskaičiuoti plotai po kiekviena koherencijos kreive ir atvaizduoti trimatėje erdvėje (žr. 4 pav.). Rezultatai rodo, kad požymiai gali būti atskirti hyperplokštuma, kuria būtų galima klasifikuoti tiriamuosius į dvi klases, t.y., į „sveikus“ ir „ligonius“.



4 pav. Koherencijos plotai


Koherencijos kreivės buvo padalintos į 3 skirtingas zonas: 0-10 Hz., 11-35 Hz. ir 35-50 Hz. Simpsono metodu suskaičiuotas kiekvienos dalies plotas po koherencijos kreive. Rezultatai pateikiami stulpelinėmis

diagramomis, kurios parodo vienos zonos apibrėžtos koherentiškumo kreivę santykį su visos koherentiškumo kreivės apibrėžiamu plotu, %.




5 pav. Plotų po koherencijos kreivėmis santykinis plotas, 0-10 Hz

Lyginant pirmosios zonos 0-10 Hz rezultatus, „sveikų“ tiriamųjų didžiausias santykinis plotas yra po IKG-SKG koherencijos kreivę, o „ligonių“ – po EKG-SKG koherencijos kreivę, atitinkamai apie 85% ir apie 86,50% (žr. 5 pav.).



6 pav. Plotų po koherencijos kreivėmis santykinis plotas, 11-35 Hz

Antrojoje zonoje 11-35 Hz, santykiniai plotai po koherencijos kreivėmis gana panašūs: „sveikų“ tiriamųjų apie 10%, o „ligonių“ – apie 6% (žr. 6 pav.).



7 pav. Plotų po koherencijos kreivėmis santykinis plotas, 36-50 Hz

Lyginant paskutinės zonos 36-50 Hz rezultatus, santykiniai plotai po koherencijos kreivėmis „ligonių“ siekia apie 7.8-8 % ir 5-6% „sveikų“ tiriamųjų (žr. 7 pav.). Tiek „sveikų“, tiek „ligonių“, didžiausias koherencijos santykinis plotas pasiskirstęs I zonoje, i.e. 0-10 Hz. Pirmosios zonos didžiausias koherencijos santykinis plotas: „sveikų“ – IKG-SKG, „ligonių“ – EKG-SKG. Visų kitų zonų plotai eksponentiškai artėja prie nulio.

Išvados

1. “Sveikų” žmonių koherencijos kreivės panašios: tuose pačiuose kreivių pikuose koherencijos reikšmės beveik sutampa.
2. “Ligonių” kardiosignalų koherencija maža ir turi gana skirtingas reikšmes tuose pačiuose pikuose.
3. Tiek “sveikų”, tiek “ligonių”, didžiausias koherencijos santykinis plotas pasiskirstęs I zonoje, i.e. 0-10 Hz.
4. I zonos didžiausias koherencijos santykinis plotas: “sveikų” – IKG-SKG, “ligonių” – EKG-SKG.

Literatūra

1. S. L. Marple Jr., Digital Spectral Analysis with Applications. Prentice Hall, Englewood Cliffs, NJ, 1987
2. S. M. Kay, Modern Spectral Estimation: Theory and Application. Prentice Hall, Englewood Cliffs, NJ, 1988.
3. P. Stoica and R. L. Moses, Introduction to Spectral Analysis. Prentice Hall, Upper Saddle River, NJ, 1997.
4. J. Capon, “High resolution frequency-wavenumber spectrum analysis,” Proc. of the IEEE, vol. 57, pp. 1408–1418, Aug. 1969.
5. R. T. Lacoss, “Data adaptive spectral analysis methods,” Geophysics, vol. 36, pp. 661–675, Aug. 1971.
6. P. Stoica, A. Jakobsson, and J. Li, “Matched-filter bank interpretation of some spectral estimators,” Signal Processing, vol. 66, pp. 45–59, Apr. 1998.
7. Gargasas L., Janušauskas A., Lukoševičius A., Vainoras A., Ruseckas R., Korsakas S., Miškinis V. Development of methods for monitoring of electrocardiograms, impedance cardiograms and seismocardiograms // Studies in health technology and informatics. ISSN 0926-9630. 2004; vol. 105: 131-141.
8. Pekarskas V. Diferencialinis ir integralinis skaičiavimas ISBN 9986-13-416-1 (I dalis) 2000; P.239.

POLICARDIOSIGNALS COHERENCE ANALYSIS

G. Keršulytė, Z.Navickas, A.Vainoras, L.Gargasas

A big part of heart disease diagnostics criteria is collected by registration and analysis of cardio signals that show electric heart activity disturbance (ECG) and hemodynamic and mechanic activity changing, as impedance cardiograms (ICG) and seismocardiograms (SCG). Therefore, a solution of problem of effective heart disease diagnostic is the creation of new cardiosignals analysis technologies. Previously Fourier series were applied to frequency analysis of ECG, but this method was not applied to estimation of ICG and SCG frequency characteristics. In this paper, the frequency analysis method was applied to three cardio signals, because they reflect the electrical and mechanical work of the human heart better as one ECG signal. The main aim of this work is to adapt Fourier transformation to assessing and comparing the characteristics of hereinbefore signals and coherence. (in Lithuanian; summary in English).