



KAUNO TECHNOLOGIJOS UNIVERSITETAS
FUNDAMENTALIŲJŲ MOKSLŲ FAKULTETAS
TAIKOMOSIOS MATEMATIKOS KATEDRA

Dovilė Astapenko

**ŠIRDIES VAINIKINIŲ ARTERIJŲ
SUSIAURĖJIMŲ VERTINIMO MODELIAI
IR PROGRAMINĖS PRIEMONĖS**

Magistro darbas

Vadovas
doc. dr. V. Janilionis

KAUNAS, 2005



KAUNO TECHNOLOGIJOS UNIVERSITETAS
FUNDAMENTALIŲJŲ MOKSLŲ FAKULTETAS
TAIKOMOSIOS MATEMATIKOS KATEDRA

TVIRTINU
Katedros vedėjas
prof. dr. J.Rimas
2005 06 01

ŠIRDIES VAINIKINIŲ ARTERIJŲ
SUSIAURĖJIMŲ VERTINIMO MODELIAI
IR PROGRAMINĖS PRIEMONĖS

Taikomosios matematikos magistro baigiamasis darbas

Kalbos konsultantas
dr. J. Džežulskienė
2005 05 24

Recenzentas
doc.dr. V.Šaferis
2005 05 31

Vadovas
doc. dr. V. Janilionis
2005 05 30

Atliko
FMMM - 3 gr. stud.
D. Astapenko
2005 05 23

KAUNAS, 2005

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, banko „NORD/LB“ vyriausiasis analitikas

Zenonas Navickas, profesorius (KTU)

Arūnas Barauskas, UAB „Elsis“ generalinio direktoriaus pavaduotojas

Astapenko D., Models and software for estimation of heart coronary arteries stenosis: Master's work in Applied Mathematics / supervisor dr. assoc. prof. V. Janilionis; Department of Applied Mathematics, Faculty of Fundamental Sciences, Kaunas University of Technology. – Kaunas, 2005. – 121 p.

SUMMARY

Coronary arteries stenosis causes ischemic heart disease which is the main fatality reason all over the world. For diagnosis arteries stenosis invasive and noninvasive methods are used. These methods are quite expensive and not all medical institutions can carry out such tests. Analysis of electrocardiogram could be one of the cheapest and current methods to diagnose arteries stenosis. Despite the fact, that in some cases such analysis is not very informative, medics look for the informative ECG parameters and their combinations in order to predict stenosis.

The goal of this work is to create statistical methods and software for prognosis of coronary arteries stenosis using digital ECG parameters. Data was collected and prepared for this research in Clinic of Cardiology of Kaunas Medical University.

In this work are presented:

1. Statistical analysis models for prognosis of coronary arteries stenosis.
2. Software for uses.
3. Comparative analysis of statistical analysis models.
4. Results of real data analysis, which were obtained by using, developed statistical models and software.

Obtained results will be used to improve methods of diagnosis ischemic heart disease and arteries stenosis in Clinic of Cardiology of Kaunas Medical University.

TURINYS

1. TEORINĖ DALIS.....	6
1.1. Išeminės širdies ligos ir jos tyrimų apžvalga	6
1.2. Vainikinių širdies arterijų susiaurėjimų įvertinimo metodų analizė	6
1.3. Statistinės analizės metodai, naudojami vainikinių širdies arterijų susiaurėjimų įvertinimui.....	7
1.4. Darbe sprendžiami uždaviniai.....	14
2. TIRIAMOJI DALIS	14
2.1. Pacientų duomenų bazės modelis	14
2.2. Vainikinių širdies arterijų susiaurėjimų įvertinimo pagal EKG ir VKG parametrus modeliai	18
2.2.1. Aprašomoji statistika.....	18
2.2.2. Vainikinių širdies arterijų susiaurėjimų įvertinimo pagal EKG ir VKG parametrus logistinės regresijos modelis	20
2.2.3. Vainikinių širdies arterijų susiaurėjimų įvertinimo pagal EKG ir VKG parametrus parametrinės diskriminantinės analizės modelis	33
2.2.4. Vainikinių širdies arterijų susiaurėjimų įvertinimo pagal EKG ir VKG parametrus neparametrinės diskriminantinės analizės modelis.....	45
2.2.5. Vainikinių širdies arterijų susiaurėjimų įvertinimo pagal EKG ir VKG parametrus modelių lyginamoji analizė.....	49
2.3. Vainikinių širdies arterijų susiaurėjimų tyrimo sprendimų priėmimo paramos sistema .	50
2.3.1. Struktūra	51
2.3.2. Širdies vainikinių arterijų susiaurėjimų analizės programiniai modeliai.....	52
2.3.3. Vartotojo sąsaja.....	54
IŠVADOS.....	58
LITERATŪRA	59
1 PRIEDAS. Darbe naudojamų klinikinių ir elektrokardiografinių parametrų santrumpos	62
2 PRIEDAS. Aprašomosios statistikos rezultatai.....	63
3 PRIEDAS. Logistinės regresijos modelio taikymo rezultatai	77
4 PRIEDAS. Parametrinės diskriminantinės analizės modelio taikymo rezultatai.....	83
5 PRIEDAS. Neparametrinės diskriminantinės analizės modelio taikymo rezultatai.....	99
6 PRIEDAS. Vainikinių širdies arterijų susiaurėjimų įvertinimo programiniai modeliai.....	108

LENTELIŲ SĄRAŠAS

1.1 lentelė. Branduolio tipai.....	12
2.1 lentelė. Vyrų imties skaitinės charakteristikos.....	18
2.2 lentelė. Moterų imties skaitinės charakteristikos atskirose grupėse.....	19
2.3 lentelė. Pažingsninio metodo taikymo rezultatai.....	22
2.4 lentelė. Logistinės regresijos lygties koeficientų taškiniai įverčiai.....	23
2.5 lentelė. Logistinės regresijos modelio apibrėžtumo koeficientai.....	25
2.6 lentelė. Hipotezių apie logistinės regresijos lygties koeficientų lygybę nuliui tikrinimo rezultatai	26
2.7 lentelė. Pacientų klasifikavimo rezultatai, kai modelyje naudojami visi kintamieji.....	26
2.8 lentelė. Pacientų klasifikavimo rezultatai, kai modelyje naudojami kintamieji, kuriems hipotezės apie jų lygybę nuliui nebuvo priimtinos.....	27
2.9 lentelė. Pažingsninio metodo taikymo rezultatai.....	29
2.10 lentelė. Logistinės regresijos lygties koeficientų taškiniai įverčiai.....	29
2.11 lentelė. Logistinės regresijos modelio apibrėžtumo koeficientai.....	30
2.12 lentelė. Hipotezių apie logistinės regresijos lygties koeficientų lygybę nuliui tikrinimo rezultatai	31
2.13 lentelė. Pacienčių klasifikavimo rezultatai, kai modelyje naudojami visi kintamieji.....	32
2.14 lentelė. Pacientų klasifikavimo rezultatai, kai modelyje naudojami kintamieji, kuriems hipotezės apie jų lygybę nuliui nebuvo priimtinos.....	32
2.15 lentelė. Vienmačių skirstinių suderinamumo hipotezių tikrinimo rezultatai.....	34
2.16 lentelė. Vienmačių skirstinių suderinamumo hipotezių tikrinimo rezultatai.....	35
2.17 lentelė. Daugiamatčių skirstinių suderinamumo hipotezių tikrinimo rezultatai.....	35
2.18 lentelė. Daugiamatčių skirstinių suderinamumo hipotezių tikrinimo rezultatai.....	36
2.19 lentelė. Pažingsninio metodo taikymo rezultatai.....	36
2.20 lentelė. Klasifikavimo lentelė.....	38
2.21 lentelė. Klaidingo klasifikavimo tikimybių įverčiai.....	38
2.22 lentelė. Lachenbrucho procedūros klaidingo klasifikavimo tikimybių įverčiai.....	38
2.23 lentelė. Lachenbrucho procedūros lentelė.....	39
2.24 lentelė. Vienmačių skirstinių suderinamumo hipotezių tikrinimo rezultatai.....	39
2.25 lentelė. Daugiamatčių skirstinių suderinamumo hipotezių tikrinimo rezultatai.....	40
2.26 lentelė. Pažingsninio metodo taikymo rezultatai.....	41
2.27 lentelė. Diskriminavimo funkcijos $d_0\left(\vec{x}\right)$ koeficientų įverčiai.....	42
2.28 lentelė. Diskriminavimo funkcijos $d_1\left(\vec{x}\right)$ koeficientų įverčiai.....	43
2.29 lentelė. Klasifikavimo lentelė.....	43
2.30 lentelė. Klaidingo klasifikavimo tikimybių įverčiai.....	44
2.31 lentelė. Lachenbrucho procedūros lentelė.....	44
2.32 lentelė. Lachenbrucho procedūros klaidingo klasifikavimo tikimybių reikšmės.....	44
2.33 lentelė. Klasifikavimo rodikliai, priklausantys nuo normaliojo branduolio spindulio.....	45
2.34 lentelė. Kovariacijų matrica.....	47
2.35 lentelė. Klasifikavimo lentelė.....	47
2.36 lentelė. Klaidingo klasifikavimo tikimybių įverčiai.....	47
2.37 lentelė. Klasifikavimo rodiklių priklausomybė nuo normaliojo branduolio spindulio.....	48
2.38 lentelė. Kovariacijų matrica.....	48
2.39 lentelė. Klasifikavimo lentelė.....	49
2.40 lentelė. Klaidingo klasifikavimo tikimybių įverčiai.....	49
2.41 lentelė. Klasifikavimo rezultatai.....	49
2.42 lentelė. Klasifikavimo rezultatai.....	50

PAVEIKSLŲ SĄRAŠAS

2.1 pav. Vektorkardiograma	15
2.3 pav. Tyrime naudojami pacientų duomenys	17
2.4 pav. Kintamojo $X^{(3)}$ stačiakampė diagrama	19
2.5 pav. Kintamojo $X^{(3)}$ stačiakampės diagramos atskirose pacientų grupėse	20
2.6 pav. Modelio, kuriame naudojami visi kintamieji, ROC kreivė	27
2.7 pav. Modelio, kuriame naudojami kintamieji, kuriems hipotezės apie jų lygybę nuliui nebuvo priimtinos, ROC kreivė	28
2.8 pav. Modelio, kuriame naudojami visi kintamieji, ROC kreivė	32
2.9 pav. Modelio, kuriame naudojami kintamieji, kuriems hipotezės apie jų lygybę nuliui nebuvo priimtinos, ROC kreivė	33
2.10 pav. Vainikinių širdies arterijų susiaurėjimų tyrimo sprendimo priėmimo paramos sistemos struktūra	51
2.11 pav. Logistinės regresijos modelio programa	53
2.12 pav. Diskriminantinės analizės modelio programa	53
2.13 pav. Pagrindinis vartotojo sąsajos langas	55
2.14 pav. Vartotojo sąsajos langas, skirtas sukurtų modelių analizei	55
2.15 pav. Vartotojo sąsajos langas, skirtas paciento paieškai duomenų bazėje	56
2.16 pav. Vartotojo sąsajos langas, kuriame realizuota sąsajos dalis skirta atskiro paciento vainikinių širdies arterijų susiaurėjimui prognozuoti	57
2.17 pav. Vartotojo sąsajos langas, kuriame įvedami nauji paciento duomenys	58

IVADAS

Širdies ir kraujagyslių ligos – tai viena iš dažniausių suaugusiųjų mirties priežasčių išsivysčiusiose šalyse ir Lietuvoje. Statistikos duomenimis, sergančiųjų širdies ir kraujagyslių ligomis Lietuvoje daugėja (26,9 atvejai 1000 gyv. 1998 m.) [16]. Tai ne tik medicininė, bet ir socialinė problema, nes sveikata yra didžiausia socialinė vertybė.

Išeminė širdies liga – tai ūminė ar lėtinė miokardo disfunkcija dėl nepakankamo širdies raumens aprūpinimo deguonimi. Dažniausia miokardo išemijos priežastis – vainikinių arterijų spindžio susiaurėjimas susidarant aterosklerotinėms plokštelėms ir prisidėjus jų komplikacijoms (apie 90 proc. atvejų) [32].

Vainikinių širdies arterijų spindžio susiaurėjimui diagnozuoti yra taikoma tiek invaziniai, tiek neinvaziniai metodai. Lietuvoje kasdieninėje kardiologinėje praktikoje vainikinių arterijų stenozės įvertinamos koronarografijos metodu, tačiau šiuo metodu 10-20 proc. atvejų vainikinių arterijų susiaurėjimų nenustatoma [8]. Koronarografija – invazinis metodas, todėl turi nepageidaujamų pašalinių poveikių, taip pat yra brangus ir Lietuvoje tik penkios gydymo įstaigos gali atlikti tokius tyrimus. Daugelis neinvazinių metodų naudojamų medicinos praktikoje stenozės diagnozavimui arba yra nelabai tikslus, arba yra brangūs, o kai kurie nedažnai naudojami dėl žalingo poveikio sveikatai, pavyzdžiui, kompiuterinė tomografija. Todėl vis dar vyksta neinvazinių metodų kūrimas, leidžiančių tiksliai, nebrangiai ir saugiai diagnozuoti vainikinių širdies arterijų susiaurėjimą.

Viena iš plačiausiai naudojamų išeminės širdies ligos neinvazinių diagnostinių priemonių yra elektrokardiografinis tyrimas [18], kuris kardiologijoje yra naudojamas jau daugiau kaip 100 metų. Elektrokardiograma yra registruojama arba krūvio metu, arba ramybėje. Šis tyrimas turi daug privalumų: neinvazinis, lengvai atliekamas ir nebrangus, o ramybės elektrokardiograma yra prieinamiausias diagnostikos metodas kardiologijoje ir yra atliekamas įvairiose sveikatos priežiūros grandyse. Krūvio elektrokardiograma yra daug informatyvesnė diagnozuojant vainikinių arterijų stenozę, tačiau krūvio testas nėra visai saugus sunkesnės būklės ligoniams [25], be to ne visos gydymo įstaigos turi galimybę atlikti tokius tyrimus. Yra žinoma, kad vainikinių arterijų susiaurėjimų prognozavimas ramybėje registruotos elektrokardiogramos ne ūminės išemijos metu yra ribotas, tačiau vyksta naujų elektrokardiografinių požymių ir jų derinių paieška, leidžiančių įtarti vainikinių širdies arterijų susiaurėjimus.

KMUK Kardiologijos klinikoje atliekant tyrimą, visiems pacientams buvo registruojama skaitmeninė ramybės elektrokardiograma, kuri vėliau buvo apdorojama su automatizuotos analizės sistema, sukurta KMU Kardiologijos instituto Kardiologinių tyrimų automatizacijos laboratorijoje. Naudojantis atsitiktinai parinktų 314 pacientų duomenimis ir yra bandoma rasti elektrokardiografinius požymius bei jų derinius, leidžiančius įtarti vainikinių širdies arterijų susiaurėjimus. Reikėtų pastebėti,

kad dėl ramybės elektrokardiogramos atskirų parametrų neinformatyvumo tokie tyrimai pasaulyje nėra atliekami, o Lietuvoje tai pirmasis tyrimas.

Darbo tikslas – sukurti statistinės analizės modelius ir programines priemones vainikinių širdies arterijų susiaurėjimų prognozavimui ir atlikti Kauno medicinos universiteto klinikų Kardiologijos klinikoje atlikto tyrimo duomenų analizę.

Darbo tema buvo perskaityti pranešimai trijose konferencijose:

1. Konferencijoje „Matematika ir matematinis modeliavimas – 2004” – KTU;
2. V studentų konferencijoje „Taikomoji matematika – 2004” – KTU;
3. Tarptautinėje konferencijoje „Analysis of Biomedical Signals and Images. BIOSIGNAL 2004“ – Brno University of Technology, Czech Republic;

ir paskelbtos trys publikacijos:

1. Astapenko D. Širdies vainikinių arterijų susiaurėjimo prognozavimas pagal elektrokardiogramos ir vektorkardiogramos parametrus/ D. Astapenko, V. Janilionis, A. Matiukas // Matematika ir matematikos dėstymas - 2004: konferencijos pranešimų medžiaga [Kaunas, 2004 m. balandžio 1, 2 d.]. Kaunas, 2004. p. 85-90.
2. Astapenko D. Širdies vainikinių arterijų susiaurėjimo prognozavimas pagal elektrokardiogramos ir vektorkardiogramos parametrus naudojant diskriminantinę analizę/ D. Astapenko, V. Janilionis, A. Matiukas // Taikomoji matematika: V studentų konferencijos pranešimų medžiaga [Kaunas, 2004 m. gegužės 8 d.]. Kaunas, 2004. p. 12-13.
3. Kaminskienė S. Correlation between T Loop Morphology and Coronary Artery Stenosis/ S. Kaminskienė, D. Astapenko, V. Janilionis, G. Urbonavičienė, A. Janavičius, A. Matiukas // Analysis of Biomedical Signals and Images: 17th International Eurasip Conference Biosignal 2004 proceedings [Brno, May 2004] . Brno, 2004. p. 176-178.

1. TEORINĖ DALIS

1.1. IŠEMINĖS ŠIRDIES LIGOS IR JOS TYRIMŲ APŽVALGA

Išeminė širdies liga – tai ūminė ar lėtinė miokardo disfunkcija, kuri išsivysto dėl sumažėjusios ar nutrūkusios kraujotakos vainikinėse arterijose ir nepakankamo širdies raumens aprūpinimo deguonimi [32]. Nors paskutinius dešimtmečiais mirštamumas dėl išeminės širdies ligos ryškiai sumažėjo, taikant pirmines profilaktikos priemones, tobulą ir intensyvų gydymą, tačiau išeminė širdies liga vis dar yra pagrindinė sergamumo ir mirties priežastis Vakarų pasaulyje. Mirtys dėl širdies kraujagyslių ligų sudaro daugiau kaip pusę visų Lietuvos gyventojų mirčių [32]. Pagrindinė išeminės širdies ligos priežastis yra aterosklerozė, t.y. vainikinių širdies arterijų spindžio susiaurėjimas susidarant aterosklerotinėms plokštelėms ir prisidėjus jų komplikacijoms. Tai sisteminė kraujagyslių sienelės liga, kuri pažeidžia aortą, vainikines, miego ir periferines arterijas. Įrodyta, kad aterosklerozės vystymąsi lemia ne tik pagrindiniai rizikos veiksniai, tokie kaip rūkymas, hipertenzija, dislipidemija, amžius, cukrinis diabetas, nutukimas, sumažėjęs fizinis aktyvumas, bet ir daugelis kitų – endotelio disfunkcija, uždegimas, infekcija, mikroalbuminurija, imuninės sistemos sutrikimai [32].

Skiriamos ūminės ir lėtinės išemijos formos. Ūminės – staigi kardialinė mirtis ir ūminiai koronariniai sindromai (nestabili krūtinės angina, miokardo infarktas, staigi mirtis). Lėtinės išemijos formos – stabili krūtinės angina, širdies ritmo sutrikimai, išeminė kardiopatija. Toliau didėjant VA stenozei, progresuoja išeminės širdies ligos ir miokardo disfunkcija iki širdies nepakankamumo.

Įtarus išeminę širdies ligą, ligonio ištyrimas prasideda nuo ramybės 12 derivacijų elektrokardiogramos, fizinio krūvio testų, esant indikacijoms, atliekamas miokardo perfuzijos tyrimas ir koronarografija [18]. Nepaisant naujų diagnostikos metodų atsiradimo bei paplitimo, elektrokardiografinis tyrimas išlieka viena iš pagrindinių išeminės širdies ligos diagnostinių priemonių. Elektrokardiogramoje sukaupta daugiau informacijos negu šiuo metu naudojama praktikoje. Kadangi elektrokardiograma yra plačiausiai šiuo metu atliekamas tyrimas tiek ligoniams, tiek ir populiacijos tyrimų metu, galvojama, kad jos analizės patobulinimas galėtų turėti didelę reikšmę ankstyvai išeminės širdies ligos diagnostikai.

1.2. VAINIKINIŲ ŠIRDIES ARTERIJŲ SUSIAURĖJIMŲ ĮVERTINIMO METODŲ ANALIZĖ

Vainikinių širdies arterijų susiaurėjimas, t.y. stenoze, yra viena iš pagrindinių išeminės širdies ligos priežasčių. Medicinos praktikoje taikomi įvairūs metodai stenozės laipsnio nustatymui. Pagrindiniai invaziniai metodai – koronarografija, intravaskulinis ultragarsinis tyrimas, intravaskulinė termografija, intravaskulinis magnetinis rezonansas, intravaskulinis branduolinis vaizdavimas ir kt.

Stenozės laipsniui nustatyti yra atliekami ir neinvaziniai tyrimai. Naudojama echokardiografija, seismokardiografija, miokardo perfūzijos tyrimas, magnetinis rezonansas, elektroninio spindulio kompiuterinė tomografija, daugiasluoksni spiralinė kompiuterinė tomografija, branduoliniai metodai. Tačiau daugelis šių metodų kasdienėje praktikoje dar nėra plačiai taikomi, yra labai brangūs, o kompiuterinė tomografija dėl didelio spinduliavimo yra dar ir žalinga sveikatai. Vienas iš naujesnių vainikinių širdies arterijų susiaurėjimo įvertinimo metodų yra magnetokardiografija [13], kuri Lietuvoje dar nėra naudojama. Krūvio bei ramybės elektrokardiogramos ir vektorkardiogramos analizė taip pat leidžia diagnozuoti vainikinių širdies arterijų susiaurėjimą, o tuo pačiu ir išeminę širdies ligą. Elektrokardiografinis tyrimas yra neinvazinis, lengvai atliekamas ir nebrangus, tačiau vainikinių arterijų susiaurėjimų prognozavimas ramybėje registruotos elektrokardiogramos ne ūminės išemijos metu yra ribotas. Yra žinoma, kad 12-os derivacijų ramybės elektrokardiograma yra sąlyginai neinformatyvi ir dažnai normali net esant ryškiems vainikinių arterijų pažeidimams [26, 27]. Normali ramybės elektrokardiograma stebima maždaug pusei ligonių sergančių stabilia krūtinės angina, paprastai tiems, kurie nesirgo plačiu miokardo infarktu. Išeminei širdies ligai diagnozuoti bei vainikinių širdies arterijų būklės įvertinimui naudojami ir fizinio krūvio testai, tačiau moterims dažnai stebimi klaidingai teigiami rezultatai, ypač elektrokardiografinio fizinio krūvio testo metu.

1.3. STATISTINĖS ANALIZĖS METODAI, NAUDOJAMI VAINIKINIŲ ŠIRDIES ARTERIJŲ SUSIAURĖJIMŲ ĮVERTINIMUI

Atliekamuose vainikinių širdies arterijų susiaurėjimo įvertinimo tyrimuose naudojami įvairūs statistinės analizės metodai. Statistinės analizės metodai plačiai naudojami analizuojant elektrokardiogramos ir vektorkardiogramos parametrus, taip pat apjungiant juos su kitų diagnostinių metodų rezultatais. Dažniausiai naudojami šie metodai [22]:

- ◆ suderinamumo hipotezių tikrinimas,
- ◆ hipotezių apie vidurkių lygybę tikrinimas,
- ◆ koreliacinė analizė,
- ◆ daugialypė dispersinė analizė,
- ◆ diskriminantinė analizė,
- ◆ regresinė analizė,
- ◆ logistinė regresinė analizė.

Vertinant vainikinių arterijų susiaurėjimą ir naudojant parametrinius modelius jų adekvatiškumui įvertinti tikrinamos suderinamumo hipotezės [22]. Pavyzdžiui, taikant Stjudento t kriterijų, dispersinės, diskriminantinės ar regresinės analizės modelius, reikalaujama, kad parametrų arba liekanų skirstiniai būtų normalieji. Koreliacinėje analizėje koreliacijos koeficientų parenkami priklausomai nuo

suderinamumo hipotezių tikrinimo rezultatų. Koreliacinė analizė naudojama, kai reikia įvertinti ryšį tarp atskirų elektrokardiogramos ir vektorkardiogramos parametrų. Tokiam pačiam uždaviniui gali būti naudojama ir daugialypė regresinė analizė [28]. Kai hipotezės apie parametrų normalumą nėra priimtinos, tuomet galima juos normalizuoti [23] arba naudoti neparametrinius kriterijus. Jeigu yra lyginamos kelios ligonių grupės ir norima nustatyti, ar parametrų, išmatuotų intervalų skalėje, vidurkiai atskirose grupėse statistiškai reikšmingai skiriasi, galima taikyti dispersinę analizę ar Stjudento t kriterijų [22], tačiau jei hipotezės apie parametrų skirstinių normalumą nėra priimtinos arba yra analizuojami kategoriniai kintamieji, tuomet naudojamas χ^2 kriterijus [29]. Logistinė regresija gali būti taikoma stenozės rizikos laipsniui nustatyti [28] arba informatyvių elektrokardiografinių parametrų radimui (vienfaktorinė logistinė regresija) [29]. Taikant Stjudento kriterijus, dispersinę analizę ar logistinę regresinę analizę yra atrenkami informatyvūs parametrai, tačiau reikia įvertinti ir tai, kad ir neinformatyvių parametrų daugiamatis sąryšis gali būti naudingas ir informatyvus [12]. Kai logistinės regresijos ar diskriminantinės analizės modeliuose naudojama daug nepriklausomų kintamųjų (EKG ir VKG parametrų) informatyvių parametrų rinkinius galima rasti naudojant pažingsninį metodą [23]. Diskriminantinės analizės bei logistinės regresinės analizės modeliai leidžia klasifikuoti pacientus į atskiras grupes bei prognozuoti jų vainikinių širdies arterijų stenozės laipsnį [23].

Darbe vainikinių arterijų susiaurėjimų įvertinimui naudojama neparametrinė diskriminantinė analizė, tačiau šio metodo taikymo pavyzdžių literatūroje nepavyko rasti. Plačiau aptarsime pagrindinius statistinės analizės modelius, naudojamus darbe.

Logistinė regresija

Logistinė regresija darbe taikoma kategorinio kintamojo reikšmių tikimybėms prognozuoti. Kita vertus, kategorinio kintamojo reikšmių prognozavimas tam tikra prasme yra klasifikavimo uždavinys. Taigi logistinė regresija gali būti taikoma ir klasifikavimui, tačiau tik tuo atveju, kai klasifikuojama į dvi grupes.

Taigi, logistinė regresija taikoma, kai nagrinėjamas kategorinis kintamasis, įgyjantis dvi reikšmes: 1 ir 0, o nepriklausomai kintamieji X_1, X_2, \dots, X_n , išmatuoti intervalų skalėje arba yra pseudokintamieji. Esant fiksuotoms nepriklausomų kintamųjų reikšmėms $X_1 = x_{1i}, \dots, X_n = x_{ni}$, atsitiktinis dydis, t.y. kategorinis kintamasis Y_i , gali įgyti reikšmes 0 arba 1 su tikimybėmis $P(Y_i = 1) = p_i$, $P(Y_i = 0) = 1 - p_i$ ($i = \overline{1, n}$). Tuomet logistinės regresijos modelis yra

$$p_i = \frac{\exp\left\{z\left(\vec{x}_i\right)\right\}}{1 + \exp\left\{z\left(\vec{x}_i\right)\right\}}, \text{ kur } z\left(\vec{x}_i\right) = a + b_1 x_{1i} + \dots + b_n x_{ni}. \quad (1.1)$$

Iš (1.1) lygties išreiškiame :

$$\frac{p_i}{1-p_i} = \exp\{a + b_1 x_{1i} + \dots + b_n x_{ni}\} = \exp\left\{z\left(\vec{x}_i\right)\right\} \quad (1.2)$$

$$\ln \frac{p_i}{1-p_i} = a + b_1 x_{1i} + \dots + b_n x_{ni} = z\left(\vec{x}_i\right) \quad (1.3)$$

Tikimybių santykis $\frac{p_i}{1-p_i}$ vadinamas galimybe (galimybės įvertinimu) įvykti įvykiui $Y_i = 1$.

Logistinė regresija tinka galiojant gana bendroms prielaidoms: kintamieji, X_2, \dots, X_n nebūtinai turi būti normalieji; nereikalaujama normaliai pasiskirsčiusių paklaidų. Taikant tas pačias, kaip ir daugialypėje regresijoje, kodavimo taisykles, į modelį galima įtraukti ir pseudokintamuosius.

Tarkime duomenis sudaro stebėjimai $(y_i, x_{1i}, \dots, x_{ni}), i = 1, 2, \dots, k$; čia y_i yra arba 0, arba 1, o x_{1i}, x_{2i}, \dots – intervalinių kintamųjų reikšmės. Parametrų a, b_1, \dots, b_n įverčius $\hat{a}, \hat{b}_1, \dots, \hat{b}_k$ reikia parinkti taip, kad (1.1) modelis su turimais duomenimis būtų kuo geriau suderintas. Tam taikomas didžiausio tikėtimumo metodas ir gaunamas tikimybės įvertis :

$$\hat{p}_i = \frac{\exp\left\{\hat{z}\left(\vec{x}_i\right)\right\}}{1 + \exp\left\{\hat{z}\left(\vec{x}_i\right)\right\}}, \quad \hat{z}\left(\vec{x}_i\right) = \hat{a} + \hat{b}_1 x_{1i} + \dots + \hat{b}_n x_{ni}. \quad (1.4)$$

Tiriant intervalinius kintamuosius, \hat{b}_j parodo, kiek padidėja (sumažėja) $\hat{z}\left(\vec{x}_i\right)$ reikšmė, kai x_j padidėja vienu vienetu, o likusieji nepriklausomi kintamieji yra fiksuoti. Paprastai skaičiuojamas vadinamas galimybių santykis $\exp\left\{\hat{b}_j\right\}$, kuris parodo, kaip kinta Y galimybė įgyti reikšmę 1.

Aprašysime, kaip logistinė regresija taikoma klasifikavimui. Žinodami $P\left(Y = 1 \mid \vec{x}\right)$ įvertį, galime nustatyti taisyklę Y reikšmei prognozuoti. Jeigu $\hat{P}\left(Y = 1 \mid \vec{x}\right) > 0,5$, tai prognozuojame, kad Y reikšmė yra 1. Jeigu $\hat{P}\left(Y = 1 \mid \vec{x}\right) < 0,5$, tai prognozuojame, kad Y reikšmė yra 0. $\hat{P}\left(Y = 1 \mid \vec{x}\right) > 0,5$ tada ir tik tada, kai $\hat{z}\left(\vec{x}_i\right) > 0$. Todėl Y reikšmėms prognozuoti patogiau taikyti tokią taisyklę: į

formulę $\hat{z}(\vec{x}_i) = \hat{a} + \hat{b}_1 x_{i1} + \dots + \hat{b}_n x_{in}$ įstatomos x_1, x_2, \dots, x_n reikšmės. Jeigu $\hat{z}(\vec{x}_i) > 0$, tai prognozuojama, kad Y reikšmė yra 1. Jeigu $\hat{z}(\vec{x}_i) < 0$, tai prognozuojama, kad Y reikšmė yra 0.

Kai logistinės regresijos lygtyje yra naudojama keletas ar net keliolika nepriklausomų kintamųjų, galimas atvejis, kad ne visi į modelį įtraukti nepriklausomi kintamieji yra svarbūs prognozavimui. Jeigu prognozuojama tikimybė nuo kintamojo x_j nepriklauso, tai modelio parametras $b_j = 0$. Todėl yra tikrinamos statistinės hipotezės apie parametru b_j lygybę nuliui. Hipotezių tikrinimui taikomi χ^2 suderinamumo kriterijus ir Voldo kriterijus. Tokiu būdu gali būti gaunama optimali logistinės regresijos lygtis, kuri geriausiai prognozuoja kintamojo Y reikšmę.

Tikrinant ar sudaryta logistinės regresijos lygtis tinka prognozavimui naudojama keletas metodų. Vienas iš tokių metodų yra Hosmerio-Lemešou kriterijus. Taikant šį kriterijų skaičiuojama Hosmerio-Lemešou statistika, kuri lyginama su χ^2 skirstiniu su $(k - 2)$ laisvės laipsnių. Fiksuojamas reikšmingumo lygmuo α ir kai Hosmerio-Lemešou statistikos p -reikšmė $p \geq \alpha$, gauname patvirtinimą, kad logistinės regresijos modelis su duomenimis suderintas. Logistinės regresijos lygties tinkamumui nustatyti naudojama ir klasifikacijos rezultatų lentelė. Taikant gautą lygtį apskaičiuojami tikimybių įverčiai $P(Y = 1 | \vec{x})$, pagal anksčiau aprašytą procedūrą įvykiai $Y_i = 1$ ir $Y_i = 0$ suskirstomi į dvi grupes ir pagal gautus klasifikavimo rezultatus apskaičiuojami klasifikavimo jautrumas, specifiškumas ir bendras teisingo klasifikavimo procentas. Klasifikavimo jautrumas nusako galimybę teisingai prognozuoti įvykį $Y_i = 1$ naudojant sudarytą logistinės regresijos lygtį, specifiškumas – įvykį $Y_i = 0$, bendras teisingo klasifikavimo procentas nusako teisingai klasifikuotų visų įvykių procentą.

Diskriminantinė analizė

Diskriminantinėje analizėje pagal intervalinių kintamųjų reikšmes sprendžiama apie objekto priklausomybę vienai iš keleto grupių. Visais atvejais tenka spręsti atskiriamumo (diskriminavimo) ir (arba) klasifikavimo uždavinius. Diskriminavimo tikslas – nustatyti požymius, padedančius atskirti tiriamų objektų grupes bei įvertinti diskriminavimo kokybę.

Diskriminantinės analizės etapai:

1. Nustatoma, kurie kintamieji tinka tiriamų objektų diskriminavimui. Pašalinami kintamieji, nepadedantys nustatyti grupių skirtumų.
2. Ieškoma diskriminavimo priežasčių. Įvertinama diskriminavimo kokybė.
3. Parenkamas labiausiai tinkamas klasifikuoti būdas. Sudaromos klasifikavimo taisyklės, t.y. konstruojamos klasifikavimo funkcijos.
4. Įvertinamas klasifikavimo patikimumas. Sudaromos klasifikavimo lentelės. Skaičiuojami klaidingos klasifikacijos tikimybių įverčiai.

Tarkime, kad matuojame kiekvieno objekto p intervalinių (vadinamųjų diskriminavimo) kintamųjų (X_1, X_2, \dots, X_p) . Žinome, kad objektų imtį sudaro g grupių. Imties duomenis sudaro stebėjimai (x_{ijk}) , $i = \overline{1, p}$, $j = \overline{1, g}$, $k = \overline{1, n_j}$; čia (x_{ijk}) yra i -ojo kintamojo k -asis stebėjimas j -oje grupėje, n_j -stebėjimų skaičius j -oje grupėje. Kai objektą aprašantys kintamieji pasiskirstę pagal daugiamatį normalųjį skirstinį $N_p(\mu_j, \Sigma_j)$, čia j žymi grupę, kuriai priklauso objektas, o p – kintamųjų skaičių, tuomet klasifikavimui naudojamos taip vadinamos parametrinės klasifikavimo funkcijos, priešingu atveju naudojami neparametrinė diskriminantinė analizės metodai. Taikant diskriminantinę analizę turi būti išpildomos sąlygos:

1. Grupių skaičius turi būti baigtinis.
2. Grupės nepriklausomos ir neturi bendrų objektų, t.y. objektas vienu metu negali priklausyti kelioms grupėms.
3. Diskriminavimo kintamieji turi būti matuojami pagal intervalų skalę.
4. Nė vienas diskriminavimo kintamasis negali būti kitų kintamųjų tiesinė daugyda.

Parametrinėje diskriminantinėje analizėje sudarant klasifikavimo funkcijas yra galimi du atvejai: kai diskriminavimo kintamųjų kovariacijų matricos grupėse lygios, t.y. $\Sigma_1 = \Sigma_2 = \dots = \Sigma_g$, tuomet naudojama tiesinė klasifikavimo (diskriminantinė) funkcija, o kai kovariacijų matricos grupėse nelygios – naudojama kvadratinė klasifikavimo (diskriminantinė) funkcija.

Tiesinės klasifikavimo funkcijos išraiška:

$$d_i(\vec{x}) = -\frac{1}{2} \mu_i' \Sigma^{-1} \mu_i + \mu_i' \Sigma^{-1} \vec{x} + \ln p_i = d_{i0} + \sum_{j=1}^p d_{ij} x_j + \ln p_i, \quad (1.5)$$

čia i žymi grupės numerį ($i = \overline{1, g}$), $d_{i0} = -\frac{1}{2} \mu_i' \Sigma^{-1} \mu_i$, $d_{ij} = j$ -asis elementas iš $\mu_i' \Sigma^{-1}$, p_i - apriorinė tikimybė, kad kintamasis priklauso i – ajai grupei.

Objektas, aprašomas kintamųjų vektoriumi \vec{x} , priskiriamas i – ajai grupei, jei $d_i(\vec{x})$ palyginti su kitomis funkcijų $d_j(\vec{x})$ ($j \neq i$) reikšmėmis, įgyja didžiausią reikšmę.

Tarkime kovariacijų matricos grupėse nelygios, t.y. $\Sigma_i \neq \Sigma_j$. Tuomet klasifikavimas atliekamas naudojant kvadratinę klasifikavimo funkciją:

$$d_i(\vec{x}) = -\frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (\vec{x} - \mu_i)' \Sigma_i^{-1} (\vec{x} - \mu_i) + \ln p_i, \quad (1.6)$$

čia i žymi grupės numerį ($i = \overline{1, g}$), Σ_i - kovariacijų matrica i – ojoje grupėje, p_i - apriorinė tikimybė, kad kintamasis priklauso i – ajai grupei. Klasifikacija atliekama tokiu principu kaip ir taikant tiesinę klasifikavimo funkciją.

Parametrinę diskriminantinę analizę taikant praktikoje dažnai tiek parametrų vidurkiai, tiek kovariacijų matricos yra nežinomi. Šiuo atveju vidurkis μ_i keičiamas empiriniu vidurkiu \bar{x}_i , o kovariacijų matricos empirinėmis kovariacijų matricomis. Naudojant tiesinę klasifikavimo funkciją, kovariacijų matrica apskaičiuojama pagal formulę

$$\frac{\sum_{i=1}^g (n_i - 1) \Sigma_i}{\sum_{i=1}^g (n_i - 1)}. \quad (1.7)$$

Literatūros šaltiniuose nepavyko rasti informacijos, apie neparametrinės diskriminantinės analizės naudojimą tiriant širdies išeminę ligą ar vainikinių arterijų susiaurėjimus. Tačiau neparametrinė diskriminantinės analizė yra parametrinės diskriminantinės analizės analogas tuo atveju, kai neišpildoma sąlyga dėl diskriminavimo kintamųjų skirstinių normalumo. Todėl ji taip pat gali būti taikoma nustatant vainikinių arterijų susiaurėjimus. Pagrindiniai neparametriniai diskriminantinės analizės klasifikavimo metodai yra branduolio metodas ir k -artimiausių kaimynų metodas. Klasifikavimui naudojant branduolio metodą, pirmiausiai kiekvienai grupei t nustatomas branduolio tankio įvertis su fiksuotu spinduliu r . Gali būti naudojami įvairūs branduolio tankio įverčiai, jie pateikti 1.1 lentelėje.

1.1 lentelė

Branduolio tipai

Branduolio pavadinimas	Branduolio funkcija
Tolygusis	$K_i(\vec{x}) = \begin{cases} \frac{1}{v_r(i)}, & \text{jeigu } (\vec{x})^T \mathbf{V}_i^{-1} \vec{x} \leq r^2 \\ 0, & \text{kitu atveju} \end{cases}$ $v_r(i) = r^p \mathbf{V}_i ^{1/2} v_0, \quad v_0 = \frac{\pi^{p/2}}{\Gamma\left(\frac{p}{2} + 1\right)}, \quad p - \text{diskriminavimo kintamųjų skaičius};$
Normalusis	$K_i(\vec{x}) = \frac{1}{c_0(i)} \exp\left(-\frac{1}{2r^2} (\vec{x})^T \mathbf{V}_i^{-1} \vec{x}\right), \quad c_0(i) = (2\pi)^{p/2} r^p \cdot \mathbf{V}_i ^{1/2}$
Epanechnikovo	$K_i(\vec{x}) = \begin{cases} c_1(i) \left(1 - \frac{1}{r^2} (\vec{x})^T \mathbf{V}_i^{-1} \vec{x}\right), & \text{jeigu } (\vec{x})^T \mathbf{V}_i^{-1} \vec{x} \leq r^2 \\ 0, & \text{kitu atveju} \end{cases}$ $c_1(i) = \frac{1}{v_r(i)} \left(1 + \frac{p}{2}\right)$

1.1 lentelės tęsinys kitame puslapyje

Branduolio pavadinimas	Branduolio funkcija
Dvisvoris	$K_i(\vec{x}) = \begin{cases} c_2(i) \left(1 - \frac{1}{r^2} \left(\vec{x} \right)^T \mathbf{V}_i^{-1} \vec{x} \right)^2, & \text{jeigu } \left(\vec{x} \right)^T \mathbf{V}_i^{-1} \vec{x} \leq r^2 \\ 0, & \text{kitu atveju} \end{cases}$ $c_2(i) = \left(1 + \frac{p}{4} \right) c_1(i)$
Trisvoris	$K_i(\vec{x}) = \begin{cases} c_3(i) \left(1 - \frac{1}{r^2} \left(\vec{x} \right)^T \mathbf{V}_i^{-1} \vec{x} \right)^3, & \text{jeigu } \left(\vec{x} \right)^T \mathbf{V}_i^{-1} \vec{x} \leq r^2 \\ 0, & \text{kitu atveju} \end{cases}$ $c_3(i) = \left(1 + \frac{p}{6} \right) c_2(i)$

Bendru atveju objektai klasifikuojami į grupes naudojant Bajeso klasifikavimo procedūrą. Taikant procedūrą, pirmiausiai apskaičiuojamos aposteriorinės tikimybės

$$p\left(i \mid \vec{x}\right) = \frac{q_i f_i\left(\vec{x}\right)}{f\left(\vec{x}\right)}, \quad (1.8)$$

čia q_i yra apriorinė tikimybė, kad objektas priklauso i – ajai grupei, $f\left(\vec{x}\right) = \sum_i q_i f_i\left(\vec{x}\right)$, $f_i\left(\vec{x}\right)$ – kintamųjų vektoriaus \vec{x} i – oje grupėje tankio funkcija. Pastaroji funkcija apskaičiuojama tokiu būdu:

$$f_i\left(\vec{x}\right) = \frac{1}{n_i} \sum_{\vec{y}} K_i\left(\vec{x} - \vec{y}\right), \quad (1.9)$$

čia sumuojama pagal visus i – osios grupės objektus, parašomus vektoriais \vec{y} , n_i – objektų priklausančių i – ajai grupei skaičius, K_i – pasirinkta branduolio įverčio funkcija. Apskaičiuavus tikimybes, objektas priskiriamas tai grupei, kurios aposteriorinė tikimybė didžiausia.

Klasifikavimo procedūros kokybę galima vertinti pagal klasifikavimo rodiklius (specifiškumą, jautrumą) bei klaidingo klasifikavimo tikimybių įverčius. Klaidingo klasifikavimo tikimybes galima apskaičiuoti keliais būdais:

1. Naudojant mokomąją imtį. Šiuo būdu apskaičiuotos tikimybės gali būti neadekvačiai mažos.
2. Dalinant tiriamą duomenų imtį į dvi imtis – „mokomąją“ ir „testinę“ santykiu 2:1. Klasifikavimo taisyklei nustatyti naudojama mokomoji imtis. Šios klasifikavimo funkcijos pritaikomos testinei imčiai ir tada apskaičiuojamos klaidingo klasifikavimo tikimybės.

3. Naudojant Lachenbruch procedūrą. Šiuo atveju pašalinamas vienas stebėjimas, o likusiųjų stebėjimų pagrindu sudaroma klasifikavimo funkcija. Naudojant šią funkciją pašalintas stebėjimas yra klasifikuojamas. Tai pakartojama visiems stebėjimams ir gauti rezultatai panaudojami klaidingo klasifikavimo tikimybės apskaičiuoti. Pastarasis metodas gana tiksliai apibūdina faktines klaidingo klasifikavimo tikimybes.

1.4. DARBE SPRENDŽIAMŲ UŽDAVINIAI

Vertinant širdies vainikinių arterijų susiaurėjimą naudojami elektrokardiogramos (EKG), vektorkardiogramos (VKG) parametrai, koronorografijos duomenys. Naudojant turimus duomenis, reikia:

- rasti informatyvius EKG ir VKG parametrų rinkinius;
- sukurti pacientų vainikinių arterijų stenozės laipsnio prognozavimo statistinės analizės modelius;
- sukurti pacientų klasifikavimo į grupes pagal vainikinių širdies arterijų susiaurėjimo laipsnį statistinės analizės modelius;
- sukurti širdies vainikinių arterijų susiaurėjimo analizės modelių programinę įrangą;
- atlikti sukurtų statistinių modelių lyginamąją analizę;


2. TIRIAMOJI DALIS

2.1. PACIENTŲ DUOMENŲ BAZĖS MODELIS

Iš KMUK kardiologijos klinikoje 1999 – 2004 metais registruotų ramybės elektrokardiogramų (EKG) atsitiktinai buvo atrinktos 314 pacientų elektrokardiogramos. Visiems pacientams buvo registruojama ramybės skaitmeninė EKG. Vėliau šios EKG buvo apdorojamos automatizuota EKG analizės sistema, sukurta KMU Kardiologijos instituto Kardiologinių tyrimų automatizacijos laboratorijoje. EKG kompiuterinės analizės sistemoje registruojamos 8 derivacijos – I, II, V1- V6, o kitos keturios – III, aVR, aVL ir aVF atkuriamos iš I ir II derivacijų. Kitame analizės etape atpažįstamos EKG P, Q, R, S, T bangos, išmatuojamos jų amplitudės ir trukmės, atliekamas parametrų vidurkinimas 10 s trukmės įrašė.

Kardiologijos klinikoje elektrokardiograma registruojama įprastinėje skaliarinėje 12 derivacijų EKG sistemoje, tuo tarpu kai vektorkardiogramos parametrų įvertinimui reikalingos vektorkardiogramos X, Y, Z derivacijos pagal Franką. Todėl vektorkardiograma buvo sintezuota iš 12 derivacijų elektrokardiogramos Dower matricos pagalba [18]. Vektorkardiograma susideda iš dviejų

pagrindinių kilpų. Didesnė iš jų atspindi širdies aktyvacijos fazę (QRS kompleksas), kita – atsistatymo fazę (T banga) (2.1 pav).




2.1 pav. Vektorkardiograma

T kilpa vektorkardiogramoje dažniausiai būna beveik plokščia ir naudojant mažiausių kvadratų metodą suprojektuojama į plokštumą. Plokštumoje kilpa įbrėžiama į kvadratą. Kvadratas dalinamas į 400 dalių. Tos dalys, kurios kerta T kilpą pažymimos juodai – T kilpos ilgis, o kurios nekerta kilpos pažymimos baltai – T kilpos plotas (2.2 pav.). Vektorių projekcijas frontalinėje plokštumoje apibrėžiantys kampai α_{QRS} , α_P , α_T ir α_{QRS-T} , α_{P-QRS} nustatomi iš I ir III derivacijų ir apskaičiuojami pagal formulę:

$$\alpha_i = \arctg\left(1,15 \frac{\Delta\alpha_i^{III}}{\Delta\alpha_i^I} + 0,575\right), \quad (2.1)$$

kur $\Delta\alpha_i^{III}$ yra QRS, P ar T bangų amplitudžių algebrinė suma III derivacijoje, o $\Delta\alpha_i^I$ – I derivacijoje. Į lygtį koeficientai 1,15 ir 0,575 įrašyti todėl, kad I ir III derivacijos nėra tarpusavyje statmenos.



2.2 pav. Vektorkardiografinis T kilpos vaizdas suprojektuotas į plokštumą

Visiems atrinktiems pacientams buvo atlikta koronarografija. Jos metu nustatyta stenozė 50 procentų ir daugiau bent vienoje vainikinėje arterijoje buvo vertinta hemodinamiškai reikšminga, priešingu atveju – hemodinamiškai nereikšminga. Pagal vainikinių arterijų susiaurėjimo laipsnį pacientai suskirstyti į dvi grupes:

1. vainikinių arterijų stenozė hemodinamiškai nereikšminga,
2. vainikinių arterijų stenozė hemodinamiškai reikšminga.

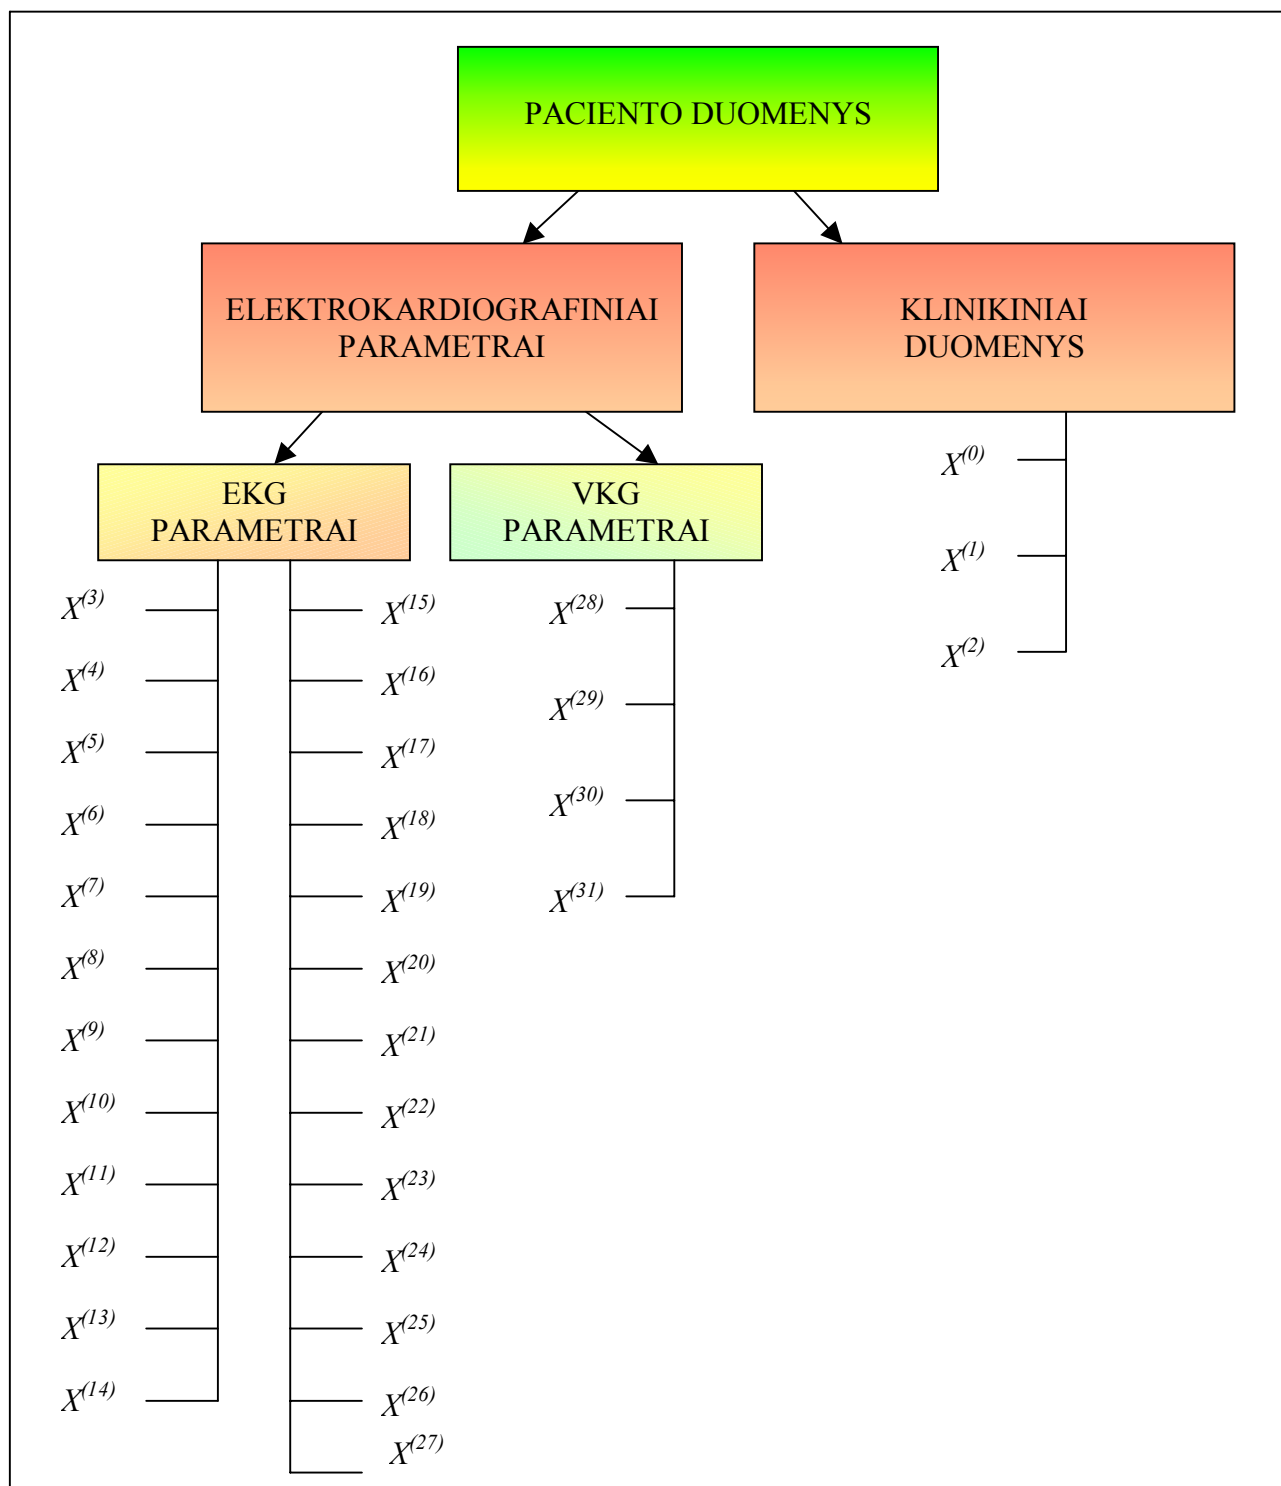
Darbe analizuojami 234 pacientų duomenys, likusių 79 pacientų duomenys į tyrimą nebuvo įtraukti dėl trūkstančių kai kurių parametrų reikšmių. Darbe tiriamos dvi pacientų imtys: vyrų ir moterų. Vyrų imtį sudaro 165 pacientai, iš kurių 68 pacientų vainikinių širdies arterijų susiaurėjimas buvo diagnozuotas (atliekant koronarografiją) hemodinamiškai nereikšmingas, o 97 pacientams – hemodinamiškai reikšmingas. Moterų tiriamą imtį sudaro 70 pacienčių duomenys, iš kurių 40 vainikinių arterijų susiaurėjimas diagnozuotas hemodinamiškai nereikšmingas, o 30 – hemodinamiškai reikšmingas.

Kiekvieną pacientą aprašančią duomenų aibę galima suskirstyti į dvi dalis: klinikinius duomenis ir elektrokardiografinius parametrus (2.3 pav.). Elektrokardiografiniai parametrai dar yra skirstomi į dvi grupes: ramybės elektrokardiogramos (EKG) ir vektorkardiogramos (VKG) parametrus.

Aptarsime tyrime naudojamus pacientų duomenis:

- klinikiniai duomenys: $X^{(0)}$ – grupė (0 – paciento vainikinių arterijų stenozė hemodinamiškai nereikšminga, 1 – paciento vainikinių arterijų stenozė hemodinamiškai reikšminga), $X^{(1)}$ – lytis, $X^{(2)}$ – amžius;
- elektrokardiografiniai parametrai: $X^{(3)}$ – QT intervalo dispersija, kai QT intervalas išmatuotas galūnių derivacijose, $X^{(4)}$ – JT intervalo dispersija, kai JT intervalas išmatuotas galūnių derivacijose, $X^{(5)}$ – QT intervalo dispersija, kai QT intervalas išmatuotas krūtinės derivacijose, $X^{(6)}$ – JT intervalo dispersija, kai JT intervalas išmatuotas krūtinės derivacijose, $X^{(7)}$ – maksimali koreguoto QT intervalo trukmė, $X^{(8)}$ – minimali koreguoto QT intervalo trukmė, $X^{(9)}$ – maksimali koreguoto JT intervalo trukmė, $X^{(10)}$ – minimali koreguoto JT intervalo trukmė, $X^{(11)}$ – koreguoto QT intervalo dispersija, $X^{(12)}$ – koreguoto JT intervalo dispersija, $X^{(13)}$ – vidutinis širdies susitraukimų dažnis, $X^{(14)}$ – vidutinė RR intervalo trukmė, $X^{(15)}$ – maksimali RR intervalo trukmė, $X^{(16)}$ – minimali RR intervalo trukmė, $X^{(17)}$ – maksimalus RR intervalų skirtumas, $X^{(18)}$ – standartinis RR intervalo nuokrypis, $X^{(19)}$ – variacijos koeficientas, $X^{(20)}$ – skirtumų tarp gretimų RR intervalų vidurkių kvadratų sumos kvadratinė šaknis, $X^{(21)}$ – labai žemų dažnių spektrinė komponentė, $X^{(22)}$ – žemų dažnių spektrinė komponentė, $X^{(23)}$ – aukštų dažnių spektrinė komponentė, $X^{(24)}$ – bendras spektrinis intensyvumas, $X^{(25)}$ – normalizuota žemų dažnių komponentė, $X^{(26)}$ – normalizuota aukštų dažnių komponentė, $X^{(27)}$ – normalizuotos žemų dažnių komponentės ir normalizuotos aukštų dažnių komponentės santykis, $X^{(28)}$ – maksimalaus P vektoriaus kampas, $X^{(29)}$ – kampas tarp maksimalių QRS ir T vektorių, $X^{(30)}$ – T

kilpos plotas, $X^{(31)}$ – T kilpos ploto ir ilgio santykis. Visi EKG ir VKG parametrai išmatuoti intervalų skalėje.



2.3 pav. Tyrime naudojami pacientų duomenys

Statistinės analizės modeliuose naudojami elektrokardiogramos ir vektorkardiogramos parametrai bei vienas klinikinis parametras – amžius. Likusieji klinikiniai parametrai naudojami sudarant įvairius duomenų matricos pjūvius, t.y. sudaryti atskiras pacientų imtis bei pacientus suskirstyti į grupes pagal jų vainikinių arterijų susiaurėjimų laipsnį.

2.2. VAINIKINIŲ ŠIRDIES ARTERIJŲ SUSIAURĖJIMŲ ĮVERTINIMO PAGAL EKG IR VKG PARAMETRUS MODELIAI

Naudojantis tyrimui atrinktų 234 pacientų klinikiniais bei elektrokardiografiniais duomenimis buvo sukurti logistinės regresinės, parametrinės ir neparametrinės diskriminantinės analizės modeliai, skirti pacientų vainikinių širdies arterijų susiaurėjimams įvertinti. Medicinos praktikoje yra žinoma, kad elektrokardiografiniai moterų ir vyrų parametrai skiriasi, todėl sudaromi modeliai atskirai vyrų ir moterų vainikinių arterijų susiaurėjimams įvertinti. Naudojant modelius buvo išskiriami informatyvūs parametru rinkiniai, kuriuos sudaro pacientų klinikiniai duomenys, ramybės elektrokardiogramos bei vektorkardiogramos parametrai. Sukurti modeliai prognozuoja pacientų vainikinių arterijų stenozės laipsnį bei klasifikuoja juos į dvi grupes pagal vainikinių arterijų susiaurėjimų laipsnį. Toliau yra aptariamas kiekvienas modelis atskirai. Aprašant sukurtus modelius, pateikiamos jų matematinės išraiškos, gauti prognozavimo ir klasifikavimo rezultatai. Panaudojus tuos pačius duomenis, atlikta pasiūlytų modelių lyginamoji analizė.

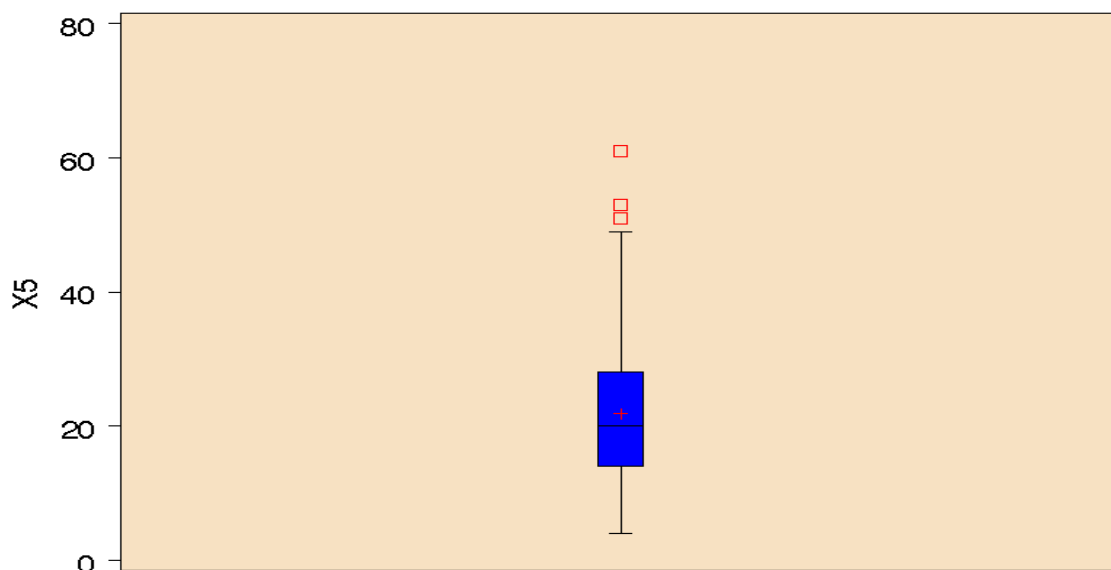
2.2.1. APRAŠOMOJI STATISTIKA

Aprašomoji statistika pateikia informaciją apie sukauptus pacientų elektrokardiogramos (EKG) ir vektorkardiogramos (VKG) duomenis. Naudojant aprašomąją statistiką skaičiuojamos kintamųjų skaitinės charakteristikos, kurios pateikiamos ir grafiškai, naudojant stačiakampes diagramas. Sudarius dvi pacientų imtis (vyrų ir moterų), kiekvienam kintamajam skaičiuojamos skaitinės charakteristikos (vidurkis, standartinis nuokrypis, kvartiliai, minimumas ir maksimumas). 2.1 lentelėje pateiktos vyrų imties skaitinės charakteristikos. Visų analizuotų parametru skaitinės charakteristikos vyrų ir moterų imtims pateiktos 2 priede. Lentelėje galima pastebėti, kad parametru reikšmių kitimo intervalai yra gana dideli.

2.1 lentelė

Vyrų imties skaitinės charakteristikos

Kintamasis	Vidurkis	Standartinis nuokrypis	Pirmasis kvartilis	Mediana	Tre iasis kvartilis	Minimumas	Maksimumas
$X^{(2)}$	57.23	10.26	49	58	65	32	81
$X^{(3)}$	34	12.35	25	32	43	11	77
$X^{(4)}$	35.02	13.42	27	33	42	10	85
$X^{(5)}$	21.79	11.42	14	20	28	4	61



2.4 pav. Kintamojo $X^{(5)}$ stačiakampė diagrama


Stačiakampė $X^{(5)}$ parametro diagrama (2.4 pav.) grafiškai vaizduoja skaitines charakteristikas. Kadangi parametrų reikšmių kitimo intervalai yra dideli (2.1 lentelė), todėl galima įtarti, kad duomenyse yra išskirčių. Šį spėjimą patvirtina stačiakampė diagrama, kurioje ir yra pažymėtos išskirtys.

Kiekvienos imties pacientus suskirsčius į grupes pagal vainikinių arterijų susiaurėjimą, skaičiuojamos šių grupių kintamųjų skaitinės charakteristikos, kurios taip pat vaizduojamos stačiakampėmis diagramomis. 2.2 lentelėje pateikiamos moterų imties keturių parametrų skaitinės charakteristikos atskirose pacienčių grupėse. Visų analizuotų parametrų skaitinės charakteristikos vyrų ir moterų imtims atskirose grupėse pateiktos 2 priede.

2.2 lentelė

Moterų imties skaitinės charakteristikos atskirose grupėse

Grupė	Kintamasis	Vidurkis	Standartinis nuokrypis	Pirmasis kvartilis	Mediana	Trečiasis kvartilis	Minimumas	Maksimumas
0	$X^{(2)}$	63.73	7.09	57.5	66	68.5	49	77
	$X^{(3)}$	26.6	7.53	20	25.5	33.5	16	44
	$X^{(4)}$	31.9	10.2	24.5	31.5	38	12	56
	$X^{(5)}$	18.45	7.13	13	18.5	21	4	39
1	$X^{(2)}$	63.9	8.55	59	63	70	45	81
	$X^{(3)}$	30.87	10.02	21	30	40	15	48
	$X^{(4)}$	34.5	11.05	26	32	42	18	56
	$X^{(5)}$	22.3	8.34	17	23	28	5	37



2.5 pav. Kintamojo $X^{(5)}$ stačiakampės diagramos atskirose pacientų grupėse

Šiuo atveju nubraižyta stačiakampė diagrama leidžia vizualiai palyginti parametru skaitines charakteristikas atskirose grupėse. Kaip pavyzdys pateiktos moterų imties atskirose grupėse $X^{(5)}$ parametro stačiakampės diagramos (2.5 pav.). Analizuojant diagramas galima įtarti, kad parametro vidurkiai atskirose grupėse statistiškai reikšmingai skiriasi. Jose matyti, kad pirmojoje grupėje vyrauja didesnės kintamojo reikšmės. Likusios stačiakampės diagramos pateiktos 2 priede.

2.2.2. VAINIKINIŲ ŠIRDIES ARTERIJŲ SUSIAURĖJIMŲ ĮVERTINIMO PAGAL EKG IR VKG PARAMETRUS LOGISTINĖS REGRESIJOS MODELIS

Logistinės regresijos modelyje naudojant nepriklausomus kintamuosius yra prognozuojamos dvireikšmio kategorinio kintamojo reikšmių tikimybės. Kategorinio kintamojo reikšmių prognozavimas tam tikra prasme yra klasifikavimo uždavinys, todėl logistinės regresijos modelis gali būti taikomas ir pacientų klasifikavimui pagal vainikinių širdies arterijų susiaurėjimų laipsnį. Analizėje naudojamas kategorinis kintamasis, kurio reikšmių tikimybės buvo prognozuojamos – *grupe* ($X^{(0)}$). Kintamasis įgyja dvi reikšmes: 0 – paciento vainikinių arterijų stenozė hemodinamiškai nereikšminga, 1 – paciento vainikinių arterijų stenozė hemodinamiškai reikšminga. Šiuo atveju nepriklausomi kintamieji yra paciento elektrokardiografiniai, t.y. elektrokardiogramos (EKG) ir vektorkardiogramos (VKG) parametrai bei paciento amžius.

Tarkime norime apskaičiuoti tikimybę, kad i -ojo paciento vainikinių arterijų stenozė hemodinamiškai reikšminga, t.y. $P(X_i^{(0)} = 1) = p_i$. Naudojame logistinės regresijos modelį:

$$p_i = \frac{\exp\left\{z\left(\vec{x}_i\right)\right\}}{1 + \left\{z\left(\vec{x}_i\right)\right\}}, \quad (2.2)$$

kai $z(\vec{x}_i) = a + b_1 x_{1i} + \dots + b_n x_{ni}$. Čia a yra konstanta, x_j – nepriklausomi kintamieji ($j = \overline{1, n}$), b_j – lygties parametrai, n – nepriklausomų kintamųjų skaičius. Iš (2.2) lygties išreiškę tikimybių santykį:

$$\frac{p_i}{1 - p_i} = \exp\left\{z\left(\vec{x}_i\right)\right\} \quad (2.3)$$

galime apskaičiuoti galimybę įvykti įvykiui $X_i^{(0)} = 1$. O išlogaritmavus abi (2.3) lygybės puses, gaunamas tiesinis logistikos modelis

$$\log\left\{\frac{p_i}{1 - p_i}\right\} = a + \sum_{k=1}^n b_k x_{ki}. \quad (2.4)$$

Lygtyse naudojamų parametų įverčiai apskaičiuojami didžiausio tikėtimumo metodu.

Iš pradžių aptarsime logistinės regresijos modelį, sukurtą vyrų populiacijai tirti. Analizuojant skaitines elektrokardiografinių parametų charakteristikas, buvo pastebėtos duomenų išskirtys. Išskirčių skaičiaus sumažinimui buvo atlikta kai kurių parametų transformacija, t.y. parametrai normalizuoti: $\ln(X^{(3)})$, $\ln(X^{(4)})$, $\sqrt{X^{(5)}}$, $\sqrt{X^{(6)}}$, $\frac{1}{[X^{(9)}]^2}$, $\frac{1}{[X^{(10)}]^2}$, $\ln(X^{(11)})$, $\sqrt{X^{(12)}}$, $\frac{1}{[X^{(14)}]^2}$, $\sqrt{X^{(17)}}$, $\sqrt{X^{(18)}}$, $\ln(X^{(19)})$, $\ln(X^{(20)})$, $\ln(X^{(21)})$, $\ln(X^{(22)})$, $\ln(X^{(23)})$, $\ln(X^{(27)})$. Tokios parametų transformacijos pasirinktos todėl, kad jas pritaikius, gautas geriausias kintamųjų reikšmių skirstinių suderinamumas su normaliuoju skirstiniu. Parametrai, kuriems atlikus įvairias transformacijas suderinamumo hipotezės nebuvo priimtinos, tyrime naudojami nenormalizuoti.

Į logistinės regresijos modelį, skirtą vyrų vainikinių arterijų susiaurėjimų prognozavimui, buvo įtraukti tik tie parametrai, kurie buvo reikšmingi prognozavimui. Informatyvių elektrokardiografinių parametų rinkinių buvo ieškoma naudojant pažingsninį metodą su įvairiais įrašymo ir išbraukimo lygmenimis. 2.3 lentelėje pateikiami gauti elektrokardiografinių parametų rinkiniai bei teisingo prognozavimo rodikliai, apskaičiuoti įrašius šiuos parametų rinkinius į logistinės regresijos lygtį.

2.3 lentelė

Pažingsninio metodo taikymo rezultatai

Parametr rinkinys	rašymo lygmuo	išbraukimo lygmuo	Klasifikavimo rezultatas		
			Bendras teisingo klasifikavimo procentas	Jautrumas	Specifiškumas
$X^{(2)}, X^{(29)}$	0,1	0,15	64,2%	82,5%	38,2%
$X^{(2)}, \ln(X^{(21)}), X^{(24)}, X^{(29)}, X^{(31)}$	0,3	0,35	60,6%	77,3%	36,8%
$X^{(2)}, -\frac{1}{[X^{(14)}]^2}, X^{(15)}, \sqrt{X^{(18)}}, \ln(X^{(19)}), \ln(X^{(20)}), \ln(X^{(21)}), X^{(24)}, X^{(29)}, X^{(31)}$	0,4	0,45	64,2%	78,4%	44,1%
$X^{(2)}, X^{(13)}, X^{(16)}, \sqrt{X^{(18)}}, \ln(X^{(19)}), \ln(X^{(20)}), \ln(X^{(21)}), \ln(X^{(22)}), \ln(X^{(23)}), X^{(24)}, X^{(26)}, X^{(27)}, X^{(29)}, X^{(31)}$	0,5	0,55	65,5%	77,3%	48,5%
$X^{(2)}, \sqrt{X^{(5)}}, \sqrt{X^{(6)}}, X^{(13)}, X^{(15)}, X^{(16)}, \sqrt{X^{(17)}}, \sqrt{X^{(18)}}, \ln(X^{(19)}), \ln(X^{(20)}), \ln(X^{(21)}), \ln(X^{(22)}), \ln(X^{(23)}), X^{(24)}, X^{(25)}, X^{(26)}, X^{(27)}, X^{(29)}, X^{(31)}$	0,55	0,6	65,5%	75,3%	51,5%

Naudojami trys teisingo prognozavimo (klasifikavimo) rodikliai: bendras teisingo klasifikavimo procentas, jautrumas ir specifiškumas. Modelio jautrumas išreiškiamas pacientų, kurių vainikinių arterijų susiaurėjimai buvo prognozuoti hemodinamiškai reikšmingi, skaičiaus ir visų tiriamų pacientų, kurių vainikinių arterijų susiaurėjimai hemodinamiškai reikšmingi, skaičiaus santykio procentine išraiška. Modelio specifiškumas parodo, keliasdešimčiai procentų pacientų iš visų pacientų, kurių širdies vainikinių arterijų susiaurėjimai hemodinamiškai nereikšmingi, vainikinių arterijų susiaurėjimai buvo prognozuoti hemodinamiškai nereikšmingi.

Remiantis gautais rezultatais bei atliktais stebėjimais į ketvirtąjį parametru rinkinį buvo įtrauktas $X^{(25)}$ parametras ir vyrų vainikinių širdies arterijų susiaurėjimo prognozavimo logistinės regresijos modeliui buvo pasirinktas kintamųjų rinkinys $X^{(2)}, X^{(13)}, X^{(16)}, \sqrt{X^{(18)}}, \ln(X^{(19)}), \ln(X^{(20)}), \ln(X^{(21)}), \ln(X^{(22)}), \ln(X^{(23)}), X^{(24)}, X^{(25)}, X^{(26)}, X^{(27)}, X^{(29)}, X^{(31)}$ bei sudaryta logistinės regresijos lygtis:

$$p_i = \frac{\exp\left\{z\left(\vec{x}_i\right)\right\}}{1 + \left\{z\left(\vec{x}_i\right)\right\}}, \quad (2.5)$$

$$\text{kai } z\left(\vec{x}_i\right) = a + b_2 x_i^{(2)} + b_{13} x_i^{(13)} + b_{16} x_i^{(16)} + b_{18} \sqrt{x_i^{(18)}} + b_{19} \ln(x_i^{(19)}) + b_{20} \ln(x_i^{(20)}) + b_{21} \ln(x_i^{(21)}) + \\ + b_{21} \ln(x_i^{(21)}) + b_{22} \ln(x_i^{(22)}) + b_{23} \ln(x_i^{(23)}) + b_{24} x_i^{(24)} + b_{25} x_i^{(25)} + b_{26} x_i^{(26)} + b_{27} x_i^{(27)} + b_{29} x_i^{(29)} + b_{31} x_i^{(31)},$$

i yra paciento numeris.

Naudojant didžiausio tikėtimumo metodą buvo apskaičiuoti koeficientų prie kintamųjų taškiniai įverčiai. Rezultatai pateikti 2.4 lentelėje.

2.4 lentelė
Logistinės regresijos
lygties koeficientų
taškiniai įverčiai

Kintamasis	Taškinis vertis
<i>Konstanta</i>	42969,8
$X^{(2)}$	0,0661
$X^{(13)}$	-0,0289
$X^{(16)}$	0,0118
$\sqrt{X^{(18)}}$	4,9803
$\ln(X^{(19)})$	-13,5009
$\ln(X^{(20)})$	1,6725
$\ln(X^{(21)})$	1,2618
$\ln(X^{(22)})$	0,6686
$\ln(X^{(23)})$	-0,5562
$X^{(24)}$	-0,00078
$X^{(25)}$	-429,7
$X^{(26)}$	-429,9
$X^{(27)}$	-3,3906
$X^{(29)}$	0,00827
$X^{(31)}$	0,3561

Apskaičiavus koeficientų taškinis įverčius, užrašoma logistinės regresijos lygtis, skirta vyrų populiacijos vainikinių širdies arterijų susiaurėjimams prognozuoti:

$$\hat{p}_i = \frac{\exp\left\{\hat{z}\left(\vec{x}_i\right)\right\}}{1 + \exp\left\{\hat{z}\left(\vec{x}_i\right)\right\}}, \quad (2.6)$$

$$\begin{aligned} \hat{z}\left(\vec{x}_i\right) = & 42969,8 + 0,0661x_i^{(2)} - 0,0289x_i^{(13)} + 0,0118x_i^{(16)} + 4,9803\sqrt{x_i^{(18)}} - 13,5009\ln(x_i^{(19)}) + \\ & + 1,6725\ln(x_i^{(20)}) + 1,2618\ln(x_i^{(21)}) + 0,6686\ln(x_i^{(22)}) - 0,5562\ln(x_i^{(23)}) - 0,00078x_i^{(24)} - \\ & - 429,7x_i^{(25)} - 429,9x_i^{(26)} - 3,3906x_i^{(27)} + 0,00827x_i^{(29)} + 0,3561x_i^{(31)}, \end{aligned}$$

$\hat{p}_i = P(x_i^{(0)} = 1)$, i – paciento numeris. Naudojantis sudarytu modeliu apskaičiuojama tikimybė, kad i -ojo paciento širdies vainikinių arterijų susiaurėjimas yra hemodinamiškai reikšmingas, įvertis ($\hat{p}_i = P(x_i^{(0)} = 1)$), kai paciento duomenų vektorius yra $\vec{x}_i = (x^{(2)}, x^{(13)}, x^{(16)}, \sqrt{x^{(18)}}, \ln(x^{(19)}), \ln(x^{(20)}), \ln(x^{(21)}), \ln(x^{(22)}), \ln(x^{(23)}), x^{(24)}, x^{(25)}, x^{(26)}, x^{(27)}, x^{(29)}, x^{(31)})$. Taikant modelį pacientą galima priskirti vienai iš tiriamų grupių. Jei $P(x_i^{(0)} = 1 | \vec{x}_i) > 0,5$, tai prognozuojame, kad $x_i^{(0)}$ reikšmė yra 1 ir pacientą priskiriame pacientų grupei, kurių vainikinių arterijų stenozė hemodinamiškai reikšminga. Priešingu atveju, t.y. kai $P(x_i^{(0)} = 1 | \vec{x}_i) < 0,5$, tai pacientą priskiriame grupei pacientų, kurių vainikinių arterijų stenozė hemodinamiškai nereikšminga. Jei atsitiktų taip, kad $P(x_i^{(0)} = 1 | \vec{x}_i) = 0,5$, tai pacientą galime priskirti tiek vienai, tiek kitai grupei.

Sudaryto logistinės regresijos modelio tinkamumą vainikinių arterijų susiaurėjimo hemodinamiškam reikšmingumui prognozuoti galima patikrinti keliais būdais. Pirmiausiai taikome Hosmerio-Lemešou kriterijų kai pasirinktas reikšmingumo lygmuo $\alpha = 0,05$. Hosmerio-Lemešou statistikos skirstinys yra χ^2 skirstinys [31]. Gauta statistikos reikšmė lygi 8,427, o p reikšmė – 0,393. Kadangi $p > \alpha$, todėl galima teigti, kad sudarytas logistinės regresijos modelis su duomenimis suderintas.

Norint skaitiškai įvertinti, ar nepriklausomų kintamųjų ir priklausomo kategorinio kintamojo priklausomybė yra didelė, skaičiuojami apibrėžtumo koeficientai [9, 11]. Statistinės analizės sistemos SAS procedūra LOGISTIC, kuri naudojama sudarant logistinės regresijos modelį, pateikia dviejų apibrėžtumo koeficientų reikšmes: Kokso-Snelo ir Nagelkerkė koeficientus. Kokso-Snelo apibrėžtumo koeficientas apibrėžiamas taip:

$$r_{CS}^2 = 1 - \left(\frac{L(\tilde{a}, 0)}{L(\hat{a}, \hat{b})} \right)^{2/n}; \quad (2.7)$$

čia $L(\hat{a}, \hat{b})$ yra didžiausiojo tikėtimumo funkcijos maksimumas, kai modelyje yra visi kintamieji, $L(\tilde{a}, 0)$ – didžiausiojo tikėtimumo funkcijos maksimumas, kai modelyje yra tik konstanta, n – stebėjimų skaičius. Nagelkerkė apibrėžtumo koeficientas apskaičiuojamas pagal formulę:

$$r_N^2 = \frac{r_{CS}^2}{1 - (L(\tilde{a}, 0))^{2/n}} \quad (2.8)$$

Dar vieno logistinės regresijos analizėje naudojamo apibrėžtumo koeficiento reikšmė gali būti taip pat lengvai apskaičiuojama, naudojantis LOGISTIC procedūros pateikiamais rezultatais. Šis koeficientas vadinasi Makfadeno apibrėžtumo koeficientu, kuris apskaičiuojamas taip:

$$r_M^2 = 1 - \frac{\ln L(\tilde{a}, \hat{b})}{\ln L(\hat{a}, 0)} \quad (2.9)$$

Visiems koeficientams galioja ta pati taisyklė: kuo koeficientas didesnis, tuo geriau logistinė regresija suderinta su duomenimis. Sudarytam modeliui apskaičiuoti apibrėžtumo koeficientai pateikti 2.5 lentelėje. Kaip matyti lentelėje, šių koeficientų reikšmės nėra didelės, todėl galima teigti, kad nagrinėjamo kategorinio kintamojo ir nepriklausomų kintamųjų priklausomybė nėra didelė.

2.5 lentelė
Logistinės regresijos modelio apibrėžtumo koeficientai

Apibr žtumo koeficientas	Koeficiento reikšm
Kokso-Snelo apibr žtumo koeficientas	0,2196
Nagelkerk s apibr žtumo koeficientas	0,2959
Makfadeno apibr žtumo koeficientas	0,1829

χ^2 suderinamumo kriterijus – tai dar vienas būdas modelio tinkamumui įvertinti. Taikant kriterijų patikrinama hipotezė, kad visi lygties koeficientai lygūs nuliui, kai pasirinktas reikšmingumo lygmuo $\alpha = 0,05$:

$$\begin{cases} H_0 : b_2 = b_{13} = b_{16} = b_{18} = b_{19} = b_{20} = b_{21} = b_{22} = b_{23} = b_{24} = b_{25} = b_{26} = b_{27} = b_{29} = b_{31} = 0, \\ H_1 : bent vienas b_j \neq 0 (j = 2, 13, 16, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 29, 31). \end{cases} \quad (2.10)$$

(2.6) lygtimi aprašytam modeliui χ^2 suderinamumo kriterijaus statistika lygi 33,889, o p reikšmė yra 0,0035. Čia $p < 0.05$, vadinasi hipotezė nėra priimtina. Naudojant Voldo kriterijų, tikrinamos hipotezės apie kiekvieno koeficiento lygybę nuliui su pasirinktu reikšmingumo lygmeniu 0,05:

$$\begin{cases} H_0 : b_j = 0 \\ H_1 : b_j \neq 0, (j = 2, 13, 16, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 29, 31). \end{cases} \quad (2.11)$$

Hipotezių tikrinimo rezultatai pateikti 2.6 lentelėje.

2.6 lentelė
Hipotezių apie logistinės regresijos
lygties koeficientų lygybę nuliui
tikrinimo rezultatai

Kintamasis	Voldo statistika	<i>p</i> reikšm
<i>Konstanta</i>	1,4402	0,2301
$X^{(2)}$	10,4924	0,0012
$X^{(13)}$	10,3402	0,0013
$X^{(16)}$	4,0823	0,0433
$\sqrt{X^{(18)}}$	6,6748	0,0098
$\ln(X^{(19)})$	6,8371	0,0089
$\ln(X^{(20)})$	2,9216	0,0874
$\ln(X^{(21)})$	12,6656	0,0004
$\ln(X^{(22)})$	2,0518	0,1520
$\ln(X^{(23)})$	2,0808	0,1492
$X^{(24)}$	9,1575	0,0025
$X^{(25)}$	1,4406	0,2300
$X^{(26)}$	1,4414	0,2299
$X^{(27)}$	3,7639	0,0524
$X^{(29)}$	1,7696	0,1834
$X^{(31)}$	2,1460	0,1429

Analizuojant šią lentelę, galima pastebėti, kad hipotezės apie kai kurių koeficientų lygybę nuliui neatmestinos ($p > 0,05$). Galima teigti, kad kintamieji, kurių koeficientams hipotezės nebuvo atmestos, prognozavimui nėra svarbus, tačiau palyginus klasifikavimo lenteles, galime įsitikinti, kad taip nėra. 2.7 lentelėje pateikti klasifikavimo rezultatai, kai modelyje yra visi kintamieji, o 2.8 lentelėje – kai iš modelio pašalinti kintamieji, kuriems hipotezės apie jų lygybę nuliui nebuvo atmestos.

2.7 lentelė
Pacientų klasifikavimo rezultatai, kai modelyje
naudojami visi kintamieji


Bendras teisingo klasifikavimo procentas	Jautrumas	Specifiškumas
65,6%	78,4%	52,9%

2.8 lentelė


Pacientų klasifikavimo rezultatai, kai modelyje naudojami kintamieji, kuriems hipotezės apie jų lygybę nuliui nebuvo priimtinos

Bendras teisingo klasifikavimo procentas	Jautrumas	Specifiškumas
55,1%	79,4%	30,9%

Šį faktą patvirtina ir ROC kreivės analizė. Tikimybė, kad vieno paciento, kurio vainikinių arterijų susiaurėjimas hemodinamiškai reikšmingas, ir paciento, kurio arterijų susiaurėjimas hemodinamiškai nereikšmingas, prognozės yra teisingos, yra lygi srities esančios po ROC kreive plotui. Pirmuoju atveju srities plotas po ROC kreive yra lygus 0,763 (2.6 pav.), o antruoju atveju, t.y. kai iš modelio pašalinami kintamieji, kuriems hipotezės apie jų lygybę nuliui nebuvo atmetos, plotas lygus 0,668 (2.7 pav.).



2.6 pav. Modelio, kuriame naudojami visi kintamieji, ROC kreivė



2.7 pav. Modelio, kuriame naudojami kintamieji, kuriems hipotezės apie jų lygybę nuliui nebuvo priimtinos, ROC kreivė

Sudarant logistinės regresijos modelį, skirtą moterų vainikinių širdies arterijų susiaurėjimui prognozuoti, buvo taip pat atliekamos kai kurių parametru transformacijos, t.y. parametrai buvo normalizuojami: $\ln(X^{(3)})$, $\sqrt{X^{(6)}}$, $\ln(X^{(11)})$, $\ln(X^{(14)})$, $\ln(X^{(15)})$, $\ln(X^{(17)})$, $\ln(X^{(18)})$, $\ln(X^{(19)})$, $\ln(X^{(20)})$, $\ln(X^{(21)})$, $\ln(X^{(22)})$, $\ln(X^{(23)})$, $\ln(X^{(24)})$, $\ln(X^{(27)})$, $\sqrt{X^{(31)}}$. Analogiškai, kaip ir sudarant modelį, skirtą vyrų vainikinių arterijų susiaurėjimų prognozavimui, informatyvių elektrokardiografinių parametru rinkinių buvo ieškoma naudojantis pažingsniniu metodu su įvairiais įrašymo ir išbraukimo lygmenimis. 2.9 lentelėje pateikiami gauti elektrokardiografinių parametru rinkiniai bei teisingo prognozavimo rodikliai (bendras teisingo klasifikavimo procentas, jautrumas, specifiškumas), apskaičiuoti įrašius šiuos parametru rinkinius į logistinės regresijos lygtį.

Pagal gautus pažingsninio metodo taikymo rezultatus, moterų vainikinių širdies arterijų susiaurėjimo prognozavimo logistinės regresijos modelio sudarymui pasirinkti kintamieji: $\sqrt{X^{(6)}}$, $X^{(7)}$, $X^{(10)}$, $X^{(12)}$, $\ln(X^{(21)})$, $\ln(X^{(22)})$, $X^{(28)}$, $X^{(29)}$, $X^{(30)}$.

2.9 lentelė

Pažingsninio metodo taikymo rezultatai

Parametr rinkinys	rašymo lygmuo	išbraukimo lygmuo	Klasifikavimo rezultatas		
			Bendras teisingo klasifikavimo procentas	Jautrumas	Specifiškumas
$X^{(7)}, X^{(10)}, \ln(X^{(21)}), \ln(X^{(22)}), X^{(28)}$	0,1	0,15	67,1%	53,3%	77,5%
$\sqrt{X^{(6)}}, X^{(7)}, X^{(10)}, X^{(12)}, \ln(X^{(21)}), \ln(X^{(22)}), X^{(28)}, X^{(30)}$	0,2	0,25	72,9%	60%	82,5%
$\sqrt{X^{(6)}}, X^{(7)}, X^{(10)}, X^{(12)}, \ln(X^{(21)}), \ln(X^{(22)}), X^{(28)}, X^{(29)}, X^{(30)}$	0,3	0,35	74,3%	63,3%	82,5%
$X^{(5)}, \sqrt{X^{(6)}}, X^{(7)}, X^{(10)}, X^{(12)}, \ln(X^{(21)}), \ln(X^{(22)}), X^{(28)}, X^{(29)}, X^{(30)}$	0,5	0,55	70%	56,7%	80%

2.10 lentelėje pateikiami koeficientų prie kintamųjų taškiniai įverčiai apskaičiuoti didžiausio tikėtimumo metodu.

2.10 lentelė

Logistinės regresijos lygties koeficientų taškiniai įverčiai

Kintamasis	Taškinis vertis
<i>Konstanta</i>	-7,6767
$\sqrt{X^{(6)}}$	0,5492
$X^{(7)}$	0,1256
$X^{(10)}$	-0,1391
$X^{(12)}$	-0,0859
$\ln(X^{(21)})$	-0,9512
$\ln(X^{(22)})$	1,2071
$X^{(28)}$	-0,0358
$X^{(29)}$	0,0125
$X^{(30)}$	-0,00805

Gauti logistinės regresijos lygties koeficientų taškiniai įverčiai naudojami sudarant logistinės regresijos lygtį, skirtą moterų vainikinių širdies arterijų susiaurėjimo reikšmingumui prognozuoti:

$$\hat{p}_i = \frac{\exp\left\{\hat{z}\left(\vec{x}_i\right)\right\}}{1 + \exp\left\{\hat{z}\left(\vec{x}_i\right)\right\}}, \quad (2.12)$$

$$\begin{aligned} \text{čia } \hat{z}\left(\vec{x}_i\right) = & -7,6767 + 0,5492\sqrt{x_i^{(6)}} + 0,1256x_i^{(7)} - 0,1391x_i^{(10)} - 0,0859x_i^{(12)} - 0,9512\ln(x_i^{(21)}) + \\ & + 1,2071\ln(x_i^{(22)}) - 0,0358x_i^{(28)} + 0,0125x_i^{(29)} - 0,00805x_i^{(30)}, \end{aligned}$$

$\hat{p}_i = P(x_i^{(0)} = 1)$, i – pacientės numeris.

Taikant sudarytą modelį apskaičiuojama tikimybė, kad i -osios pacientės širdies vainikinių arterijų susiaurėjimas yra hemodinamiškai reikšmingas, įvertis ($\hat{p}_i = P(x_i^{(0)} = 1)$), kai pacientės duomenų vektorius yra $\vec{x}_i = (\sqrt{x_i^{(6)}}, x_i^{(7)}, x_i^{(10)}, x_i^{(12)}, \ln(x_i^{(21)}), \ln(x_i^{(22)}), x_i^{(28)}, x_i^{(29)}, x_i^{(30)})$. Taikant modelį pacientę galima priskirti vienai iš tiriamų grupių. Klasifikavimo procedūra yra analogiška aprašytai procedūrai, taikomai tiriant vyrų populiaciją.

Sudarius modelį, tikrinamas jo tinkamumas vainikinių arterijų hemodinamiškai reikšmingam susiaurėjimui prognozuoti. Pirmiausia taikomas Hosmerio-Lemešou kriterijus su pasirinktu reikšmingumo lygmeniu $\alpha = 0,05$. Gauta kriterijaus statistikos reikšmė lygi 12,464, o p reikšmė lygi 0,132. Pagal apskaičiuotą kriterijaus p reikšmę sprendžiamą apie sudaryto modelio suderinamumą su duomenimis. Šiuo atveju $p > \alpha$, todėl gautas rezultatas patvirtina, kad modelis su duomenimis suderintas.

Nepriklausomų kintamųjų ir priklausomo kategorinio kintamojo priklausomybei įvertinti skaičiuojami apibrėžtumo koeficientai: Kokso-Snelo, Nagelkerk s ir Makfadeno apibrėžtumo koeficientas. Pastarj koeficient išraiškos užrašytos (2.7), (2.8) ir (2.9) formulėse. Sudarytam logistinės regresijos modeliui šie koeficientai pateikiami 2.11 lentelėje. Nors Hosmerio-Lemešou kriterijus patvirtina, kad modelis su duomenimis suderintas, tačiau determinacijos koeficientų reikšmės nėra didelės, todėl galiam teigti, kad nagrinėjamo kategorinio kintamojo ir nepriklausomų kintamųjų priklausomybė nėra didelė.

2.11 lentelė
Logistinės regresijos modelio apibrėžtumo koeficientai

Apibrėžtumo koeficientas	Koeficiento reikšmė
Kokso-Snelo apibrėžtumo koeficientas	0,3538
Nagelkerk s apibrėžtumo koeficientas	0,4749
Makfadeno apibrėžtumo koeficientas	0,3196

Modelio tinkamumui įvertinti naudojame ir χ^2 suderinamumo kriterijų. Šiuo atveju patikrinama hipotezė, kad visi lygties koeficientai lygūs nuliui, kai pasirinktas reikšmingumo lygmuo 0,05:

$$\begin{cases} H_0 : b_6 = b_7 = b_{10} = b_{12} = b_{21} = b_{22} = b_{28} = b_{29} = b_{30} = 0, \\ H_1 : \text{bent vienas } b_j \neq 0 (j = 6, 7, 10, 12, 21, 22, 28, 29, 30). \end{cases} \quad (2.13)$$

Tikrinant hipotezę apskaičiuota kriterijaus statistikos reikšmė, kuri lygi 21,4053, o p reikšmė lygi 0,0037. Kadangi $p < 0.05$, tai tikrinta hipotezė nėra priimtina ir galima daryti išvadą, kad bent vienas nepriklausomas kintamasis modelyje reikalingas. Naudojant Voldo kriterijų, tikrinamos hipotezės apie konkrečių koeficientų lygybę nuliui:

$$\begin{cases} H_0 : b_j = 0 \\ H_1 : b_j \neq 0, (j = 6, 7, 10, 12, 21, 22, 28, 29, 30). \end{cases} \quad (2.14)$$

Hipotezių tikrinimo rezultatai pateikti 2.12 lentelėje.

2.12 lentelė
Hipotezių apie logistinės regresijos
lygties koeficientų lygybę nuliui
tikrinimo rezultatai

Kintamasis	Voldo statistika	p reikšmė
Konstanta	0,6815	0,4091
$\sqrt{X^{(6)}}$	2,0014	0,1572
$X^{(7)}$	8,7076	0,0032
$X^{(10)}$	10,7799	0,0010
$X^{(12)}$	3,5628	0,0591
$\ln(X^{(21)})$	3,5711	0,0588
$\ln(X^{(22)})$	7,2304	0,0072
$X^{(28)}$	5,0900	0,0241
$X^{(29)}$	1,2975	0,2547
$X^{(30)}$	1,9343	0,1643

Pagal hipotezių tikrinimo rezultatus sudarytame modelyje tik keturi kintamieji ($X^{(7)}$, $X^{(10)}$, $\ln(X^{(22)})$, $X^{(28)}$) yra svarbūs prognozavimui, kadangi hipotezės apie koeficientų prie šių kintamųjų lygybę nuliui buvo atmestos. Norint patikrinti šį teiginį sudaromas naujas modelis, kuriame yra tik šie keturi elektrokardiografiniai parametrai. Tačiau palyginus klasifikavimo lenteles, galime įsitikinti, kad vis dėlto geriau prognozuoja pirmasis modelis, kuriame yra visi kintamieji. 2.13 lentelėje pateikti klasifikavimo rezultatai, kai modelyje yra visi kintamieji, o 2.14 lentelėje – kai į modelį įrašyti tik keturi kintamieji.


2.13 lentelė
Pacienčių klasifikavimo rezultatai, kai modelyje
naudojami visi kintamieji

Bendras teisingo klasifikavimo procentas	Jautrumas	Specifiškumas
72,9%	63,3%	82,5%


2.14 lentelė
Pacientų klasifikavimo rezultatai, kai modelyje
naudojami kintamieji, kuriems hipotezės apie jų
lygybę nuliui nebuvo priimtinos

Bendras teisingo klasifikavimo procentas	Jautrumas	Specifiškumas
67,1%	56,7%	77,5%

Jei palyginsime sričių plotus po ROC kreive, kurios nubraižytos naudojant abu šiuos modelius, pastebėsime, kad jie gana ženkliai skiriasi. Taikant pirmąjį modelį plotas lygus 0,872 (2.8 pav.), o taikant antrąjį, kuriame yra tik keturi kintamieji – 0,796 (2.9 pav.).



2.8 pav. Modelio, kuriame naudojami visi kintamieji, ROC kreivė



2.9 pav. Modelio, kuriame naudojami kintamieji, kuriems hipotezės apie jų lygybę nuliui nebuvo priimtinos, ROC kreivė

2.2.3. VAINIKINIŲ ŠIRDIES ARTERIJŲ SUSIAURĖJIMŲ ĮVERTINIMO PAGAL EKG IR VKG PARAMETRUS PARAMETRINĖS DISKRIMINANTINĖS ANALIZĖS MODELIS

Diskriminantinėje analizėje pagal tolydžiųjų kintamųjų reikšmes sprendžiama apie objekto priklausomybę vienai iš keleto grupių. Diskriminantinėje analizėje iš anksto žinomas grupių skaičius bei informacija apie tiriamų objektų požymių reikšmes ir priklausomybę vienai ar kitai grupei. Yra du diskriminantinės analizės tipai: parametrinė ir neparametrinė diskriminantinė analizė. Parametrinė diskriminantinė analizė taikoma tuomet, kai tiriamų diskriminavimo kintamųjų daugiamačiai skirstiniai yra normalieji. Kai normalumo sąlyga nėra tenkinama, tuomet galima naudoti neparametrinę diskriminantinę analizę. Pirmiausia aptarsime parametrinės diskriminantinės analizės modelius.

Sudarant modelį, skirtą vyrų vainikinių širdies arterijų susiaurėjimų prognozavimui, buvo tikrinamos parametrinės diskriminantinės analizės prielaidos. Tiriamos dvi pacientų grupės: vienoje grupėje yra pacientai, kurių vainikinių širdies arterijų susiaurėjimas hemodinamiškai nereikšmingas, kitoje – kurių vainikinių arterijų susiaurėjimas hemodinamiškai reikšmingas, taigi grupių skaičius yra baigtinis ir lygus 2. Grupės yra nepriklausomos ir neturi bendrų objektų. Diskriminantinėje analizėje

yra reikalaujama, kad nė vienas diskriminavimo kintamasis, šiuo atveju elektrokardiografiniai ir klinikiniai pacientų parametrai, nebūtų kitų kintamųjų tiesinė daugdara. Dėl šios priežasties iš analizės buvo pašalinti parametrai $X^{(11)}$, $X^{(12)}$, $X^{(17)}$. Taip pat yra reikalaujama, kad diskriminavimo kintamieji būtų matuojami pagal intervalų skalę. Dėl šio reikalavimo modelyje naudojamas tik vienas klinikinis parametras – paciento amžius. Paskutinioji modelio prielaida – diskriminavimo kintamųjų daugiamačiai skirstiniai atskirose grupėse turi būtų daugiamačiai normalieji.

Atskirai aptarsime kaip buvo tikrinama, ar diskriminavimo kintamųjų daugiamačiai skirstiniai atskirose grupėse normalieji. Visų pirma naudojantis viena iš daugiamačio normaliojo skirstinio savybių patikrinta, ar vienmačiai parametrai skirstiniai yra normalieji:

$$\begin{cases} H_0 : X^{(i)} \sim N(\mu_i, \sigma_i^2); \\ H_1 : X^{(i)} \neq N(\mu_i, \sigma_i^2). \end{cases} \quad (2.15)$$

Suderinamumo hipotezių tikrinimui naudojamas Šapiro-Vilkoksono kriterijus, kai pasirinktas reikšmingumo lygmuo $\alpha = 0,05$. Suderinamumo hipotezės patikrintos naudojantis SAS sistemos procedūra UNIVARIATE. Buvo analizuojamos pacientų grupės atskirai, t.y. patikrintos pacientų, kurių arterijų susiaurėjimas hemodinamiškai nereikšmingas, ir pacientų, kurių vainikinių širdies arterijų stenozė hemodinamiškai reikšminga, elektrokardiografinių ir klinikinio parametrai suderinamumo hipotezės. Šioms grupėms identifikuoti buvo naudojamas kintamasis $X^{(0)}$. Kaip pavyzdys 2.15 lentelėje pateikti $X^{(3)}$ parametro hipotezių tikrinimo rezultatai. Likusieji rezultatai yra pateikti 4 priede.

2.15 lentelė
Vienmačių skirstinių suderinamumo hipotezių
tikrinimo rezultatai

$X^{(0)}$	Statistikos reikšm	p reikšm
0	0.9776	0.2595
1	0.9523	0.0014

Kadangi $p < 0,05$ kai $X^{(0)} = 1$, todėl hipotezė, kad parametro $X^{(3)}$ skirstinys abiejose grupėse yra normalusis nėra priimtina. Ši hipotezė neatmetama tik parametrams $X^{(2)}$, $X^{(13)}$, $X^{(15)}$, $X^{(16)}$, $X^{(30)}$ todėl likusiųjų elektrokardiografinių parametrai reikšmės buvo normalizuojamos. Taikoma keletas normalizavimo būdų: $\ln(X^{(i)})$, $\sqrt{X^{(i)}}$, $-\frac{1}{X^{(i)}}$, $-\frac{1}{(X^{(i)})^2}$, $-\frac{1}{(X^{(i)})^3}$. Normalizavus parametrus vėl patikrintos suderinamumo hipotezės. 2.16 lentelėje pateikiamas $\ln(X^{(3)})$ parametro suderinamumo hipotezių tikrinimo rezultatai, o likusieji rezultatai yra pateikiami 4 priede.

2.16 lentelė

**Vienmačių skirstinių suderinamumo hipotezių
tikrinimo rezultatai**

$X^{(0)}$	Statistikos reikšm	p reikšm
0	0.9737	0.1595
1	0.9905	0.7242

Patikrinus suderinamumo hipotezes apie parametrų vienmačių skirstinių normalumą, patikrinta hipotezė apie daugiamačio skirstinio, sudaryto iš šių parametrų normalumą. Į daugiamatį skirstinį buvo įtraukti šie parametrai: $X^{(2)}$, $\ln(X^{(3)})$, $\ln(X^{(4)})$, $\sqrt{X^{(5)}}$, $\sqrt{X^{(6)}}$, $-\frac{1}{[X^{(9)}]^2}$, $X^{(13)}$, $-\frac{1}{[X^{(14)}]^2}$, $X^{(15)}$, $X^{(16)}$, $\sqrt{X^{(18)}}$, $\ln(X^{(19)})$, $\ln(X^{(20)})$, $\ln(X^{(21)})$, $\ln(X^{(22)})$, $\ln(X^{(23)})$, $\ln(X^{(27)})$, $X^{(30)}$. Tokios parametrų transformacijos pasirinktos todėl, kad jas pritaikius, gautas geriausias kintamųjų reikšmių skirstinių suderinamumas su normaliuoju skirstiniu. Parametrai $X^{(7)}$, $X^{(8)}$, $X^{(10)}$, $X^{(24)}$, $X^{(25)}$, $X^{(26)}$, $X^{(28)}$, $X^{(29)}$, $X^{(31)}$ į daugiamatį skirstinį nebuvo įtraukti, kadangi atlikus normalizavimą hipotezės apie jų vienmačių skirstinių normalumą nebuvo priimtinos. Daugiamačio skirstinio normalumui tikrinti naudojami Mardia daugiamačių asimetrijos koeficiento ir eksceso kriterijai. Pateikiame hipotezių tikrinimo rezultatus:

2.17 lentelė

Daugiamačių skirstinių suderinamumo hipotezių tikrinimo rezultatai

$X^{(0)}$	Statistika	Statistikos reikšm	p reikšm
0	Asimetrijos	2616,10	< 0,0001
	Eksceso	6,37	< 0,0001
1	Asimetrijos	2019,91	< 0,0001
	Eksceso	1,84	0,0659

Remiantis lentelėje pateiktomis p reikšmėmis galima teigti, kad hipotezės apie daugiamačio skirstinio normalumą abiejose grupėse nėra priimtinos. Daugiamačių skirstinių suderinamumo hipotezės abiejose grupėse nebuvo atmestinos tik tuomet, kai iš daugiamačių skirstinių buvo išbraukti parametrai $X^{(4)}$, $X^{(5)}$, $X^{(14)}$, $X^{(15)}$, $X^{(16)}$, $X^{(18)}$, $X^{(20)}$, $X^{(22)}$. Hipotezių tikrinimo rezultatai pateikiami 2.18 lentelėje.

2.18 lentelė

Daugiamačių skirstinių suderinamumo hipotezių tikrinimo rezultatai

$X^{(0)}$	Statistika	Statistikos reikšm	p reikšm
0	Asimetrijos	234,348	0,242
	Eksceso	-1,186	0,236
1	Asimetrijos	224,779	0,398
	Eksceso	-0,969	0,333

Išpildžius visas diskriminantinės analizės taikymo sąlygas, sudarant modelį buvo naudojamas parametų rinkinys, kuriame yra vienas klinikinis parametras – paciento amžius ir dešimt elektrokardiografinių parametų: $X^{(2)}$, $X^{(3)}$, $X^{(6)}$, $X^{(9)}$, $X^{(13)}$, $X^{(19)}$, $X^{(21)}$, $X^{(23)}$, $X^{(27)}$, $X^{(30)}$. Informatyvių diskriminavimo kintamųjų buvo ieškoma naudojant pažingsninį metodą su įvairiais įrašymo ir išbraukimo lygmenimis. Šiuo metodu atrinkus parametų rinkinius, buvo sudarytos klasifikavimo funkcijos. Ar parametų rinkinys yra informatyvus vyrų vainikinių širdies arterijų susiaurėjimų prognozavimui buvo sprendžiama pagal klaidingo klasifikavimo tikimybių įverčius, kurie apskaičiuojami naudojantis Lachenbruch procedūra. 2.19 lentelėje pateikiami pažingsninio metodo taikymo rezultatai.

2.19 lentelė

Pažingsninio metodo taikymo rezultatai

Parametr rinkinys	rašymo lygmuo	Išbraukimo lygmuo	Klasifikavimo rodikliai		
			Bendras teisingo klasifikavimo procentas	Jautrumas	Specifiškumas
$X^{(2)}$, $X^{(13)}$, $\ln(X^{(19)})$, $\ln(X^{(21)})$	0,3	0,35	58,14%	61,86%	54,41%
$X^{(2)}$, $X^{(13)}$, $\ln(X^{(19)})$, $\ln(X^{(21)})$, $\ln(X^{(27)})$, $X^{(30)}$	0,5	0,55	58,64%	62,86%	54,41%
$X^{(2)}$, $X^{(13)}$, $\ln(X^{(19)})$, $\ln(X^{(21)})$, $\ln(X^{(23)})$, $\ln(X^{(27)})$, $X^{(30)}$	0,7	0,75	59,39%	62,89%	55,88%

Naudojant šiuos parametų rinkinius klasifikavimo kokybė panaši. Todėl remiantis medikų rekomendacijomis paskutiniajame parametų rinkinyje buvo pašalintas parametras $X^{(13)}$ ir naudojant tokį parametų rinkinį klasifikavimo patikimumas padidėjo. Šiuo atveju bendras teisingo klasifikavimo procentas 61,81%, jautrumas 69,95% ir specifiškumas 57,35%. Remiantis gautais rezultatais parametrinės diskriminantinės analizės modelis, skirtas vyrų vainikinių arterijų stenozei prognozuoti, buvo sudarytas naudojant diskriminavimo kintamuosius: $X^{(2)}$, $\ln X^{(19)}$, $X^{(21)}$, $\ln X^{(23)}$, $\ln X^{(27)}$, $X^{(30)}$.

Parametrinės diskriminantinės analizės modelyje pacientų priskyrimas vienai iš grupių, o tuo pačiu ir jų vainikinių arterijų stenozės prognozavimas gali būti atliekamas naudojantis arba tiesinėmis, arba kvadratinėmis diskriminavimo funkcijomis. Kurį funkciją pasirinkti sprendžiama pagal diskriminavimo kintamųjų kovariacijų matricas atskirose grupėse, todėl buvo tikrinama hipotezė apie kovariacijų matricų homogeniškumą (lygybę) kai pasirinktas reikšmingumo lygmuo $\alpha = 0,01$. Hipotezės tikrinimui apskaičiuota χ^2 statistika, kurios reikšmė 13,92, o p reikšmė 0,87. Kadangi hipotezė, kad kovariacijų matricos atskirose grupėse yra homogeniškos nebuvo atmestina, todėl buvo sudarytos tiesinės diskriminavimo funkcijos. Matricinėje formoje tiesinė diskriminantinė funkcija užrašoma:

$$d_i\left(\begin{matrix} \rightarrow \\ x \end{matrix}\right) = -\frac{1}{2}\vec{\mu}_i \Sigma^{-1}\left(\begin{matrix} \rightarrow \\ \mu_i \end{matrix}\right)^T + \vec{\mu}_i \Sigma^{-1}\left(\begin{matrix} \rightarrow \\ x \end{matrix}\right)^T + \ln p_i, \quad (2.16)$$

čia i – grupės numeris ($i = 0,1$), $\vec{\mu}_i$ – diskriminavimo kintamųjų vidurkių vektorius, Σ – diskriminavimo kintamųjų jungtinė kovariacijų matrica, \vec{x} – paciento duomenų vektorius $\vec{x} = (x^{(2)}, x^{(19)}, x^{(21)}, x^{(23)}, x^{(27)}, x^{(30)})$, p_i – apriorinė tikimybė, kad pacientas, kurio elektrokardiografiniai parametrai aprašomi vektoriumi \vec{x} , priklauso grupei i . Mūsų atveju $p_0 = p_1 = \frac{1}{2}$.

Naudojantis SAS sistemos procedūra DISCRIM buvo apskaičiuoti grupių vektorių vidurkių įverčiai, kovariacijų matricos įvertis ir sudarytos tiesinės diskriminavimo funkcijos:

$$d_0\left(\begin{matrix} \rightarrow \\ x \end{matrix}\right) = -47,7319 + 0,7332x^{(2)} - 5,3792x^{(19)} + 6,6116x^{(21)} + 2,8259x^{(23)} + 2,3174x^{(27)} + 0,065x^{(30)}$$

$$d_1\left(\begin{matrix} \rightarrow \\ x \end{matrix}\right) = -52,0791 + 0,784x^{(2)} - 5,4663x^{(19)} + 7,0093x^{(21)} + 2,5373x^{(23)} + 1,9634x^{(27)} + 0,0674x^{(30)}$$

(2.17)

Paciento priskyrimas vienai iš grupių, o tuo pačiu ir jo vainikinių širdies arterijų susiaurėjimų prognozavimas atliekamas tokiu būdu:

1. Į diskriminavimo funkcijas įrašius paciento duomenis, apskaičiuojamos funkcijų reikšmės.
2. Pacientas priskiriamas tai grupei, kurios apskaičiuota funkcijos reikšmė yra didesnė.

Diskriminantinės analizės modelio klasifikavimo kokybę nusako klasifikavimo lentelė bei klaidingo klasifikavimo tikimybių įverčiai. Klaidingo klasifikavimo tikimybių įverčiai apskaičiuojami taip [11]:

$$\hat{P}(G_0|G_1) = \frac{n_{01}}{n_1}, \quad \hat{P}(G_1|G_0) = \frac{n_{10}}{n_0}, \quad (2.18)$$

čia $\hat{P}(G_i|G_j)$ yra tikimybės priskirti objektą grupei G_i , kai jis priklauso grupei G_j , i vertis, n_{ij} – objektų, priklausančių j -ajai grupei ir priskirtų i -ajai grupei skaičius, n_j – objektų, priklausančių j -ajai grupei skaičius.

Naudojantis sudarytomis klasifikavimo funkcijomis pacientai buvo suklasifikuoti į grupes pagal jų vainikinių širdies arterijų stenozės laipsnį. Grupei, žymimai skaičiumi 0, priskirti pacientai, kurių vainikinių arterijų susiaurėjimai hemodinamiškai nereikšmingi, grupei, žymimai skaičiumi 1, priskirti pacientai, kurių vainikinių arterijų susiaurėjimai hemodinamiškai reikšmingi. Klasifikavimo rezultatai pateikti 2.20 lentelėje, o klaidingo klasifikavimo tikimybių įverčiai – 2.21 lentelėje.

2.20 lentelė

Klasifikavimo lentelė

Pacientai priklausantys grup ms	Pacientai priskirti grup ms		Viso
	0	1	
0	43 63,24%	25 36,76%	68 100%
1	29 29,90%	68 70,10%	97 100%

2.21 lentelė

Klaidingo klasifikavimo tikimybių įverčiai

	Grup		Bendras
	0	1	
vertis	0,3676	0,299	0,3333

Iš pastarųjų lentelių matyti, kad modelio klasifikavimo jautrumas yra 70,1%, o specifiškumas 63,24%. Tai yra „mokomosios imties“ klasifikavimo rezultatas, todėl kyla klausimas, kokie klasifikavimo rezultatai būtų gauti klasifikuojant „testinės imties“ duomenis, naudojant tas pačias diskriminavimo funkcijas. Vietoje „testinės imties“ duomenų klasifikavimo gali būti naudojama Lachenbrucho procedūra ir pagal jos rezultatus gali būti sprendžiama apie diskriminavimo funkcijų klasifikavimo kokybę [11]. Šios procedūros rezultatai taip pat pateikiami klaidingo klasifikavimo tikimybių įverčiais (2.22 lentelė) bei klasifikacine lentele (2.23 lentelė).

2.22 lentelė

Lachenbrucho procedūros klaidingo klasifikavimo tikimybių įverčiai

	Grup		Bendras
	0	1	
vertis	0,4265	0,3505	0,3885

2.23 lentelė
Lachenbruchio procedūros lentelė

Pacientai priklausantys grup ms	Pacientai priskirti grup ms		Viso
	0	1	
0	39 57,35%	29 42,65%	68 100%
1	34 35,05%	63 64,95%	97 100%

Lygindami abi klasifikavimo lenteles, matome, kad pacientų klasifikavimo į atskiras grupes rezultatai suprastėjo palyginti nedaug – nuo 63,24% iki 57,35% (jautrumas), nuo 70,1% iki 64,95% (specifiškumas) ir nuo 67,27 iki 61,82 (bendras teisingo klasifikavimo procentas). Naudojantis šiais rezultatais galima daryti išvadą, kad diskriminavimo kintamųjų pertekliaus nėra.

Sudarant parametrinės diskriminantinės analizės modelį, skirtą moterų vainikinių arterijų susiaurėjimams prognozuoti, analogiškai kaip ir vyrų atveju, buvo tikrinamos modelio taikymo sąlygos. Buvo tiriamos dvi moterų grupės, kurias identifikuoja dvireikšmis kintamasis $X^{(0)}$, taigi, grupių skaičius yra baigtinis ir lygus 2, jos nepriklausomos ir neturi bendrų objektų. Iš tyrimo pašalinti elektrokardiografiniai parametrai $X^{(11)}$, $X^{(12)}$, $X^{(17)}$ kadangi $X^{(11)} = X^{(7)} - X^{(8)}$, $X^{(12)} = X^{(9)} - X^{(10)}$ ir $X^{(17)} = X^{(15)} - X^{(16)}$. Į tyrimą įtrauktas ir vienas klinikinis parametras – amžius. Hipotezių tikrinimą apie daugiamačių skirstinių, sudarytų iš elektrokardiografinių ir klinikinio parametro, normalumą aptarsime atskirai. Iš pradžių patikrintos parametru vienmačių skirstinių atskirose grupėse suderinamumo hipotezės. Suderinamumo hipotezių tikrinimui naudojamas Šapiro-Vilk (Shapiro-Wilk) kriterijus su pasirinktu reikšmingumo lygmeniu 0,05. Kriterijus realizuotas naudojantis SAS sistemos procedūra UNIVARIATE. 2.24 lentelėje pateikiami $X^{(2)}$ parametro hipotezių tikrinimo rezultatai. Visi likusieji hipotezių tikrinimo rezultatai yra 4 priede.

2.24 lentelė
Vienmačių skirstinių suderinamumo hipotezių tikrinimo rezultatai

$X^{(0)}$	Statistikos reikšm	p reikšm
0	0,9664	0,2769
1	0,9791	0,8024

Šiuo atveju hipotezės apie parametro skirstinio normalumą nebuvo atmestinos, tačiau kai kuriems kintamiesiems šios hipotezės buvo atmestinos. Diskriminantiniai kintamieji, kuriems suderinamumo hipotezės nebuvo priimtinos, t.y. kintamieji $X^{(3)}$, $X^{(6)}$, $X^{(13)}$, $X^{(14)}$, $X^{(15)}$, $X^{(18)}$, $X^{(19)}$, $X^{(20)}$,

$X^{(21)}, X^{(22)}, X^{(23)}, X^{(24)}, X^{(27)}, X^{(28)}, X^{(29)}, X^{(31)}$ buvo normalizuojami. Kintamieji buvo normalizuojami naudojant transformacijas $\ln(X^{(i)}), \sqrt{X^{(i)}}, -\frac{1}{X^{(i)}}, -\frac{1}{(X^{(i)})^2}, -\frac{1}{(X^{(i)})^3}$. Buvo pasirinktos parametru transformacijos: $\ln(X^{(3)}), \sqrt{X^{(6)}}, \ln(X^{(13)}), \ln(X^{(14)}), \ln(X^{(15)}), \ln(X^{(18)}), \ln(X^{(19)}), \ln(X^{(20)}), \ln(X^{(21)}), \ln(X^{(22)}), \ln(X^{(23)}), \ln(X^{(24)}), \ln(X^{(27)}), \sqrt{X^{(31)}}$. Tokios parametru transformacijos pasirinktos todėl, kad jas pritaikius, gautas geriausias kintamųjų reikšmių skirstinių suderinamumas su normaliuoju skirstiniu. Tačiau kintamiesiems $X^{(28)}, X^{(29)}$ atlikus įvairias transformacijas, hipotezės apie jų vienmačių skirstinių normalumą nebuvo priimtinos, todėl į diskriminantinės analizės modelį jie nebuvo įtraukti. Jei daugiamačio skirstinio kintamųjų vienmačiai skirstiniai yra normalieji, tai yra išpildoma būtina sąlyga, kad ir daugiamačio skirstinys yra normalusis, bet ji nėra pakankama. Todėl dar reikia patikrinti hipotezę apie daugiamačio skirstinio normalumą. Šiai hipotezei tikrinti naudojami Mardia daugiamačių asimetrijos koeficiento ir eksceso kriterijai. Hipotezės apie daugiamačių skirstinių normalumą abiejose pacienčių grupėse nebuvo atmestinos tik tuomet, kai iš skirstinių pašalinti kintamieji $X^{(5)}, X^{(6)}, X^{(18)}, X^{(25)}, X^{(27)}, X^{(31)}$. Hipotezių tikrinimo rezultatai pateikti 2.25 lentelėje.

2.25 lentelė
Daugiamačių skirstinių suderinamumo hipotezių tikrinimo rezultatai

$X^{(i)}$	Statistika	Statistikos reikšm	p reikšm
0	Asimetrijos	1334,281	0,462
	Eksceso	-1,144	0,253
1	Asimetrijos	1278,582	0,841
	Eksceso	-1,873	0,061

Patikrinus visas parametrinės diskriminantinės analizės prielaidas, modelio, skirto moterų vainikinių širdies arterijų susiaurėjimo hemodinamiškam reikšmingumui prognozuoti, sudarymui buvo naudojami šie diskriminantiniai kintamieji: $X^{(2)}, \ln(X^{(3)}), X^{(4)}, X^{(7)}, X^{(8)}, X^{(9)}, X^{(10)}, \ln(X^{(13)}), \ln(X^{(14)}), \ln(X^{(15)}), X^{(16)}, \ln(X^{(19)}), \ln(X^{(20)}), \ln(X^{(21)}), \ln(X^{(22)}), \ln(X^{(23)}), \ln(X^{(24)}), X^{(26)}, X^{(30)}$. Ne visi šie kintamieji pasižymi geromis diskriminavimo savybėmis, todėl naudojant pažingsninį metodą su įvairiais įrašymo ir išbraukimo lygmenimis buvo ieškomi informatyvių parametru rinkiniai. Atrinkus informatyvius parametrus, buvo sudaromos diskriminavimo funkcijos ir apskaičiuojami klaidingo klasifikavimo tikimybių įverčiai, naudojantis Lachenbruch'o procedūra. Ši procedūra buvo pasirinkta todėl, kad neesant „testiniai imčiai“, tai yra vienas iš būdų patikrinti diskriminavimo kokybę [11]. 2.26 lentelėje pateikiami pažingsninio metodo taikymo rezultatai.

2.26 lentelė

Pažingsninio metodo taikymo rezultatai

Parametr rinkinys	rašymo lygmuo	Išbraukimo lygmuo	Klasifikavimo rodikliai		
			Bendras teisingo klasifikavimo procentas	Jautrumas	Specifiškumas
$X^{(7)}, X^{(10)}, \ln(X^{(21)}), \ln(X^{(22)})$	0,1	0,15	65,42%	67,5%	63,33%
$X^{(7)}, X^{(9)}, X^{(10)}, \ln(X^{(21)}), \ln(X^{(22)})$	0,2	0,25	72,5%	75%	70%
$X^{(7)}, X^{(9)}, X^{(10)}, \ln(X^{(21)}), \ln(X^{(22)}), X^{(30)}$	0,3	0,35	67,09%	67,5%	66,67%
$X^{(7)}, X^{(9)}, X^{(10)}, \ln(X^{(21)}), \ln(X^{(22)}), X^{(23)}, X^{(30)}$	0,5	0,55	72,5%	75%	70%
$X^{(2)}, X^{(7)}, X^{(9)}, X^{(10)}, X^{(16)}, \ln(X^{(21)}), \ln(X^{(22)}), X^{(23)}, X^{(30)}$	0,6	0,65	70%	70%	70%

Matome, kad padidinus įrašymo ir išbraukimo lygmenis, diskriminavimo kokybė suprastėjo, todėl remiantis tyrimo metu atliktais stebėjimais bei medikų rekomendacijomis buvo pasirinktas paskutinis parametrų rinkinys, tačiau iš jo buvo pašalinti parametrai $X^{(2)}, X^{(22)}$ ir įtrauktas parametras $X^{(19)}$. Šis parametrų rinkinys $X^{(7)}, X^{(9)}, X^{(10)}, X^{(16)}, \ln(X^{(19)}), \ln(X^{(21)}), \ln(X^{(23)}), X^{(30)}$ buvo naudojamas parametrinės diskriminantinės analizės modelio, skirto moterų vainikinių arterijų stenozei prognozuoti, sudarymui. Kadangi diskriminavimo funkcijos išraiška priklauso nuo to, ar diskriminavimo kintamųjų kovariacijų matricos atskirose grupėse yra lygios, todėl pirmiausia patikrinta hipotezė apie kovariacijų matricių homogeniškumą atskirose grupėse su pasirinktu reikšmingumo lygmeniu $\alpha = 0,01$. Tikrinant hipotezę apskaičiuota χ^2 statistikos reikšmė lygi 61,49, o p reikšmė lygi 0,0051. Kadangi $p < 0,01$, todėl hipotezė apie kovariacijų matricių lygybę nebuvo priimtina ir diskriminantinės analizės modelyje buvo naudojamos kvadratinės diskriminavimo funkcijos:

$$d_i(\vec{x}) = -\frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} \left(\vec{x} - \vec{\mu}_i \right) \Sigma_i^{-1} \left(\vec{x} - \vec{\mu}_i \right)^T + \ln p_i, \quad (2.19)$$

čia i – grupės numeris ($i = 0,1$), $\vec{\mu}_i$ – diskriminavimo kintamųjų vidurkių vektorius, Σ_i – diskriminavimo kintamųjų kovariacijų matrica, \vec{x} – pacientės duomenų vektorius $\vec{x} = (x^{(7)}, x^{(9)}, x^{(10)}, x^{(16)}, \ln x^{(19)}, \ln x^{(21)}, \ln x^{(23)}, x^{(30)})$, p_i – apriorinė tikimybė, kad pacientė, kurios elektrokardiografiniai parametrai aprašomi vektoriumi \vec{x} , priklauso i -ajai grupei. Mūsų atveju $p_0 = p_1 = \frac{1}{2}$.

Naudojantis SAS sistemos procedūra DISCRIM buvo apskaičiuoti grupių vektorių vidurkių įverčiai, kovariacijų matricių įverčiai ir sudarytos kvadratinės diskriminavimo funkcijos:

$$\begin{aligned}
 d_0\left(\vec{x}\right) &= -439,601 + 2,44x^{(7)} - 0,584x^{(9)} - 0,352x^{(10)} + 0,136x^{(16)} + 28,335x^{(19)} - 2,736x^{(21)} - \\
 &- 3,761x^{(23)} + 0,034x^{(30)} - 0,01x^{(7)}x^{(7)} + 0,006x^{(7)}x^{(9)} + 0,004x^{(7)}x^{(10)} - 0,076x^{(7)}x^{(19)} + 0,027x^{(7)}x^{(21)} + \\
 &+ 0,002x^{(7)}x^{(23)} - 0,009x^{(9)}x^{(9)} + 0,002x^{(9)}x^{(10)} + 0,044x^{(9)}x^{(19)} - 0,022x^{(9)}x^{(21)} + 0,001x^{(9)}x^{(23)} - \\
 &- 0,007x^{(10)}x^{(10)} + 0,022x^{(10)}x^{(19)} - 0,004x^{(10)}x^{(21)} - 0,002x^{(10)}x^{(23)} - 0,011x^{(16)}x^{(19)} + 0,004x^{(16)}x^{(21)} + \\
 &+ 0,004x^{(16)}x^{(23)} - 6,835x^{(19)}x^{(19)} + 1,577x^{(19)}x^{(21)} + 0,89x^{(19)}x^{(23)} + 0,001x^{(19)}x^{(30)} - 1,07x^{(21)}x^{(21)} - \\
 &- 0,105x^{(21)}x^{(23)} + 0,004x^{(21)}x^{(30)} - 0,559x^{(23)}x^{(23)} - 0,001x^{(23)}x^{(30)} \\
 \\
 d_1\left(\vec{x}\right) &= -1172,909 + 4,239x^{(7)} - 1,777x^{(9)} + 1,996x^{(10)} + 0,311x^{(16)} - 22,911x^{(19)} + 58,369x^{(21)} + \\
 &+ 4,8931x^{(23)} - 0,316x^{(30)} - 0,007x^{(7)}x^{(7)} + 0,004x^{(7)}x^{(9)} - 0,001x^{(7)}x^{(10)} - 0,038x^{(7)}x^{(19)} - 0,024x^{(7)}x^{(21)} + \\
 &+ 0,001x^{(7)}x^{(30)} - 0,007x^{(9)}x^{(9)} + 0,004x^{(9)}x^{(10)} - 0,027x^{(9)}x^{(19)} + 0,033x^{(9)}x^{(21)} + 0,005x^{(9)}x^{(23)} - \\
 &- 0,006x^{(10)}x^{(10)} + 0,079x^{(10)}x^{(19)} - 0,047x^{(10)}x^{(21)} - 0,006x^{(10)}x^{(23)} - 0,003x^{(16)}x^{(19)} - 0,003x^{(16)}x^{(21)} - \\
 &- 11,642x^{(19)}x^{(19)} + 3,852x^{(19)}x^{(21)} + 1,081x^{(19)}x^{(23)} + 0,014x^{(19)}x^{(30)} - 2,682x^{(21)}x^{(21)} - 0,353x^{(21)}x^{(23)} - \\
 &- 0,007x^{(21)}x^{(30)} - 0,472x^{(23)}x^{(23)}.
 \end{aligned}$$

(2.20)

2.27 lentelėje pateikiami $d_0\left(\vec{x}\right)$ funkcijos koeficientai, o 2.28 lentelėje $d_1\left(\vec{x}\right)$ funkcijos koeficientai.

2.27 lentelė

Diskriminavimo funkcijos $d_0\left(\vec{x}\right)$ koeficientų įverčiai

	$X^{(7)}$	$X^{(9)}$	$X^{(10)}$	$X^{(16)}$	$X^{(19)}$	$X^{(21)}$	$X^{(23)}$	$X^{(30)}$
$X^{(7)}$	-0.010	0.006	0.004	0	-0.076	0.027	0.002	0
$X^{(9)}$		-0.009	0.002	0	0.044	-0.022	0.001	0
$X^{(10)}$			-0.007	0	0.022	-0.004	-0.002	0
$X^{(16)}$				0	-0.011	0.004	0.004	0
$X^{(19)}$					-6.835	1.577	0.89	0.001
$X^{(21)}$						-1.07	-0.105	0.004
$X^{(23)}$							-0.559	-0.001
$X^{(30)}$								0
Tiesiniai nariai	2.44	-0.584	-0.352	0.136	28.335	-2.736	-3.761	0.034

2.28 lentelė

Diskriminavimo funkcijos $d_1(\vec{x})$ koeficientų įverčiai

	$X^{(7)}$	$X^{(9)}$	$X^{(10)}$	$X^{(16)}$	$X^{(19)}$	$X^{(21)}$	$X^{(23)}$	$X^{(30)}$
$X^{(7)}$	-0.007	0.004	-0.001	0	-0.038	-0.024	0	0.001
$X^{(9)}$		-0.007	0.004	0	-0.027	0.033	0.005	0
$X^{(10)}$			-0.006	0	0.079	-0.047	-0.006	0
$X^{(16)}$				0	-0.003	-0.003	0	0
$X^{(19)}$					-11.642	3.852	1.081	0.014
$X^{(21)}$						-2.682	-0.353	-0.007
$X^{(23)}$							-0.472	0
$X^{(30)}$								0
Tiesiniai nariai	4.239	-1.777	1.996	0.311	-22.911	58.369	4.893	-0.316

Pacientės priskyrimui vienai iš grupių bei jos vainikinių širdies arterijų susiaurėjimų prognozavimui, taikant kvadratinės diskriminavimo funkcijas, naudojama tokia pat procedūra kaip ir taikant tiesines diskriminavimo funkcijas:

1. Į diskriminavimo funkcijas įrašius pacientės duomenis, apskaičiuojamos funkcijų reikšmės.
2. Pacientė priskiriamas tai grupei, kurios apskaičiuota funkcijos reikšmė yra didesnė.

Kaip jau buvo minėta anksčiau, diskriminantinės analizės modelio klasifikavimo kokybę nusako klasifikavimo lentelė (2.29 lentelė) bei klaidingo klasifikavimo tikimybių įverčiai (2.30 lentelė).

2.29 lentelė

Klasifikavimo lentelė

Pacientai priklausantys grup ms	Pacientai priskirti grup ms		Viso
	0	1	
0	37 92,5%	3 7,5%	40 100%
1	3 10%	27 90%	30 100%

2.30 lentelė
Klaidingo klasifikavimo tikimybių įverčiai

	Grup		Bendras
	0	1	
vertis	0,075	0,1	0,0875

Rezultatai, pateikti klasifikavimo lentelėje rodo, kad sudaryto modelio klasifikavimo jautrumas yra 90%, o specifiškumas 92,5%. Dar vienas iš būdų klasifikavimo kokybei įvertinti yra Lachenbrucho procedūra. Jos rezultatas taip pat pateikiamas klasifikavimo lentelė (2.31 lentelė) bei klaidingo klasifikavimo tikimybių įverčiais (2.32 lentelė).

2.31 lentelė
Lachenbrucho procedūros lentelė

Pacientai priklausantys grup ms	Pacientai priskirti grup ms		Viso
	0	1	
0	29 72,5%	11 27,5%	40 100%
1	8 26,67%	22 73,33%	30 100%

2.32 lentelė
Lachenbrucho procedūros klaidingo klasifikavimo tikimybių reikšmės

	Grup		Bendras
	0	1	
vertis	0,275	0,267	0,271

Iš pastarųjų lentelių matyti, kad Lachenbrucho procedūros klasifikavimo rodikliai prastesni už rodiklius, gautus klasifikuojant pacientus į grupes, naudojant sudarytas klasifikavimo funkcijas. Tačiau šie rodikliai yra pakankamai geri ir tai rodo, kad sudarytos klasifikavimo procedūros pakankamai patikimai klasifikuoja moteris į grupes pagal jų vainikinių širdies arterijų susiaurėjimų laipsnį.

2.2.4. VAINIKINIŲ ŠIRDIES ARTERIJŲ SUSIAURĖJIMŲ ĮVERTINIMO PAGAL EKG IR VKG PARAMETRUS NEPARAMETRINĖS DISKRIMINANTINĖS ANALIZĖS MODELIS

Neparametrinėje diskriminantinėje analizėje (kaip ir parametrinėje diskriminantinėje analizėje) pagal tolydžiųjų kintamųjų reikšmes sprendžiama apie objekto priklausomybę vienai iš keleto grupių. Tačiau neparametriniai diskriminantinės analizės metodai pagrįsti grupės tankių neparametriniais įverčiais, taigi, čia nėra reikalaujama, kad daugiamatis nepriklausomų kintamųjų skirstinys būtų normalusis. Likusieji reikalavimai, kurie keliami sudarant parametrinės diskriminantinės analizės modelius, taikomi ir neparametrinės diskriminantinės analizės modeliuose. Šiuose modeliuose kiekvienos grupės tankių įverčių radimui ir klasifikavimo kriterijų sudarymui gali būti naudojamas branduolio metodas su fiksuotu spinduliu r arba artimiausių kaimynų metodas, su nustatytais kaimynų skaičiumi. Darbe atliekamai analizei buvo pasirinktas normalusis branduolio tipas ir atliekamas tyrimas, keičiant spindulio dydį.

Remiantis tyrimo metu atliktais stebėjimais bei medikų rekomendacijomis, sudarant neparametrinės diskriminantinės analizės modelį, skirtą vyrų vainikinių arterijų susiaurėjimų prognozavimui, informatyvių parametrų rinkinys buvo sudarytas iš nepriklausomų kintamųjų, naudotų parametrinės diskriminantinės analizės modelyje, bei dar vieno vektorkardiogramos parametro – $X^{(29)}$. Sudarant modelius buvo naudojami tie patys diskriminavimo kintamieji $X^{(2)}$, $X^{(13)}$, $\ln X^{(19)}$, $\ln X^{(23)}$, $\ln X^{(27)}$, $X^{(29)}$, $X^{(30)}$, o keičiamas branduolio spindulys. Modelių klasifikavimo kokybė vertinta naudojant Lachenbruch'o procedūrą. Gauti rezultatai pateikiami 2.33 lentelėje. Diskriminantinės analizės modelis, kuriame normaliojo branduolio spindulys lygus 1, pacientus į grupes pagal jų vainikinių arterijų susiaurėjimų laipsnį klasifikuoja geriausiai.

2.33 lentelė

Klasifikavimo rodikliai, priklausantys nuo normaliojo branduolio spindulio

	Branduolio spindulys, r		
	0,5	1	1,5
Jautrumas (%)	61,86	61,86	59,79
Specifiškumas (%)	58,82	64,71	63,24
Bendras teisingo klasifikavimo procentas (%)	60,34	63,28	61,51

Pagal Bajeso klasifikavimo procedūrą [31] pacientas, kurio stebėjimų vektorius $\vec{x} = (x^{(2)}, x^{(13)}, \ln x^{(19)}, \ln x^{(23)}, \ln x^{(27)}, x^{(29)}, x^{(30)})$, priskiriamas grupei pacientų, kurių vainikinių arterijų susiaurėjimas

hemodinamiškai nereikšmingas, jeigu $p\left(G_0 \middle| \vec{x}\right) = \frac{q_0 f_0\left(\vec{x}\right)}{f\left(\vec{x}\right)} \geq p\left(G_1 \middle| \vec{x}\right) = \frac{q_1 f_1\left(\vec{x}\right)}{f\left(\vec{x}\right)}$, arba grupei pacientų,

kurių vainikinių arterijų susiaurėjimas hemodinamiškai reikšmingas, jeigu

$p\left(G_0 \middle| \vec{x}\right) = \frac{q_0 f_0\left(\vec{x}\right)}{f\left(\vec{x}\right)} < p\left(G_1 \middle| \vec{x}\right) = \frac{q_1 f_1\left(\vec{x}\right)}{f\left(\vec{x}\right)}$. Čia $p\left(G_i \middle| \vec{x}\right)$ yra tikimybė, kad pacientas, kurio stebėjimų

vektorius \vec{x} , priklauso i -ajai grupei, q_i yra apriorinė tikimybė, kad pacientas priklauso i -ajai grupei,

$f_i\left(\vec{x}\right)$ – branduolio tankio funkcija i -oje grupėje, o $f\left(\vec{x}\right) = q_0 f_0\left(\vec{x}\right) + q_1 f_1\left(\vec{x}\right)$. Nagrinėjamu atveju

tariama, kad $q_0 = q_1 = 0,5$, o $f_i\left(\vec{x}\right)$ yra normaliojo branduolio tankio funkcija. Normaliojo branduolio

išraiška yra:

$$K_i\left(\vec{x}\right) = \frac{1}{c_0(i)} \exp\left(-\frac{1}{2r^2} \vec{x} \mathbf{V}_i^{-1} \left(\vec{x}\right)^T\right), \quad (2.21)$$

kai $c_0(i) = (2\pi)^{\frac{p}{2}} \cdot r^p \cdot |\mathbf{V}_i|^{0,5}$, \mathbf{V}_i – kovariacijų matrica, p – stebėjimų vektoriaus \vec{x} dimensija, o $i = 0, 1$ yra pacientų grupių identifikaciniai numeriai. Taigi i -osios grupės tankis naudojant normaliojo branduolio funkciją apskaičiuojamas taip:

$$f_i\left(\vec{x}\right) = \frac{1}{n_i} \sum_{\vec{y}} K_i\left(\vec{x} - \vec{y}\right), \quad (2.22)$$

čia sumuojama pagal visus stebėjimų vektorius, priklausančius i -ajai grupei.

Kaip jau buvo minėta anksčiau, tiriant vyrų populiacijos vainikinių širdies arterijų susiaurėjimų reikšmingumą pasirinktas branduolio spindulys lygus 1. Be to analizėje buvo naudojama jungtinė pacientų grupių kovariacijų matrica. Remiantis šiomis prielaidomis vyrų klasifikavimui į grupes pagal jų vainikinių arterijų stenozės laipsnį buvo naudojama tokia normaliojo branduolio išraiška:

$$K\left(\vec{x}\right) = \frac{1}{c_0} \exp\left(-\frac{1}{2} \vec{x} \mathbf{V}^{-1} \left(\vec{x}\right)^T\right), \quad (2.23)$$

kur $c_0 = (2\pi)^{\frac{7}{2}} \cdot |\mathbf{V}|^{0,5}$, o jungtinė kovariacijų matrica \mathbf{V} pateikta 2.34 lentelėje.

2.34 lentelė

Kovariacijų matrica

	$X^{(2)}$	$X^{(13)}$	$X^{(19)}$	$X^{(23)}$	$X^{(27)}$	$X^{(29)}$	$X^{(30)}$
$X^{(2)}$	99.82	140.66	-1.00	-0.92	-1.79	-13.00	-5.61
$X^{(13)}$	140.66	17625.07	7.20	94.18	-32.04	-197.60	-627.53
$X^{(19)}$	-1.00	7.20	0.14	0.22	0.08	0.45	-1.55
$X^{(23)}$	-0.92	94.18	0.22	1.52	-0.58	4.36	-13.50
$X^{(27)}$	-1.79	-32.04	0.08	-0.58	0.85	-3.34	10.54
$X^{(29)}$	-13.00	-197.60	0.45	4.36	-3.34	1249.84	-120.59
$X^{(30)}$	-5.61	-627.53	-1.55	-13.50	10.54	-120.59	3711.28

Taikant sudarytą modelį ir aprašytą klasifikavimo procedūrą, „mokomosios imties“ pacientų klasifikacijos rezultatai pateikiami 2.35 ir 2.36 lentelėse.

2.35 lentelė

Klasifikavimo lentelė

Pacientai priklausantys grup ms	Pacientai priskirti grup ms		Viso
	0	1	
0	65 95,59%	3 4,41%	68 100%
1	14 14,43%	83 85,57%	97 100%

2.36 lentelė

Klaidingo klasifikavimo tikimybių įverčiai

	Grup		Bendras
	0	1	
vertis	0,0441	0,1443	0,0942

Analogiškai sudarant neparimetrinės diskriminantinės analizės modelį, skirtą moterų vainikinių arterijų susiaurėjimų prognozavimui, informatyvių parametrų rinkinys buvo sudarytas iš nepriklausomų kintamųjų, naudotų moterims skirtame parametrinės diskriminantinės analizės modelyje, bei dar vieno vektorkardiogramos parametro – $X^{(29)}$. Sudarant modelius buvo naudojamas tas pats diskriminavimo kintamųjų rinkinys $X^{(7)}$, $X^{(9)}$, $X^{(10)}$, $X^{(16)}$, $\ln(X^{(19)})$, $\ln(X^{(21)})$, $\ln(X^{(23)})$, $X^{(29)}$, $X^{(30)}$, o branduolio spindulys – keičiamas. Modelių klasifikavimo kokybė buvo vertinta naudojant Lachenbruch procedūrą. Gauti rezultatai pateikiami 2.37 lentelėje.

2.37 lentelė

Klasifikavimo rodiklių priklausomybė nuo normaliojo branduolio spindulio

	Branduolio spindulys, r			
	0,7	1,4	2,1	2,8
Jautrumas (%)	53,33	66,67	66,67	63,33
Specifiškumas (%)	52,50	65	67,5	70
Bendras teisingo klasifikavimo procentas (%)	52,92	65,83	67,08	66,67

Pagal rodiklius pateiktus 2.37 lentelėje galima spręsti, kad diskriminantinės analizės modelis, kuriame normaliojo branduolio spindulys 2,1, pacientes į grupes pagal jų vainikinių arterijų susiaurėjimų laipsnį klasifikuoja geriausiai. Pacientės, kurių stebėjimų vektoriai $\vec{x} = (x^{(7)}, x^{(9)}, x^{(10)}, x^{(16)}, \ln x^{(19)}, \ln x^{(21)}, \ln x^{(23)}, x^{(29)}, x^{(30)})$, suskirstomos į atskiras grupes naudojant analogišką Bajeso klasifikavimo procedūrą, kuri buvo aprašyta sudarant vyrams skirtą modelį. Kadangi tiriant moterų populiaciją, kaip ir vyrų populiacijos atveju, naudojama jungtinė grupių kovariacijų matrica, tai klasifikavimui naudojama normaliojo branduolio išraiška yra:

$$K\left(\vec{x}\right) = \frac{1}{c_0} \exp\left(-\frac{1}{8,82} \vec{x} \mathbf{V}^{-1} \begin{pmatrix} \vec{x} \\ x \end{pmatrix}^T\right), \quad (2.24)$$

kai $c_0 = (2\pi)^{4,5} \cdot 2,1^{4,5} |\mathbf{V}|^{0,5}$. Šioje išraiškoje naudojama jungtinė kovariacijų matrica \mathbf{V} pateikta 2.38 lentelėje

2.38 lentelė

Kovariacijų matrica

	$X^{(7)}$	$X^{(9)}$	$X^{(10)}$	$X^{(16)}$	$X^{(19)}$	$X^{(21)}$	$X^{(23)}$	$X^{(29)}$	$X^{(30)}$
$X^{(7)}$	284.37	213.38	172.15	-593.19	-0.91	-1.62	-1.11	40.51	294.68
$X^{(9)}$	213.38	268.59	191.58	-168.87	-0.25	-0.79	1.44	9.46	123.29
$X^{(10)}$	172.15	191.58	235.04	-180.89	-0.02	-0.64	1.15	-2.45	46.85
$X^{(16)}$	-593.19	-168.87	-180.89	18659.86	-9.91	-6.31	58.19	-82.76	-2034.27
$X^{(19)}$	-0.91	-0.25	-0.02	-9.91	0.14	0.2	0.16	2.46	2.58
$X^{(21)}$	-1.62	-0.79	-0.64	-6.31	0.2	0.75	0.14	4.16	4.24
$X^{(23)}$	-1.11	1.44	1.15	58.19	0.16	0.14	1.66	-2.11	-8.83
$X^{(29)}$	40.51	9.46	-2.45	-82.76	2.46	4.16	-2.11	818.12	111.82
$X^{(30)}$	294.68	123.29	46.85	-2034.27	2.58	4.24	-8.83	111.82	3758.7

Naudojant sudarytą modelį, pacienčių klasifikacijos į atskiras grupes pagal vainikinių širdies arterijų susiaurėjimų hemodinamišką reikšmingumą rezultatai pateikiami 2.39 ir 2.40 lentelėse.

2.39 lentelė

Klasifikavimo lentelė

Pacientai priklausantys grup ms	Pacientai priskirti grup ms		Vsio
	0	1	
0	34 85%	6 15%	40 100%
1	5 16,67%	25 83,33%	30 100%

2.40 lentelė

Klaidingo klasifikavimo tikimybių įverčiai

	Grup		Bendras
	0	1	
vertis	0,15	0,1667	0,1583

2.2.5. VAINIKINIŲ ŠIRDIES ARTERIJŲ SUSIAURĖJIMŲ ĮVERTINIMO PAGAL EKG IR VKG PARAMETRUS MODELIŲ LYGINAMOJI ANALIZĖ

Vainikinių širdies arterijų susiaurėjimų įvertinimui naudojant elektrokardiogramas, vektorkardiogramas bei klinikinius pacientų duomenis buvo sukurti trys statistinės analizės modeliai: logistinės regresinės analizės, parametrinės diskriminantinės analizės bei neparametrinės diskriminantinės analizės modeliai. Atsižvelgiant į tai, kad vyrų ir moterų elektrokardiografinių parametrų reikšmės skiriasi, modeliai buvo sukurti atskirai moterims ir vyrams. Tiek vyrams, tiek moterims sukurtų modelių klasifikavimo, o tuo pačiu ir prognozavimo tikslumai skiriasi. Apie modelio tikslumą sprendžiama pagal klasifikavimo jautrumą, specifiškumą bei bendrą teisingo klasifikavimo procentą. 2.41 lentelėje pateikiami vyrų vainikinių širdies arterijų susiaurėjimų įvertinimui sukurtų modelių klasifikavimo rezultatai.

2.41 lentelė

Klasifikavimo rezultatai

Modelis	Jautrumas (%)	Specifiškumas (%)	Bendras teisingo klasifikavimo procentas (%)
Logistinės regresijos	78,4	52,9	65,65
Parametrinės diskriminantinės analizės	70,10	63,24	66,67
Neparametrinės diskriminantinės analizės	85,57	95,59	90,58

Pagal 2.41 lentelėje pateiktus rezultatus galima teigti, kad vyrų vainikinių širdies arterijų susiaurėjimus geriausiai prognozuoja neparimetrinės diskriminantinės analizės modelis – 90,58% teisingai klasifikuotų pacientų. Prasčiausiai prognozuoja logistinės regresijos modelis, kurį taikant 65,65% pacientai klasifikuoti teisingai. Neparimetrinės diskriminantinės analizės modelio klasifikavimo jautrumas ir specifiškumas yra didžiausi – 85,57% ir 95,59%.

2.42 lentelėje pateikiami moterų vainikinių širdies arterijų susiaurėjimų įvertinimui sukurtų modelių klasifikavimo rezultatai. Šie rezultatai rodo, kad tiksliausiai moterų vainikinių arterijų susiaurėjimus prognozuoja parametrinės diskriminantinės analizės modelis. Modelio bendras teisingai klasifikuotų pacienčių skaičius 91,25%. Šio modelio klasifikavimo specifiškumas ir jautrumas yra taip pat didžiausi lyginant su kitais modeliais. Prasčiausiai moterų stenozės laipsnį prognozuoja logistinės regresijos modelis. Šio modelio klasifikavimo specifiškumas ir jautrumas yra taip pat mažiausi – 63,3% ir 82,5%.

2.42 lentelė

Klasifikavimo rezultatai

Modelis	Jautrumas (%)	Specifiškumas (%)	Bendras teisingo klasifikavimo procentas (%)
Logistinės regresijos	63,3	82,5	72,9
Parametrinės diskriminantinės analizės	90	92,5	91,25
Neparimetrinės diskriminantinės analizės	83,3	85	84,17

Lyginant vyrų ir moterų modelius, galima pastebėti, kad logistinės regresijos ir parametrinės diskriminantinės analizės modelių, skirtų moterų vainikinių arterijų susiaurėjimų vertinimui, klasifikavimo rodikliai yra geresni nei vyrams skirtų modelių. Be to tiek vyrų, tiek moterų stenozę prasčiausiai prognozuoja logistinės regresijos modeliai.

2.3. VAINIKINIŲ ŠIRDIES ARTERIJŲ SUSIAURĖJIMŲ TYRIMO SPRENDIMŲ PRIĖMIMO PARAMOS SISTEMA

Vainikinių širdies arterijų susiaurėjimų tyrimo sprendimo priėmimo paramos sistema sukurta naudojantis statistinės analizės sistema *SAS* bei jos posistemėmis *SAS/BASE*, *SAS/ACCESS*, *SAS/IML*, *SAS/STAT*, *SAS/AF*, *SAS/GRAPH*. Sudarant sprendimų priėmimo paramos sistemą buvo keliami du pagrindiniai uždaviniai:

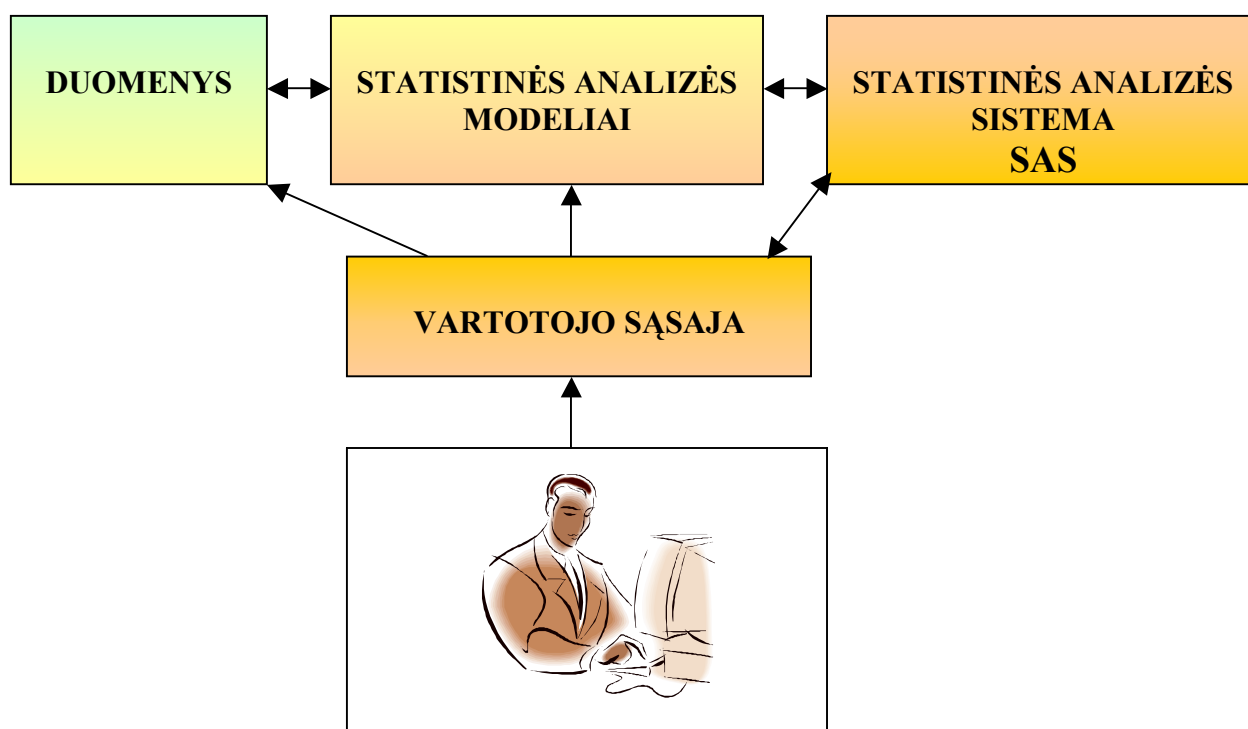
- 1) sukauptų pacientų duomenų analizė;
- 2) paciento vainikinių širdies arterijų susiaurėjimų prognozavimas.

Realizuojant šiuos uždavinius buvo sukurta vartotojo sąsaja, kuri apjungia ir valdo pastarųjų uždavinių realizavimą. Atliekant sukauptų pacientų duomenų analizę yra pateikiami sukurti statistinės analizės

modeliai bei jų taikymo rezultatai. Papildžius pacientų duomenų bazę naujais duomenimis, sukurti statistinės analizės modeliai gali būti tikslinami. Realizuojant antrąjį uždavinį naudojant suskurtus modelius (ir pradinius, ir patikslintus) įvertinami ir prognozuojami atskiro paciento vainikinių širdies arterijų susiaurėjimai.

2.3.1. STRUKTŪRA

Vainikinių širdies arterijų susiaurėjimų tyrimo sprendimo priėmimo paramos sistemos struktūra pavaizduota 2.10 paveiksle.



2.10 pav. Vainikinių širdies arterijų susiaurėjimų tyrimo sprendimo priėmimo paramos sistemos struktūra

Skurta paramos sistema susideda iš trijų posistemų: vartotojo sąsajos posistemės, duomenų posistemės ir statistinės analizės posistemės. Duomenų posistemę sudaro pacientų duomenų failas, kuris buvo naudojamas sudarant statistinės analizės modelius, duomenų failai, kurie naudojami atskirų pacientų vainikinių širdies arterijų susiaurėjimų prognozavimui bei kaupiamasis duomenų failas, kuris gali būti papildomas naujais pacientų duomenimis. Visi duomenys yra saugomi EXCEL formato failuose. Statistinės analizės modelių posistemę sudaro programos, kuriose yra realizuoti modeliai, skirti atlikti jau sukauptų pacientų duomenų analizę. Šios analizės pagrindu sukuriama modeliai, skirti atskirų pacientų vainikinių širdies arterijų susiaurėjimams prognozuoti. Sukurtų modelių programos taip pat priklauso statistinės analizės modelių posistemėi. Vartotojo sąsajos posistemė apjungia duomenų ir modelių posistemas bei realizuoja statistinės analizės modelius.

Statistinės analizės modelių ir vartotojo sąsajos posistemės sukurtos naudojant sistemos SAS posistemas. Vartotojo sąsaja sukurta naudojant SAS/AF ir SAS/BASE posistemas, SAS programavimo kalbą, SAS makro programavimo priemones. Statistinės analizės modeliai realizuoti naudojant SAS/BASE, SAS/ACCESS, SAS/IML, SAS/STAT, SAS/GRAPH posistemas.

2.3.2. ŠIRDIES VAINIKINIŲ ARTERIJŲ SUSIAURĖJIMŲ ANALIZĖS PROGRAMINIAI MODELIAI

Kiekvieno sudaryto statistinės analizės modelio, skirto pacientų vainikinių širdies arterijų susiaurėjimų tyrimui, realizavimui buvo sukurtos atskiros programos. Programos sukurtos naudojant statistinės analizės sistemos *SAS* programines priemones. Kiekvieną programą sudaro dvi dalys. Pirmoje dalyje sudaroma duomenų matrica, formuojami duomenų matricos pjūviai. Antroje dalyje naudojant SAS sistemos posistemas *SAS/BASE*, *SAS/IML*, *SAS/STAT*, *SAS/GRAPH* bei šių posistemų procedūras realizuojami statistinės analizės modeliai bei pateikiami jų taikymo rezultatai. Rezultatai pateikiami ir lentelių, ir grafikų pavidalu. Darbe naudojamus statistinės analizės metodus realizuoja šios procedūros:

- Aprašomoji statistinė analizė realizuota naudojant procedūras *MEANS* ir *BOXPLOT*. Skaitinės parametrų charakteristikos apskaičiuotos naudojant *MEANS*, o stačiakampės diagramos braižomos naudojant procedūrą *BOXPLOT*.
- Logistinės regresinės analizės modelis realizuotas naudojant procedūrą *LOGISTIC*.
- Suderinamumo hipotezės apie pacientų duomenų skirstinius tikrinamos naudojant procedūras *UNIVARIATE* ir *IML*. Procedūra *UNIVARIATE* naudojama vienmačių skirstinių atveju, o daugiamačių skirstinių – *IML*.
- Parametrinės ir neparametrinės diskriminantinės analizės modeliai realizuojami su procedūra *DISCRIM*. Realizuojant parametrinės diskriminantinės analizės modelį, procedūroje nustatomas parametras *METHOD=NORMAL*, o esant neparametrinei diskriminantinei analizei – *METHOD=NPAR*.

Visose procedūrų programose pacientų klinikiniai ir elektrokardiografiniai parametrai žymimi naudojant sutrumpinimus. Sutrumpinimų sąrašas pateikiamas *1 priede*.

Aptarsime dviejų modelių programų tekstus, o visi programų tekstai pateikti *6 priede*. Taigi moterų širdies vainikinių arterijų susiaurėjimų prognozavimo logistinės regresijos modelis sudarytas naudojant procedūrą *LOGISTIC*. Šios procedūros tekstas pateiktas 2.11 paveiksle.


```

proc logistic DATA=duom_m DESCENDING;
  MODEL grupe=amzius qtd jtd qtdapex jtdapex qtcd jtcd maxnnskir vidnn
    vidssd maxnn minnn sdnm rmssd vlf lf hf bsi lfnu hfnu
    lf_hf pkampas qrs_tnau tplotas tsantyk/
  SLENTY=0.2 SLSTAY=0.25 DETAILS SELECTION=stepwise LACKFIT PPROB=0.5 CTABLE
  OUTROC=roc_m;
run;

```

2.11 pav. Logistinės regresijos modelio programa

Naudojant procedūrą iš visų analizėje naudojamų pacienčių duomenų atrenkamas informatyvus parametru rinkinys, kai įrašymo ir išbraukimo lygmenys parenkami `SLENTY=0.2` ir `SLSTAY=0.25`. Į procedūrą įrašius parametrus `DETAILS` ir `SELECTION=stepwise`, pacienčių informatyvūs elektrokardiografiniai parametrai atrenkami taikant pažingsninį metodą ir kiekviename žingsnyje yra pateikiama informacija, apie įrašytą arba išbrauktą parametru bei iš jau atrinktų parametru sudarytą modelį. Atlikus pažingsninį metodą ir atrinkus informatyvius parametrus, gautam logistinės regresijos modeliui yra apskaičiuojami logistinės regresijos lygties koeficientai, tikrinamos hipotezės apie modelio patikimumą (pavyzdžiui, įrašius procedūros parametru `LACKFIT` taikomas Hosmerio-Lemešou kriterijus), sudaroma klasifikavimo lentelė (naudojami procedūros parametrai `PPROB=0.5 CTABLE`), sudaroma duomenų matrica, naudojama ROC kreivei nubraižyti (`OUTROC=roc_m`). Vyru širdies vainikinių arteriju susiaurėjimu prognozavimo logistinės regresijos modelis sudarytas naudojant analogišką procedūrą ir jos parametrus.

Vyru vainikinių širdies arteriju susiaurėjimu reikšmingumo prognozavimo parametrinės diskriminantinės analizės modelis sudarytas naudojant procedūrą `DISCRIM`, kurios tekstas pateiktas

2.12

```

proc discrim DATA=duom_v METHOD=normal POOL=test OUTSTAT=info_v
  CROSSLIST LISTERR;
  CLASS grupe;
  VAR amzius vk vlf hf lf_hf tplotas;
run;

```

paveiksle.

2.12 pav. Diskriminantinės analizės modelio programa

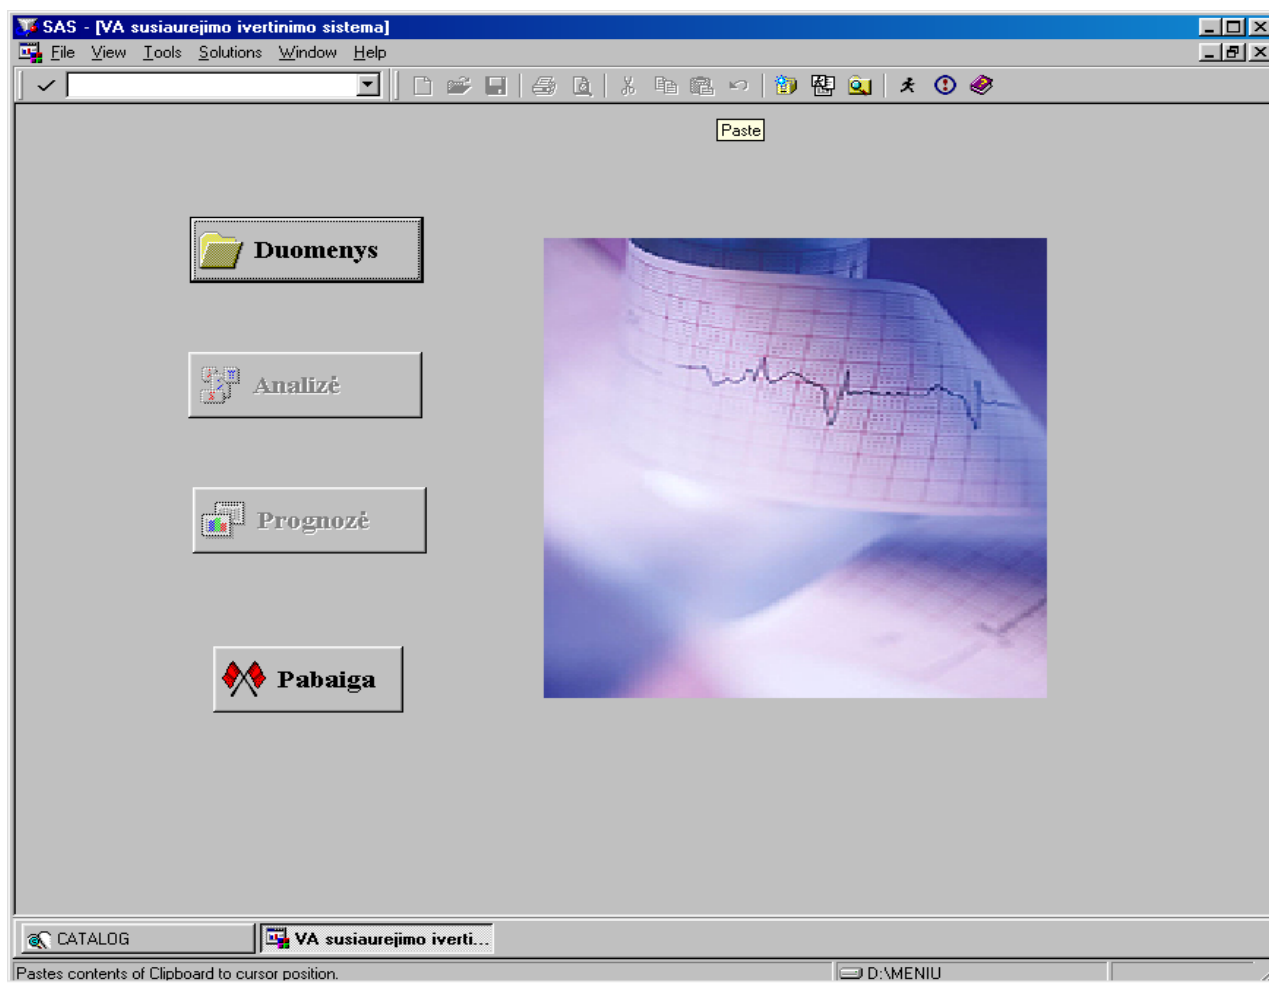
Procedūroje po parametro `CLASS` rašomas kintamasis, kuris identifikuoja pacientu tiriamas grupes. Po parametro `VAR` išvardijami naudojami diskriminavimo kintamieji. Įrašius parametru `POOL=test` yra tikrinamos hipotezės apie kovariacijų lygybę atskirose pacientu grupėse. Duomenų failas, kuriame pateikiamos įvairios kovariacijų matricos, klasifikavimo funkciju koeficientai, imties

skaitinės charakteristikos ir kt., sukuriamas kai naudojamas parametras `OUTSTAT=info_v`. Moterų populiacijai skirtas modelis realizuojamas analogiška procedūra.

2.3.3. VARTOTOJO SĄSAJA

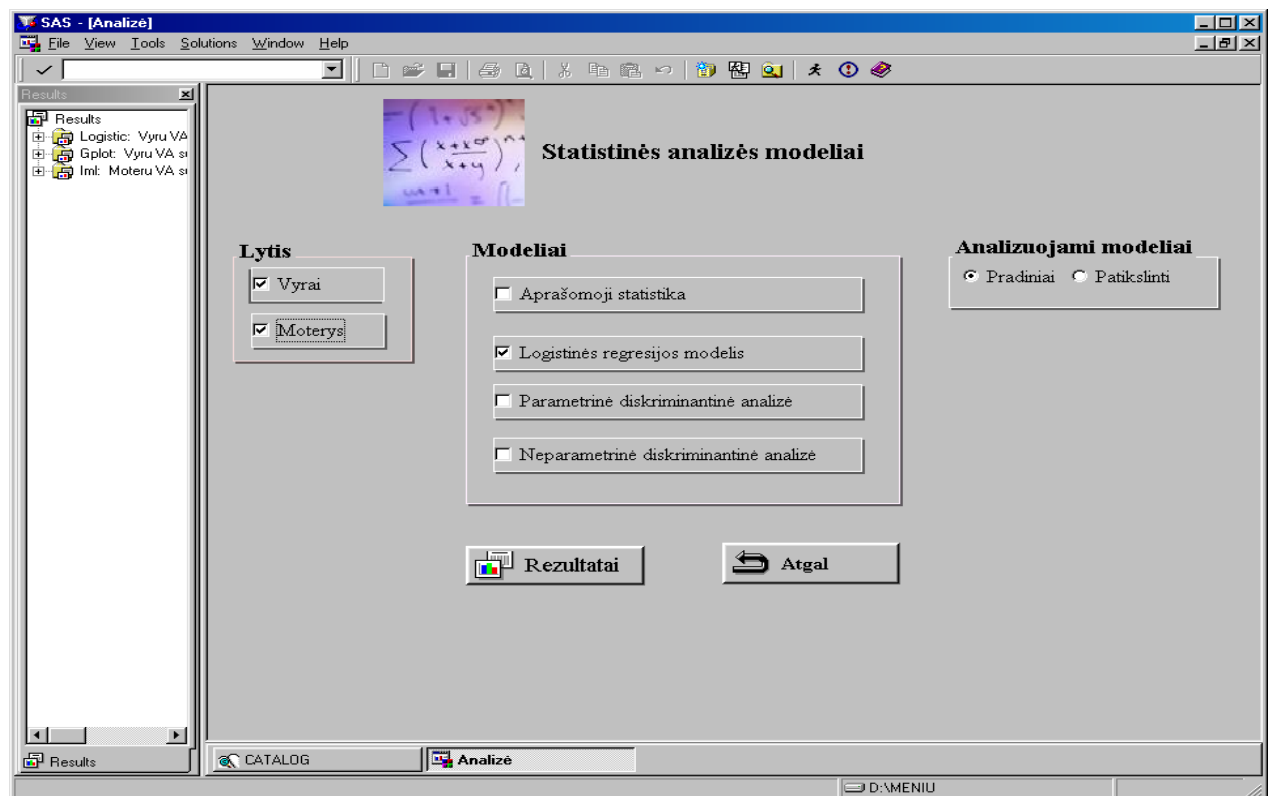
Sąsajos su vartotoju posistemė apjungia ir valdo vainikinių širdies arterijų susiaurėjimų tyrimo sprendimo priėmimo paramos sistemą. Ši posistemė sukurta panaudojus objektinio programavimo priemones turintį SAS sistemos modulį SAS/AF, SAS/BASE modulio procedūras, SAS programavimo kalbą ir SAS makro programavimo priemones. Programos skirtos vartotojo interaktyviai sąsajai su sistema yra SAS sistemos kataloge *menu.sas7bcats*. Kiekvieną programą sudaro du vienodo pavadinimo failai: grafiniai sąsajos objektai, kurių pagalba vartotojas bendrauja su SAS sistema (mygtukai, teksto įvedimo laukai ir kita), yra sukomponuoti faile, kurio praplėtimas **.frame*, o programos kodas, apibrėžiantis ryšius tarp objektų ir juos valdantis, saugomas faile, kurio praplėtimas **.scl*.

Aptarsime pagrindinius vartotojo sąsajos veikimo principus. Pirmajame lange (2.13 pav.) yra keturi mygtukai. Mygtukai „Analizė“ ir „Prognozė“ neaktyvūs, kadangi duomenys neįkelti į SAS sistemą ir analizės atlikti negalima.



2.13 pav. Pagrindinis vartotojo sąsajos langas

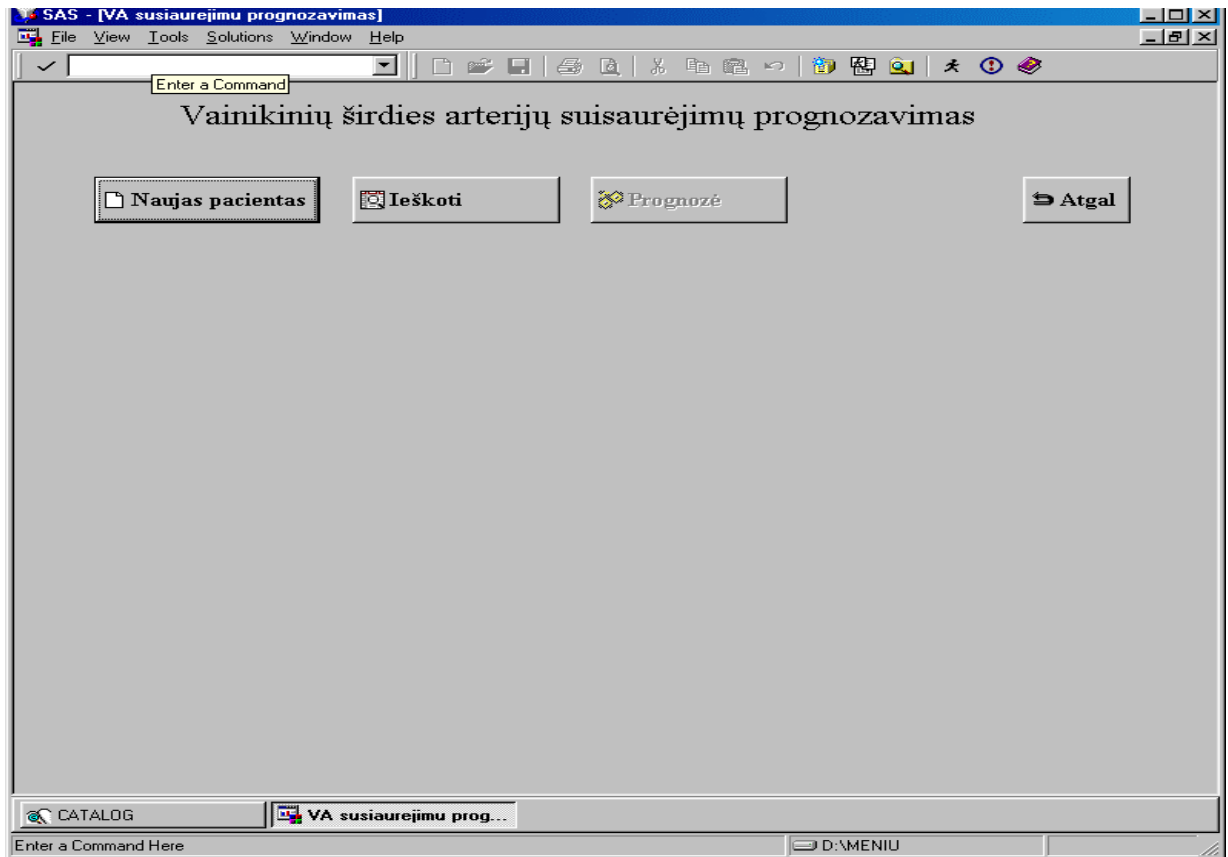
Paspaudus mygtuką „Duomenys“, duomenys, kurie saugomi EXCEL failuose įrašomi į SAS sistemą ir mygtukai „Analizė“ ir „Prognozė“ aktyvuojami. Paspaudus aktyvuotą mygtuką „Analizė“, atsiranda naujas langas (2.14 pav.). Vartotojas gali pasirinkti kokius pacientų grupes (vyrų ar moterų) ir kokius sudarytus modelius jis nori analizuoti. Kai pacientų duomenų bazė papildoma naujais duomenimis, tuomet galima patikslinti sudarytus pradinis modelius. Pradiniai statistinės analizės modeliai patikslinami srityje pavadintoje „Analizuojami modeliai“ parinkus pavadinimą „Patikslinti“ (2.14 pav.). Paspaudus mygtuką „Rezultatai“, pasirinkti modeliai realizuojami ir pateikiami gauti rezultatai. Rezultatai pateikiami netik SAS sistemos lange „Results“, bet įrašomi į Word failą ir saugomi direktorijoje „D:\menu\Rezultatai“. Šioje direktorijoje saugomi visi rezultatų failai. Paspaudus mygtuką „Atgal“ grįžtama į pradinį meniu langą.



2.14 pav. Vartotojo sąsajos langas, skirtas sukurtų modelių analizei

Pradiniame meniu lange paspaudus mygtuką „Prognozė“, atsiranda langas, kuriame realizuota vartotojo sąsajos dalis, skirta atskirų pacientų vainikinių širdies arterijų susiaurėjimų prognozavimui (2.15 pav.). Vartotojas naudodamas sukurtus statistinės analizės modelius gali prognozuoti duomenų bazėje įrašyto paciento vainikinių širdies arterijų susiaurėjimų hemodinamišką reikšmingumą. Tam reikia paspausti mygtuką „Ieškoti“ ir įvesti paciento numerį. Jei pacientas, kurio numerį vartotojas

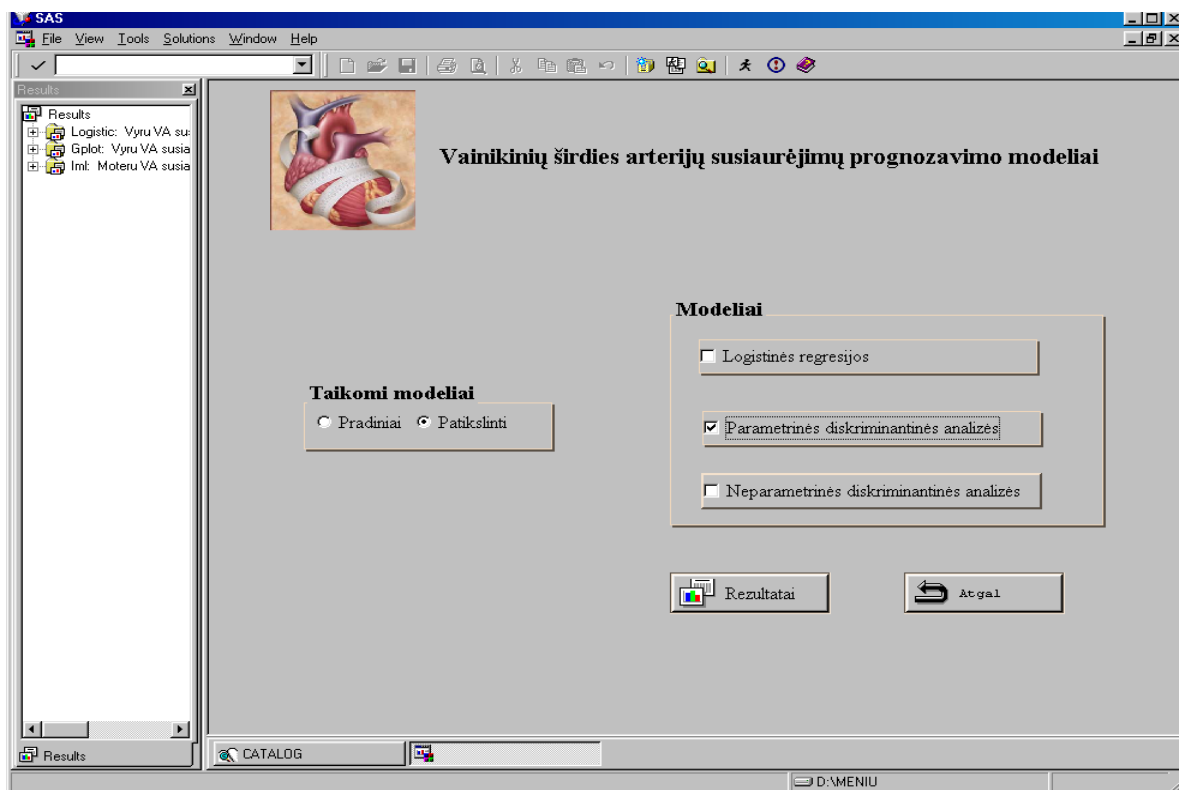
įrašė, duomenų bazėje yra, tuomet atsiranda pranešimas, kad pacientas rastas ir aktyvuojamas mygtukas „Prognozė“. Paspaudus šį mygtuką, atsiranda naujas langas (2.16 pav.), kuriame vartotojas paciento vainikinių arterijų susiaurėjimo įvertinimui ir prognozavimui gali pasirinkti sukurtus statistinės analizės modelius. Prognozavimui gali būti naudojami pradiniai arba patikslinti modeliai (jei atlikus modelių analizę jie buvo patikslinti). Jeigu paciento, identifikuojamo įvestu numeriu, duomenų bazėje nėra, tuomet atsiranda pranešimas, kad pacientas nerastas.



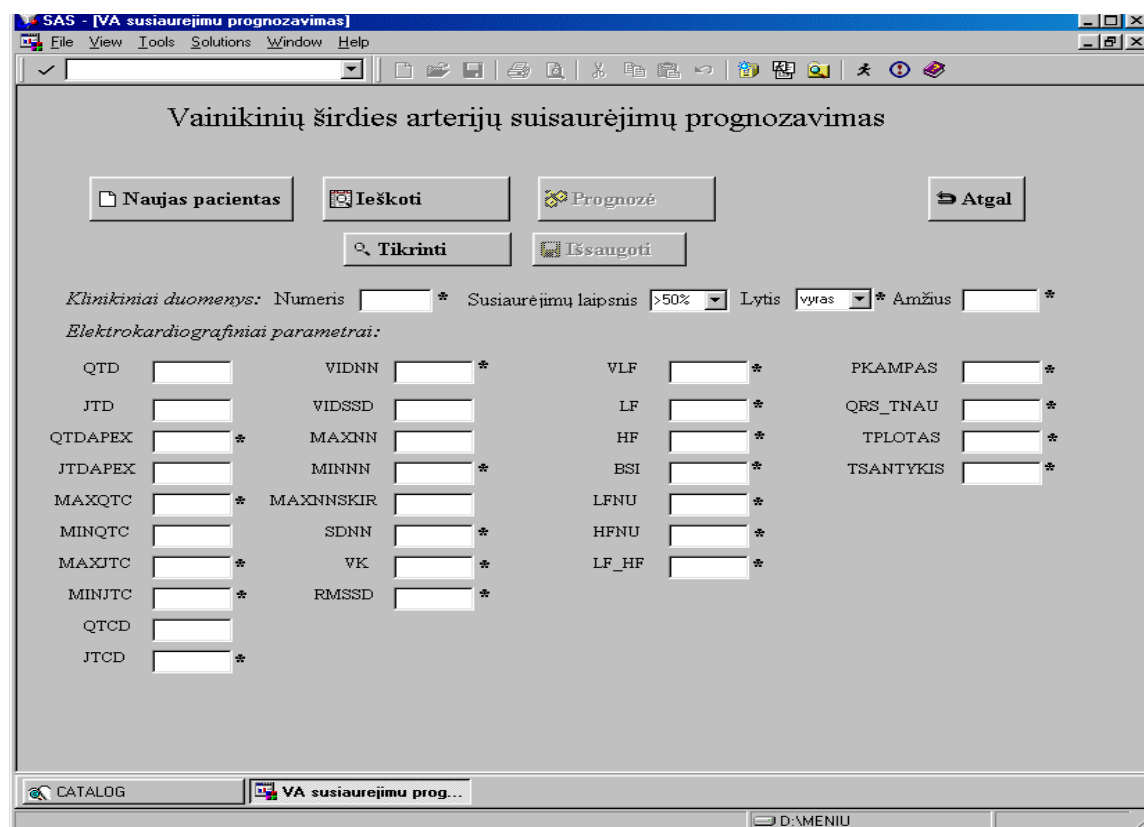
2.15 pav. Vartotojo sąsajos langas, skirtas paciento paieškai duomenų bazėje

Vartotojas paspaudęs mygtuką „Naujas pacientas“ gali prognozuoti vainikinių širdies arterijų susiaurėjimų reikšmingumą ir pacientui, kurio duomenų bazėje nėra (2.17 pav.). Norint atlikti prognozę pirmiausiai reikia įvesti tiriamo paciento klinikinius ir elektrokardiografinius duomenis. Modeliuose naudojami paciento duomenys pažymėti žvaigždutėmis, tai reiškia, kad norint atlikti prognozę juos būtina įvesti. Suvedus duomenis, reikia paspausti mygtuką „Tikrinti“, tuomet sistema patikrina, ar teisingai suvesti naujo paciento duomenys. Jeigu pacientas tokiu numeriu jau yra įrašytas į duomenų bazę, tuomet atsiranda atitinkamas pranešimas. Elektrokardiografinių parametrų reikšmės (išskyrus maksimalaus P vektoriaus kampo reikšmę) turi būti didesnės už nulį. Jeigu ši sąlyga neišpildoma arba neįvedamas modeliuose naudojamas parametras, tuomet paspaudus mygtuką „Tikrinti“ ekrane atsiranda pranešimas, apie klaidingai įvestą parametą. Jei duomenys suvesti teisingai, tuomet vartotojui pranešama, kad duomenys teisingi ir aktyvuojami mygtukai „Saugoti“ ir

„Prognozė“. Paspaudus mygtuką prognozė, atveriamas prognozavimui skirtas meniu langas (2.16 pav.). Jei vartotojas nori, kad jo suvesti paciento duomenys būtų įrašyti į duomenų bazę, reikia paspausti mygtuką „Saugoti“. Į pagrindinį meniu langą grįžtama paspaudus mygtuką „Atgal“. Darbas su vartotojo sąsaja baigiamas pagrindiniame lange (2.13 pav.) paspaudus mygtuką „Pabaiga“.



2.16 pav. Vartotojo sąsajos langas, kuriame realizuota sąsajos dalis skirta atskiro paciento vainikinių širdies arterijų susiaurėjimui prognozuoti



2.17 pav. Vartotojo sąsajos langas, kuriame įvedami nauji paciento duomenys

IŠVADOS

1. Atlikta išeminės širdies ligos ir vainikinių širdies arterijų susiaurėjimų tyrimuose taikomų metodų apžvalga ir nustatyta, kokie statistinės analizės metodai dažniausiai naudojami tokio tipo tyrimuose.

2. Panaudojus logistinės regresinės, parametrinės ir neparametrinės diskriminantinės analizės metodus sudaryti vainikinių širdies arterijų susiaurėjimų prognozavimo modeliai.

3. Panaudojus statistinės analizės sistemą SAS ir jos objektinio programavimo priemones, sudaryti modeliai realizuoti programiškai ir sukurta vainikinių širdies arterijų susiaurėjimų tyrimo sprendimų priėmimo paramos sistema. Sistemoje integruotos priemonės, kurios leidžia tikslinti pasiūlytų modelių parametrus, papildžius duomenų bazę naujais pacientų duomenimis.

4. Panaudojus sukurtus modelius, programines priemones ir Kauno medicinos universiteto klinikų Kardiologijos klinikos tyrimo duomenis, atlikta sudarytų statistinės analizės modelių lyginamoji analizė. Gauti šie pagrindiniai rezultatai:

- Vyrų širdies vainikinių arterijų susiaurėjimų reikšmingumą geriausiai prognozuoja neparametrinės diskriminantinės analizės modelis. Modelio bendras teisingo klasifikavimo procentas 90,58% (jautrumas 85,57%, specifiškumas 95,59%).
- Moterų širdies vainikinių arterijų susiaurėjimų reikšmingumą geriausiai prognozuoja parametrinės diskriminantinės analizės modelis. Modelio bendras teisingo klasifikavimo procentas 91,25% (jautrumas 90%, specifiškumas 92,5%).

Gauti rezultatai bus panaudoti išeminės širdies ligos ir vainikinių širdies arterijų susiaurėjimų diagnostikos, naudojant neinvazinius metodus, tobulinimui Kauno medicinos universiteto klinikų Kardiologijos klinikoje.

LITERATŪRA

1. Прикладная статистика: классификация и снижение размерности / С.А. Аивазян, В.М. Бухшгабер, И.С. Енюков, Л.Д. Мешалкин. Москва, „Финансы и статистика”, 1989. 607 с. ISBN 5-279-00054-X.
2. Aksomaitis A. Tikimybių teorija ir statistika. Kaunas, 2000. 346 p. ISBN 9986-13-893-0.
3. Astapenko D. Širdies vainikinių arterijų susiaurėjimo prognozavimas pagal elektrokardiogramos ir vektorkardiogramos parametrus / D. Astapenko, V. Janilionis, A. Matiukas // Matematika ir matematikos dėstyimas – 2004: konferencijos pranešimų medžiaga [Kaunas, 2004 m. balandžio 1, 2 d.]. Kaunas, 2004. p. 85-90.
4. Astapenko D. Širdies vainikinių arterijų susiaurėjimo prognozavimas pagal elektrokardiogramos ir vektorkardiogramos parametrus naudojant diskriminantinę analizę/ D. Astapenko, V. Janilionis, A. Matiukas // Taikomoji matematika: V studentų konferencijos pranešimų medžiaga [Kaunas, 2004 m. gegužės 8 d.]. Kaunas, 2004. p. 12-13.
5. Baršauskienė V. Studijų darbų parengimo tvarka/ V. Baršauskienė, I. Mačerinskienė, Kaunas, 2003. 79 p. ISBN 9955-09-064-2.
6. Computerized Approach for Revealing Coronary Artery Stenosis / A. Bastys, I. Bužaitė, J. Blužas, S. Kaminskienė, A. Matiukas, M. Tamošiūnaitė, G. Urbonavičienė, J.R. Vaišnys // Heart Disease: New Trends in Research, Diagnosis and Treatment, ed. A. Kimchi, Medimond Englewood. 2001, p. 375-379.
7. New Approach of Vector ECG Analysis for Revealing Coronary Artery Stenosis / A. Bastys, J. Blužas, S. Kaminskienė, R. Navickas, G. Urbonavičienė // Elektronika ir elektrotechnika. ISSN 1392-9631. 2004, nr. 2 (51), p.82-85.
8. Assessment of ambiguous coronary lesions by intravascular ultrasound / D. Baumgart, M. Haude, C.C. Birgelen, G. Gorge, R. Erbel // International Journal of Cardiovascular Intervention. 1999, No 2 (1), p. 3-12.
9. Бююль А. SPSS: искусство обработки информации. Анализ статистических данных и восстановление скрытых закономерностей / А. Бююль, П. Цефель. Масква, 2002. 608 с. ISBN 5-93772-032-6.
10. Čekanavičius V. Statistika ir jos taikymai / V. Čekanavičius, G. Murauskas. Vilnius, 2000. 240 p.; D.1. ISBN 9986-546-93-1.
11. Čekanavičius V. Statistika ir jos taikymai / V. Čekanavičius, G. Murauskas. Vilnius, 2002. 272 p.; D.2. ISBN 9955-491-16-7.
12. ST depression in ECG at entry indicates severe coronary lesions and large benefits of an early invasive treatment strategy in unstable coronary artery disease / E. Diderholm, B. Andrén, G.


- Frostfeldt, M. Genberg, T. Jernberg, B. Lagerqvist, B. Lindahl and L. Wallentin // *European Heart Journal*. 2002, No 23, p. 41–49.
13. The value of magnetocardiography in patients with and without relevant stenoses of the coronary arteries using an unshielded system / B. Hailer, I. Chaikovsky, S. Autheisenitz, H. Schafer, P. V. Leeuwen. *From Pacing and Clinical Electrophysiology [Interactive]*. 2005, Vol. 28, Is. 1 [cited 2005-02-01]. Available from internet: <<http://www.blackwell-synergy.com/toc/pace/28/1>>.
 14. Hair J. F. *Multivariate data analysis* / J. F. Hair, R. E. Anderson, R. L. Tatham, W. C. Black. 5th ed. Upper Saddle River, 1998. 730p. ISBN 0-13-930587-4.
 15. *Applied Multivariate Statistics with SAS Software*. Available from Internet: <<http://ftp.sas.com/samples/A56903>>.
 16. Jankauskienė D. Sveikatos sistemos reformos Lietuvoje 1990-1998 m. įvertinimas. Daktaro disertacija. *Biomedicinos mokslai. Visuomenės sveikata (10B)*. Vilnius 2000.
 17. Johnson R. A. *Applied multivariate statistical analysis*/ R. A. Johnson, D. W. Wichern. 5th ed. Upper Saddle River, 2002. 767 p. ISBN 0-13-121973-1.
 18. Kaminskienė S. Vainikinių arterijų susiaurėjimų nustatymo galimybės kompiuterinės EKG analizės metodais, ligoniams, sergantiems išemine širdies liga. Daktaro disertacija. *Biomedicinos mokslai. Medicina (07 B)*. Kaunas 2004.
 19. Correlation between T Loop Morphology and Coronary Artery Stenosis/ S. Kaminskienė, D. Astapenko, V. Janilionis, G. Urbonavičienė, A. Janavičius, A. Matiukas // *Analysis of Biomedical Signals and Images: 17th International Eurasip Conference Biosignal 2004 proceedings [Brno, May 2004]* . Brno, 2004. p. 176-178.
 20. Kruopis J. *Matematinė statistika*. Vilnius, 1993. 411 p. ISBN 5-420-01015-1.
 21. Kubilius J. *Tikimybių teorija ir matematinė statistika*. Vilnius, 1996. 439 p. ISBN 9986-19-177-7.
 22. Kusuoka H., Hoffman J.I.E. Advice on Statistical Analysis for Circulation Research // *Circulation Research* 2002, No. 91, p. 662-671.
 23. Computer-aided diagnosis of coronary artery disease by means of Stress ECG / R. B.Luesma, J. M. Gascón, S. O. Gasso, P. Serrano, J. G. Moros, A. del Río, I.J. Ferreira, P. L. Lasaosa // *First international congress on computational bioengineering*. Zaragoza. 2003. p. 219-224. Available from Internet: < http://diec.unizar.es/~rbailon/publicaciones_personales.php >.
 24. Comparison of Coronary Angiographic and ECG Diagnostic Methods for Ischemic heart Disease Patients / A. Matiukas, S. Kaminskienė, V. Jurkonis, L. Gargasas, J. Blužas, J. Kornej, R. Vaišnys, M. Tamošiūnaitė // *Elektronika ir elektrotechnika*. ISSN 1392-1215. 2002, nr. 3 (38), p.15-17.

25. Vektorkardiografijos reikšmė nustatant širdies vainikinių arterijų susiaurėjimus/ A. Matiukas, S. Kaminskienė, S. Rūtienė, G. Jaruševičius, L. Gargasas, *Elektrika ir elektrotechnika*. 2003, nr. 48(6), p. 74-77.
26. The preoperative ECG in day surgery: a habit? / C. J. Murdoch, D.R. Murdoch., P. McIntyre, H. Hosie, C Clark // *Anaesthesia*. 1999, No 54, p. 899-908.
27. Limited value of the resting electrocardiogram in assessing patients with recent onset chest pain: lessons from a chest pain clinic / M. Norell, D. Lythall, G. Coghlan, A. Cheng, S. Kushwaha, J. Swan, C. Iisly, A. Mitchell // *British Heart Journal*.1992, No 67, p 53-56.
28. QT Interval Dispersion Analysis in Patients with Aortic Valve Stenosis: A Prospective Study / E. Orłowska-Baranowska, R. Baranowski, D. Zakrzewski, B. Kusmierczyk, I.Rawczynska-Englert // *Heart Valve Disease*. 2003, Vol. 12. No. 3, p. 319-324.
29. The value of ECG and echocardiography during stress testing for identifying systemic endothelial dysfunction and epicardial artery stenosis / A. Pálincás, E. Tóth, R. Amyot, F. Rigo, L. Venneri, E. Picano // *European Heart Journal*. 2002, No 23, p. 1587–1595.
30. Petrauskiene J., Kalediene R. Lietuvos gyventojų mirtingumo pokyčiai per pirmąjį Nepriklausomybės dešimtmetį. *Medicina* 2003 39 t. Nr. 8: p. 788–796.
31. The SAS System OnlineDOC [CD-ROM]. Cary, NC, USA, SAS Institute 2000.
32. Stalioraitytė E., Pangonytė D. Kardialinė patologija // *Lithuanian Journal of Cardiology*. 1997, p. 95-98.

1 PRIEDAS

DARBE NAUDOJAMŲ KLINIKINIŲ IR ELKTROKARDIOGRAFINIŲ PARAMETRŲ SANTRUMPOS

- $X^{(0)}$ – grupė,
 $X^{(1)}$ – lytis,
 $X^{(2)}$ – amžius,
 $X^{(3)}$ (QTD) – QT intervalo dispersija, kai QT intervalas išmatuotas galūnių derivacijose,
 $X^{(4)}$ (JTD) – JT intervalo dispersija, kai JT intervalas išmatuotas galūnių derivacijose,
 $X^{(5)}$ (QTDAPEX) – QT intervalo dispersija, kai QT intervalas išmatuotas krūtinės derivacijose,
 $X^{(6)}$ (JTDAPEX) – JT intervalo dispersija, kai JT intervalas išmatuotas krūtinės derivacijose,
 $X^{(7)}$ (MAXQTC) – maksimali koreguoto QT intervalo trukmė,
 $X^{(8)}$ (MINQTC) – minimali koreguoto QT intervalo trukmė,
 $X^{(9)}$ (MAXJTC) – maksimali koreguoto JT intervalo trukmė,
 $X^{(10)}$ (MINJTC) – minimali koreguoto JT intervalo trukmė,
 $X^{(11)}$ (QTCD) – koreguoto QT intervalo dispersija,
 $X^{(12)}$ (JTCD) – koreguoto JT intervalo dispersija,
 $X^{(13)}$ (VIDNN) – vidutinis širdies susitraukimų dažnis,
 $X^{(14)}$ (VIDSSD) – vidutinė RR intervalo trukmė,
 $X^{(15)}$ (MAXNN) – maksimali RR intervalo trukmė,
 $X^{(16)}$ (MINNN) – minimali RR intervalo trukmė,
 $X^{(17)}$ (MAXNNSKIR) – maksimalus RR intervalų skirtumas,
 $X^{(18)}$ (SDNN) – standartinis RR intervalo nuokrypis,
 $X^{(19)}$ (VK) – variacijos koeficientas,
 $X^{(20)}$ (RMSSD) – skirtumų tarp gretimų RR intervalų vidurkių kvadratų sumos kvadratinė šaknis,
 $X^{(21)}$ (VLF) – labai žemų dažnių spektrinė komponentė,
 $X^{(22)}$ (LF) – žemų dažnių spektrinė komponentė,
 $X^{(23)}$ (HF) – aukštų dažnių spektrinė komponentė,
 $X^{(24)}$ (BSI) – bendras spektrinis intensyvumas,
 $X^{(25)}$ (LFNU) – normalizuota žemų dažnių komponentė,
 $X^{(26)}$ (HFNU) – normalizuota aukštų dažnių komponentė,
 $X^{(27)}$ (LF_HF) – normalizuotos žemų dažnių komponentės ir normalizuotos aukštų dažnių komponentės santykis,
 $X^{(28)}$ (PKAMPAS) – maksimalaus P vektoriaus kampas,
 $X^{(29)}$ (QRS_TNAU) – kampas tarp maksimalių QRS ir T vektorių,
 $X^{(30)}$ (TPLOTAS) – T kilpos plotas,
 $X^{(31)}$ (TSANTYK) – T kilpos ploto ir ilgio santykis.



2 PRIEDAS

APRAŠOMOSIOS STATISTIKOS REZULTATAI

Vyru imties skaitinės charakteristikos

Kintamasis	Vidurkis	Standartinis nuokrypis	Pirmasis kvartilis	Mediana	Trečiasis kvartilis	Minimumas	Maksimumas
$X^{(2)}$	57.23	10.26	49.00	58.00	65.00	32.00	81.00
$X^{(3)}$	34.00	12.35	25.00	32.00	43.00	11.00	77.00
$X^{(4)}$	35.02	13.42	27.00	33.00	42.00	10.00	85.00
$X^{(5)}$	21.79	11.42	14.00	20.00	28.00	4.00	61.00
$X^{(6)}$	22.88	12.02	14.00	21.00	30.00	1.00	62.00
$X^{(7)}$	423.59	20.37	410.00	421.00	432.00	388.00	503.00
$X^{(8)}$	387.65	21.79	372.00	387.00	399.00	282.00	461.00
$X^{(9)}$	334.52	20.11	320.00	332.00	346.00	298.00	408.00
$X^{(10)}$	298.10	21.08	284.00	295.00	311.00	228.00	378.00
$X^{(11)}$	35.95	15.12	26.00	34.00	43.00	11.00	138.00
$X^{(12)}$	36.41	13.86	27.00	35.00	44.00	10.00	84.00
$X^{(13)}$	920.50	132.46	814.00	935.00	1013.00	570.00	1176.00
$X^{(14)}$	66.13	10.36	59.00	64.00	73.00	51.00	105.00
$X^{(15)}$	1006.53	148.52	906.00	1014.00	1118.00	610.00	1306.00
$X^{(16)}$	809.81	124.29	716.00	808.00	904.00	420.00	1100.00
$X^{(17)}$	5.19	0.43	4.96	5.17	5.52	3.58	5.99
$X^{(18)}$	30.90	12.91	21.40	29.20	38.10	6.80	70.10
$X^{(19)}$	3.33	1.26	2.41	3.04	3.95	0.87	7.34
$X^{(20)}$	20.08	11.64	12.00	16.50	25.50	4.30	66.50
$X^{(21)}$	531.82	686.19	163.60	300.40	593.70	11.40	5251.70
$X^{(22)}$	172.65	363.33	41.80	85.70	188.60	4.00	4088.00
$X^{(23)}$	65.81	94.89	13.70	33.70	76.40	0.90	686.50
$X^{(24)}$	1928.67	1939.22	707.69	1318.80	2202.30	93.81	9727.48
$X^{(25)}$	60.68	19.14	46.21	63.15	76.44	11.37	94.16
$X^{(26)}$	39.30	19.16	23.51	36.85	53.79	5.84	88.63
$X^{(27)}$	2.46	2.42	0.86	1.71	3.25	0.13	16.12
$X^{(28)}$	40.63	22.78	30.00	47.00	57.00	-28.00	75.00
$X^{(29)}$	33.67	35.56	9.00	21.00	45.00	0.00	180.00

$X^{(30)}$	202.73	60.83	154.00	208.00	247.00	60.00	320.00
$X^{(31)}$	1.40	0.78	0.87	1.29	1.91	0.02	3.41

Vyrų imties skaitinės charakteristikos atskirose grupėse

Grupė	Pacientų skaičius	Kintamasis	Vidurkis	Standartinis nuokrypis	Pirmasis kvartilis	Mediana	Trečiasis kvartilis	Minimumas	Maksimumas
0	68	$X^{(2)}$	54.28	10.49	47.00	54.00	60.50	32.00	76.00
		$X^{(3)}$	34.31	12.11	25.00	33.00	43.00	13.00	62.00
		$X^{(4)}$	34.84	12.94	24.00	35.50	41.00	15.00	77.00
		$X^{(5)}$	21.38	10.33	14.00	19.00	27.00	6.00	53.00
		$X^{(6)}$	22.32	10.82	13.00	20.00	29.50	7.00	53.00
		$X^{(7)}$	422.00	20.73	408.00	420.00	432.00	390.00	503.00
		$X^{(8)}$	385.09	24.12	369.50	386.00	396.50	282.00	461.00
		$X^{(9)}$	332.88	20.15	318.00	330.00	343.50	298.00	408.00
		$X^{(10)}$	296.87	20.51	282.00	294.00	309.00	261.00	378.00
		$X^{(11)}$	36.91	17.64	26.00	34.50	43.00	13.00	138.00
		$X^{(12)}$	36.01	13.34	25.00	34.50	43.50	15.00	84.00
		$X^{(13)}$	926.85	139.32	816.50	925.50	1048.00	570.00	1163.00
		$X^{(14)}$	65.76	10.90	56.50	64.50	73.00	51.00	105.00
		$X^{(15)}$	1011.85	151.07	903.00	1003.00	1125.00	610.00	1306.00
		$X^{(16)}$	810.97	117.12	715.00	802.00	907.00	530.00	1036.00
		$X^{(17)}$	5.22	0.42	4.92	5.26	5.53	4.09	5.98
		$X^{(18)}$	31.59	12.83	21.45	29.60	39.95	11.10	69.10
		$X^{(19)}$	3.38	1.18	2.50	3.19	4.01	1.23	7.34
		$X^{(20)}$	20.18	10.75	11.40	16.55	26.25	6.90	48.50
		$X^{(21)}$	551.03	700.80	121.00	283.70	584.60	31.30	3604.40
		$X^{(22)}$	212.30	516.24	40.80	88.65	221.60	10.30	4088.00
		$X^{(23)}$	62.79	73.26	13.65	40.95	77.20	2.50	445.90
		$X^{(24)}$	2105.21	2189.87	669.24	1207.25	2608.44	139.25	9727.48
		$X^{(25)}$	61.98	17.85	50.06	62.54	76.89	25.49	94.16
		$X^{(26)}$	38.02	17.85	23.11	37.47	49.95	5.84	74.51
		$X^{(27)}$	2.68	2.94	1.01	1.67	3.33	0.34	16.12
		$X^{(28)}$	39.91	22.59	30.00	45.50	55.50	-28.00	75.00
		$X^{(29)}$	28.04	26.93	9.00	20.00	38.50	0.00	136.00

		$X^{(30)}$	198.74	59.86	151.50	203.00	239.00	60.00	302.00
		$X^{(31)}$	1.33	0.71	0.86	1.20	1.90	0.02	2.93
1	97	$X^{(2)}$	59.30	9.63	53.00	59.00	66.00	40.00	81.00
		$X^{(3)}$	33.78	12.57	25.00	32.00	42.00	11.00	77.00
		$X^{(4)}$	35.14	13.81	27.00	32.00	44.00	10.00	85.00
		$X^{(5)}$	22.08	12.16	13.00	20.00	28.00	4.00	61.00
		$X^{(6)}$	23.27	12.83	14.00	21.00	31.00	1.00	62.00
		$X^{(7)}$	424.71	20.16	411.00	422.00	438.00	388.00	482.00
		$X^{(8)}$	389.44	19.93	375.00	388.00	403.00	348.00	457.00
		$X^{(9)}$	335.66	20.10	322.00	333.00	347.00	302.00	394.00
		$X^{(10)}$	298.97	21.53	285.00	296.00	313.00	228.00	365.00
		$X^{(11)}$	35.27	13.13	26.00	33.00	42.00	11.00	76.00
		$X^{(12)}$	36.69	14.28	28.00	35.00	44.00	10.00	82.00
		$X^{(13)}$	916.04	127.98	814.00	936.00	998.00	628.00	1176.00
		$X^{(14)}$	66.38	10.02	60.00	64.00	73.00	51.00	95.00
		$X^{(15)}$	1002.80	147.37	906.00	1016.00	1116.00	664.00	1292.00
		$X^{(16)}$	808.99	129.67	716.00	810.00	896.00	420.00	1100.00
		$X^{(17)}$	5.18	0.44	4.97	5.16	5.45	3.58	5.99
		$X^{(18)}$	30.42	13.02	21.40	28.50	35.40	6.80	70.10
		$X^{(19)}$	3.30	1.32	2.29	2.96	3.86	0.87	7.08
		$X^{(20)}$	20.02	12.28	12.20	16.50	25.40	4.30	66.50
		$X^{(21)}$	518.35	679.10	176.60	322.60	596.60	11.40	5251.70
		$X^{(22)}$	144.86	193.97	44.20	85.70	166.60	4.00	1341.30
		$X^{(23)}$	67.93	107.82	14.10	29.80	76.40	0.90	686.50
		$X^{(24)}$	1804.91	1743.53	797.45	1350.12	2054.77	93.81	8989.71
		$X^{(25)}$	59.77	20.04	42.93	65.05	75.05	11.37	91.85
		$X^{(26)}$	40.20	20.06	23.51	34.95	57.07	8.15	88.63
		$X^{(27)}$	2.31	1.98	0.75	1.86	3.25	0.13	11.27
		$X^{(28)}$	41.13	23.01	30.00	47.00	58.00	-26.00	74.00
		$X^{(29)}$	37.61	40.20	9.00	25.00	49.00	0.00	180.00
		$X^{(30)}$	205.53	61.65	158.00	211.00	258.00	77.00	320.00
		$X^{(31)}$	1.45	0.83	0.87	1.51	2.00	0.10	3.41

Moterų imties skaitinės charakteristikos









Kintamasis	Vidurkis	Standartinis nuokrypis	Pirmasis kvartilis	Mediana	Trečiasis kvartilis	Minimumas	Maksimumas
$X^{(2)}$	63.80	7.69	58.00	64.50	70.00	45.00	81.00
$X^{(3)}$	28.43	8.88	21.00	27.00	35.00	15.00	48.00
$X^{(4)}$	33.01	10.57	26.00	32.00	39.00	12.00	56.00
$X^{(5)}$	20.10	7.85	15.00	19.50	26.00	4.00	39.00
$X^{(6)}$	22.69	10.64	15.00	20.50	28.00	4.00	49.00
$X^{(7)}$	426.91	16.76	415.00	427.00	437.00	396.00	468.00
$X^{(8)}$	397.20	17.96	383.00	399.50	410.00	358.00	430.00
$X^{(9)}$	343.24	16.72	334.00	343.00	353.00	305.00	391.00
$X^{(10)}$	308.83	16.11	296.00	310.50	319.00	274.00	343.00
$X^{(11)}$	29.71	9.38	22.00	28.50	38.00	17.00	51.00
$X^{(12)}$	34.41	10.99	25.00	32.00	43.00	12.00	60.00
$X^{(13)}$	910.81	124.66	812.00	899.50	990.00	695.00	1140.00
$X^{(14)}$	66.61	9.09	60.00	66.50	73.00	52.00	86.00
$X^{(15)}$	987.71	142.13	868.00	965.00	1080.00	732.00	1268.00
$X^{(16)}$	817.71	136.20	736.00	809.00	914.00	302.00	1064.00
$X^{(17)}$	5.04	0.43	4.70	5.02	5.39	4.30	6.49
$X^{(18)}$	28.01	13.09	18.30	25.60	34.40	13.10	93.20
$X^{(19)}$	3.05	1.25	2.07	2.80	3.70	1.43	8.78
$X^{(20)}$	18.99	10.63	12.20	16.05	22.80	6.70	51.50
$X^{(21)}$	418.73	614.15	137.60	269.95	401.40	43.70	4673.80
$X^{(22)}$	89.33	97.28	26.40	50.65	119.50	7.80	441.50
$X^{(23)}$	80.74	139.36	15.20	39.90	91.70	2.00	896.70
$X^{(24)}$	1376.12	1191.07	572.41	888.68	1906.80	263.19	6079.02
$X^{(25)}$	53.59	20.89	35.93	54.40	69.63	12.47	89.60
$X^{(26)}$	46.41	20.89	30.37	45.61	64.07	10.40	87.53
$X^{(27)}$	1.88	1.90	0.56	1.19	2.29	0.14	8.62
$X^{(28)}$	41.50	24.56	30.00	49.00	59.00	-39.00	77.00
$X^{(29)}$	31.20	28.54	10.00	23.50	41.00	0.00	134.00
$X^{(30)}$	176.63	61.16	130.00	171.50	224.00	75.00	308.00
$X^{(31)}$	1.08	0.78	0.47	0.98	1.48	0.05	3.12









Moterų imtie skaitinės charakteristikos atskirose grupėse









Grup	Pacient skaičius	Kintamasis	Vidurkis	Standartinis nuokrypis	Pirmasis kvartilis	Mediana	Trečiasis kvartilis	Minimumas	Maksimumas
0	40	$X^{(2)}$	63.73	7.09	57.50	66.00	68.50	49.00	77.00
		$X^{(3)}$	26.60	7.53	20.00	25.50	33.50	16.00	44.00
		$X^{(4)}$	31.90	10.20	24.50	31.50	38.00	12.00	56.00
		$X^{(5)}$	18.45	7.13	13.00	18.50	21.00	4.00	39.00
		$X^{(6)}$	20.53	10.09	14.50	18.00	24.50	6.00	49.00
		$X^{(7)}$	427.68	16.55	415.50	427.50	436.50	396.00	468.00
		$X^{(8)}$	399.80	16.27	389.00	401.50	410.50	358.00	429.00
		$X^{(9)}$	346.55	16.08	337.50	346.50	355.00	319.00	391.00
		$X^{(10)}$	313.38	15.25	304.00	316.50	321.50	274.00	343.00
		$X^{(11)}$	27.88	8.34	20.50	26.00	34.50	17.00	44.00
		$X^{(12)}$	33.18	10.48	25.00	32.00	40.50	12.00	59.00
		$X^{(13)}$	915.73	132.43	812.00	922.50	1038.50	695.00	1140.00
		$X^{(14)}$	66.40	9.72	57.50	64.50	73.00	52.00	86.00
		$X^{(15)}$	990.65	150.18	863.00	995.00	1138.00	732.00	1250.00
		$X^{(16)}$	828.60	123.10	747.00	813.00	914.00	600.00	1058.00
		$X^{(17)}$	5.00	0.41	4.69	5.02	5.38	4.36	5.91
		$X^{(18)}$	27.69	15.05	16.35	25.00	36.25	13.80	93.20
		$X^{(19)}$	2.98	1.38	2.02	2.74	3.54	1.43	8.78
		$X^{(20)}$	18.59	10.82	10.25	15.70	23.80	6.70	47.90
		$X^{(21)}$	492.16	765.22	151.05	286.45	423.45	44.10	4673.80
		$X^{(22)}$	79.64	98.51	24.80	36.00	96.70	7.80	441.50
		$X^{(23)}$	72.62	123.22	12.80	35.10	67.10	2.00	629.20
		$X^{(24)}$	1339.34	1201.20	534.58	801.18	1913.37	263.19	6079.02
		$X^{(25)}$	53.66	21.68	40.33	51.11	70.87	12.47	88.78
		$X^{(26)}$	46.34	21.68	29.14	48.90	59.67	11.22	87.53
		$X^{(27)}$	1.96	2.00	0.68	1.06	2.44	0.14	7.91
		$X^{(28)}$	44.68	21.46	30.00	51.00	60.50	-16.00	77.00
		$X^{(29)}$	28.70	26.64	13.00	22.50	35.00	0.00	134.00
		$X^{(30)}$	181.85	65.49	124.00	183.00	236.00	75.00	308.00
		$X^{(31)}$	1.10	0.78	0.38	1.02	1.76	0.05	3.01
		1	30	$X^{(2)}$	63.90	8.55	59.00	63.00	70.00
$X^{(3)}$	30.87			10.02	21.00	30.00	40.00	15.00	48.00







$X^{(4)}$	34.50	11.05	26.00	32.00	42.00	18.00	56.00
$X^{(5)}$	22.30	8.34	17.00	23.00	28.00	5.00	37.00
$X^{(6)}$	25.57	10.85	18.00	25.50	33.00	4.00	47.00
$X^{(7)}$	425.90	17.28	407.00	427.00	442.00	397.00	463.00
$X^{(8)}$	393.73	19.73	378.00	391.50	409.00	363.00	430.00
$X^{(9)}$	338.83	16.80	326.00	339.00	353.00	305.00	370.00
$X^{(10)}$	302.77	15.44	289.00	305.50	313.00	276.00	333.00
$X^{(11)}$	32.17	10.24	22.00	32.00	40.00	18.00	51.00
$X^{(12)}$	36.07	11.61	28.00	35.50	44.00	19.00	60.00
$X^{(13)}$	904.27	115.37	819.00	881.00	980.00	719.00	1140.00
$X^{(14)}$	66.90	8.34	61.00	67.50	73.00	52.00	83.00
$X^{(15)}$	983.80	133.06	880.00	956.00	1034.00	766.00	1268.00
$X^{(16)}$	803.20	152.89	700.00	807.00	886.00	302.00	1064.00
$X^{(17)}$	5.08	0.47	4.72	5.04	5.45	4.30	6.49
$X^{(18)}$	28.44	10.13	19.40	28.30	34.40	13.10	55.00
$X^{(19)}$	3.16	1.08	2.26	3.18	3.89	1.57	5.63
$X^{(20)}$	19.54	10.52	13.30	17.90	22.00	7.30	51.50
$X^{(21)}$	320.82	304.29	130.70	266.80	401.40	43.70	1702.10
$X^{(22)}$	102.25	95.71	37.30	78.80	137.40	8.10	436.60
$X^{(23)}$	91.57	159.94	24.20	61.30	99.30	3.71	896.70
$X^{(24)}$	1425.15	1196.10	572.41	1011.01	1906.80	398.86	5432.95
$X^{(25)}$	53.49	20.16	34.07	57.11	69.63	19.36	89.60
$X^{(26)}$	46.51	20.16	30.37	42.90	65.93	10.40	80.64
$X^{(27)}$	1.77	1.79	0.52	1.34	2.29	0.24	8.62
$X^{(28)}$	37.27	27.99	25.00	46.50	55.00	-39.00	70.00
$X^{(29)}$	34.53	31.05	8.00	29.00	52.00	1.00	124.00
$X^{(30)}$	169.67	55.19	130.00	159.50	210.00	75.00	281.00
$X^{(31)}$	1.05	0.79	0.49	0.82	1.37	0.10	3.12

Vyrų imties parametrų skaitinių charakteristikų atskirose grupėse stačiakampės diagramos.























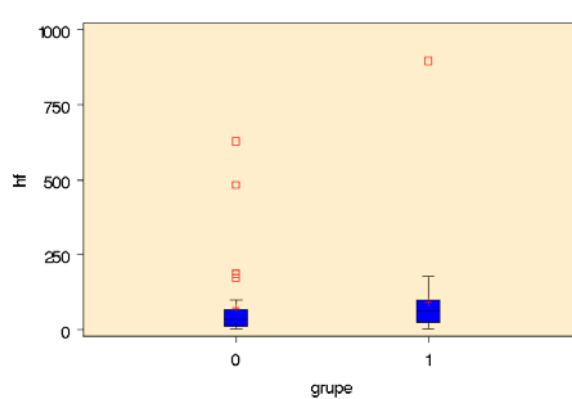















Moterų imties parametrų skaitinių charakteristikų atskirose grupėse stačiakampės diagramos.









3 PRIEDAS

LOGISTINĖS REGRESIJOS MODELIO TAIKYMO REZULTATAI

Logistinės regresijos modelio, skirto vyrų populiacijos tyrimui, rezultatai

Model Information		
Data Set	WORK.DUOM_V_N ORM	
Response Variable	GRUPE	grupe
Number of Response Levels	2	
Number of Observations	165	
Model	binary logit	
Optimization Technique	Fisher's scoring	

Response Profile		
Ordered Value	GRUPE	Total Frequency
1	1	97
2	0	68

Model Fit Statistics		
Criterion	Intercept Only	Intercept and Covariates
AIC	225.615	214.710
SC	228.721	264.405
-2 Log L	223.615	182.710

R-Square	0.2196	Max-rescaled R-Square	0.2959
----------	--------	-----------------------	--------

Testing Global Null Hypothesis: BETA=0			
Test	Chi-Square	DF	Pr > ChiSq
Likelihood Ratio	40.9051	15	0.0003
Score	33.8890	15	0.0035
Wald	27.9685	15	0.0218

Analysis of Maximum Likelihood Estimates						
Parameter	DF	Estimate	Standard Error	Wald Chi-Square	Pr > ChiSq	Exp(Est)
Intercept	1	42969.8	35804.0	1.4403	0.2301	I
AMZIUS	1	0.0661	0.0204	10.4924	0.0012	1.068
VIDNN	1	-0.0289	0.00900	10.3402	0.0013	0.971
MINNN	1	0.0118	0.00585	4.0823	0.0433	1.012
SDNN	1	4.9803	1.9277	6.6748	0.0098	145.525
VK	1	-13.5009	5.1633	6.8371	0.0089	0.000
RMSSD	1	1.6725	0.9785	2.9216	0.0874	5.326
VLF	1	1.2618	0.3545	12.6656	0.0004	3.532
LF	1	0.6686	0.4667	2.0518	0.1520	1.951
HF	1	-0.5562	0.3856	2.0808	0.1492	0.573
BSI	1	-0.00078	0.000258	9.1575	0.0025	0.999
LFNU	1	-429.7	358.0	1.4406	0.2300	0.000
HFNU	1	-429.9	358.0	1.4414	0.2299	0.000
LF_HF	1	-3.3906	1.7476	3.7639	0.0524	0.034
QRS_TNAU	1	0.00827	0.00622	1.7696	0.1834	1.008
TSANTYK	1	0.3561	0.2431	2.1460	0.1429	1.428

Odds Ratio Estimates			
Effect	Point Estimate	95% Wald Confidence Limits	
AMZIUS	1.068	1.026	1.112
VIDNN	0.971	0.954	0.989
MINNN	1.012	1.000	1.024
SDNN	145.525	3.327	>999.999
VK	<0.001	<0.001	0.034
RMSSD	5.326	0.782	36.248
VLF	3.532	1.763	7.076
LF	1.951	0.782	4.871
HF	0.573	0.269	1.221
BSI	0.999	0.999	1.000
LFNU	<0.001	<0.001	>999.999
HFNU	<0.001	<0.001	>999.999
LF_HF	0.034	0.001	1.035

Odds Ratio Estimates			
Effect	Point Estimate	95% Wald Confidence Limits	
QRS_TNAU	1.008	0.996	1.021
TSANTYK	1.428	0.887	2.299


Association of Predicted Probabilities and Observed Responses			
Percent Concordant	76.2	Somers' D	0.526
Percent Discordant	23.6	Gamma	0.527
Percent Tied	0.3	Tau-a	0.256
Pairs	6596	c	0.763

Partition for the Hosmer and Lemeshow Test					
Group	Total	GRUPE = 1		GRUPE = 0	
		Observed	Expected	Observed	Expected
1	17	2	2.74	15	14.26
2	17	5	4.95	12	12.05
3	18	8	7.36	10	10.64
4	17	13	9.40	4	7.60
5	17	7	10.59	10	6.41
6	17	13	11.56	4	5.44
7	17	12	12.37	5	4.63
8	17	12	13.24	5	3.76
9	17	14	14.24	3	2.76
10	11	11	10.40	0	0.60

Hosmer and Lemeshow Goodness-of-Fit Test		
Chi-Square	DF	Pr > ChiSq
8.4270	8	0.3929

Prob Level	Correct		Incorrect		Percentages				
	Event	Non-Event	Event	Non-Event	Correct	Sensi - tivity	Speci - ficity	False POS	False NEG
0.500	76	36	32	21	65.6	78.4	52.9	37.5	29.0

ROC Curve



Logistinės regresijos modelio, skirto moterų populiacijos tyrimui, rezultatai

Model Information		
Data Set	WORK.DUOM_M_N ORM	
Response Variable	GRUPE	grupe
Number of Response Levels	2	
Number of Observations	70	
Model	binary logit	
Optimization Technique	Fisher's scoring	

Response Profile		
Ordered Value	GRUPE	Total Frequency
1	1	30
2	0	40

Model Fit Statistics		
Criterion	Intercept Only	Intercept and Covariates
AIC	97.607	85.047
SC	99.856	107.532
-2 Log L	95.607	65.047

R-Square	0.3538	Max-rescaled R-Square	0.4749
----------	--------	-----------------------	--------

Testing Global Null Hypothesis: BETA=0			
Test	Chi-Square	DF	Pr > ChiSq
Likelihood Ratio	30.5604	9	0.0004
Score	24.4053	9	0.0037
Wald	15.5830	9	0.0761

Analysis of Maximum Likelihood Estimates						
Parameter	DF	Estimate	Standard Error	Wald Chi-Square	Pr > ChiSq	Exp(Est)
Intercept	1	-7.6767	9.2991	0.6815	0.4091	0.000
JTDAPEX	1	0.5492	0.3882	2.0014	0.1572	1.732
MAXQTC	1	0.1256	0.0426	8.7076	0.0032	1.134
MINJTC	1	-0.1391	0.0424	10.7799	0.0010	0.870
JTCD	1	-0.0859	0.0455	3.5628	0.0591	0.918
VLF	1	-0.9512	0.5034	3.5711	0.0588	0.386
LF	1	1.2071	0.4489	7.2304	0.0072	3.344
PKAMPAS	1	-0.0358	0.0159	5.0900	0.0241	0.965
QRS_TNAU	1	0.0125	0.0110	1.2975	0.2547	1.013
TPLOTAS	1	-0.00805	0.00579	1.9343	0.1643	0.992

Odds Ratio Estimates			
Effect	Point Estimate	95% Wald Confidence Limits	
JTDAPEX	1.732	0.809	3.707
MAXQTC	1.134	1.043	1.232
MINJTC	0.870	0.801	0.945
JTCD	0.918	0.839	1.003
VLF	0.386	0.144	1.036
LF	3.344	1.387	8.060
PKAMPAS	0.965	0.935	0.995
QRS_TNAU	1.013	0.991	1.035
TPLLOTAS	0.992	0.981	1.003


Association of Predicted Probabilities and Observed Responses			
Percent Concordant	87.2	Somers' D	0.744
Percent Discordant	12.8	Gamma	0.745
Percent Tied	0.1	Tau-a	0.370
Pairs	1200	c	0.872

Partition for the Hosmer and Lemeshow Test					
Group	Total	GRUPE = 1		GRUPE = 0	
		Observed	Expected	Observed	Expected
1	7	1	0.16	6	6.84
2	7	0	0.60	7	6.40
3	7	0	1.21	7	5.79
4	7	1	1.63	6	5.37
5	7	2	2.24	5	4.76
6	7	4	3.11	3	3.89
7	7	4	3.81	3	3.19
8	7	7	4.81	0	2.19
9	7	5	5.79	2	1.21
10	7	6	6.65	1	0.35

Hosmer and Lemeshow Goodness-of-Fit Test		
Chi-Square	DF	Pr > ChiSq
12.4642	8	0.1317

Prob Level	Correct		Incorrect		Percentages				
	Event	Non-Event	Event	Non-Event	Correct	Sensitivity	Specificity	False POS	False NEG
0.500	19	33	7	11	72.9	63.3	82.5	21.6	30.8

ROC Curve



4 PRIEDAS

PARAMETRINĒS DISKRIMINANTINĒS ANALIZĒS MODELIO TAIKUMO REZULTATAI

Vyrų imties parametrų atskirose grupėse suderinamumo hipotezių tikrinimo rezultatai

Grup	Parametras	Statistikos reikšm	<i>p</i> reikšm
0	AMZIUS	0.98820	0.77188
1	AMZIUS	0.98616	0.40567
0	BSI	0.76380	0.00000
1	BSI	0.73845	0.00000
0	HF	0.71102	0.00000
1	HF	0.56923	0.00000
0	HFNU	0.97564	0.20376
1	HFNU	0.94504	0.00050
0	JTCD	0.93836	0.00223
1	JTCD	0.95233	0.00145
0	JTD	0.94252	0.00355
1	JTD	0.95338	0.00170
0	JTDAPEX	0.93913	0.00243
1	JTDAPEX	0.94267	0.00035
0	LF	0.32369	0.00000
1	LF	0.61461	0.00000
0	LF_HF	0.68667	0.00000
1	LF_HF	0.85093	0.00000
0	LFNU	0.97564	0.20376
1	LFNU	0.94543	0.00052
0	MAXJTC	0.94247	0.00353
1	MAXJTC	0.96575	0.01234
0	MAXNN	0.98670	0.68639
1	MAXNN	0.98059	0.16166
0	MAXNNSKIR	0.95846	0.02345
1	MAXNNSKIR	0.94938	0.00093
0	MAXQTC	0.89314	0.00003
1	MAXQTC	0.97015	0.02611
0	MINJTC	0.93863	0.00230
1	MINJTC	0.98496	0.33593
0	MINNN	0.98110	0.39082
1	MINNN	0.98600	0.39572
0	MINQTC	0.90450	0.00007
1	MINQTC	0.98376	0.27638
0	PKAMPAS	0.92535	0.00056

Grup	Parametras	Statistikos reikšm	<i>p</i> reikšm
1	PKAMPAS	0.89814	0.00000
0	QRS_TNAU	0.83714	0.00000
1	QRS_TNAU	0.79541	0.00000
0	QTCD	0.78195	0.00000
1	QTCD	0.94454	0.00046
0	QTD	0.97762	0.25953
1	QTD	0.95231	0.00144
0	QTDAPEX	0.92845	0.00077
1	QTDAPEX	0.94460	0.00047
0	RMSSD	0.90072	0.00005
1	RMSSD	0.85044	0.00000
0	SDNN	0.93477	0.00150
1	SDNN	0.94736	0.00069
0	TPLOTAS	0.97593	0.21115
1	TPLOTAS	0.97455	0.05610
0	TSANTYK	0.97072	0.10970
1	TSANTYK	0.97048	0.02763
0	VIDNN	0.97528	0.19473
1	VIDNN	0.97993	0.14395
0	VIDSSD	0.93230	0.00115
1	VIDSSD	0.94033	0.00026
0	VK	0.95012	0.00856
1	VK	0.93792	0.00018
0	VLF	0.69709	0.00000
1	VLF	0.57316	0.00000

Vyrų imties normalizuotų parametų atskirose grupėse suderinamumo hipotezių tikrinimo rezultatai

Grup	Parametras	Statistikos reikšm	<i>p</i> reikšm
0	HF	0.98071	0.37373
1	HF	0.99601	0.99406

Grup	Parametras	Statistikos reikšm	<i>p</i> reikšm
0	JTD	0.97256	0.13847
1	JTD	0.98409	0.29190
0	JTDAPEX	0.96490	0.05246
1	JTDAPEX	0.99231	0.85585
0	LF	0.97022	0.10308
1	LF	0.98865	0.57957
0	LF_HF	0.98438	0.55419
1	LF_HF	0.97445	0.05518
0	MAXJTC	0.98645	0.67203
1	MAXJTC	0.98717	0.47179
0	QTD	0.97368	0.15954
1	QTD	0.99050	0.72416
0	QTDAPEX	0.97360	0.15796
1	QTDAPEX	0.98882	0.59240
0	RMSSD	0.97367	0.15933
1	RMSSD	0.99231	0.85598
0	SDNN	0.97013	0.10180
1	SDNN	0.98446	0.31023
0	TPLOTAS	0.97593	0.21115
1	TPLOTAS	0.97455	0.05610
0	VIDSSD	0.97240	0.13572
1	VIDSSD	0.98081	0.16788
0	VK	0.99618	0.99930
1	VK	0.97876	0.11742
0	VLF	0.97804	0.27330
1	VLF	0.98597	0.39387

Parametrinės diskriminantinės analizės modelio, skirto vyrų populiacijos tyrimui, rezultatai

Observations	165	DF Total	164
Variables	6	DF Within Classes	163
Classes	2	DF Between Classes	1

Class Level Information					
GRUPE	Variable Name	Frequency	Weight	Proportion	Prior Probability
0	_0	68	68.0000	0.412121	0.500000
1	_1	97	97.0000	0.587879	0.500000

Within Covariance Matrix Information		
GRUPE	Covariance Matrix Rank	Natural Log of the Determinant of the Covariance Matrix
0	6	9.24987
1	6	9.20506
Pooled	6	9.31251

Test of Homogeneity of Within Covariance Matrices

Chi-Square	DF	Pr > ChiSq
13.922380	21	0.8729

Since the Chi-Square value is not significant at the 0.1 level, a pooled covariance matrix will be used in the discriminant function. Reference: Morrison, D.F. (1976) Multivariate Statistical Methods p252.

Generalized Squared Distance to GRUPE		
From GRUPE	0	1
0	0	0.3861
1	0.3861	0

Linear Discriminant Function for GRUPE			
Variable	Label	0	1
Constant		-47.73188	-52.07909
AMZIUS	amzius	0.73317	0.78403
VK	vk	-5.37919	-5.46629
VLF	vlf	6.61158	7.00926
HF	hf	2.82586	2.53728
LF_HF	lf_hf	2.31738	1.96338
TPLLOTAS	tplotas	0.06502	0.06738

Posterior Probability of Membership in GRUPE					
Obs	From GRUPE	Classified into GRUPE		0	1
3	1	0	*	0.6623	0.3377
4	1	0	*	0.7061	0.2939
6	1	0	*	0.7402	0.2598
7	1	0	*	0.7616	0.2384
8	1	0	*	0.5415	0.4585
9	1	0	*	0.5898	0.4102
10	0	1	*	0.3413	0.6587
13	0	1	*	0.2829	0.7171
14	1	0	*	0.6352	0.3648
18	0	1	*	0.4820	0.5180
21	0	1	*	0.4804	0.5196
25	1	0	*	0.5210	0.4790
28	1	0	*	0.5986	0.4014
30	1	0	*	0.5131	0.4869
33	0	1	*	0.3783	0.6217
40	1	0	*	0.6297	0.3703
42	0	1	*	0.3305	0.6695
43	0	1	*	0.3035	0.6965
51	0	1	*	0.4608	0.5392
53	0	1	*	0.4461	0.5539
54	1	0	*	0.6544	0.3456
55	0	1	*	0.3308	0.6692
57	1	0	*	0.5780	0.4220
64	1	0	*	0.6348	0.3652
66	1	0	*	0.5393	0.4607

Posterior Probability of Membership in GRUPE					
Obs	From GRUPE	Classified into GRUPE		0	1
80	0	1	*	0.3870	0.6130
83	1	0	*	0.7294	0.2706
84	0	1	*	0.4425	0.5575
94	1	0	*	0.5006	0.4994
100	1	0	*	0.5677	0.4323
105	0	1	*	0.4886	0.5114
108	1	0	*	0.5846	0.4154
109	1	0	*	0.7277	0.2723
111	0	1	*	0.3286	0.6714
113	0	1	*	0.4777	0.5223
114	1	0	*	0.6664	0.3336
117	1	0	*	0.6213	0.3787
120	0	1	*	0.3210	0.6790
121	0	1	*	0.2330	0.7670
123	0	1	*	0.3834	0.6166
128	0	1	*	0.4203	0.5797
130	1	0	*	0.5062	0.4938
132	1	0	*	0.7606	0.2394
133	0	1	*	0.4132	0.5868
136	0	1	*	0.4878	0.5122
139	0	1	*	0.2869	0.7131
140	1	0	*	0.6915	0.3085
141	1	0	*	0.7275	0.2725
142	0	1	*	0.3896	0.6104
145	0	1	*	0.3622	0.6378
153	0	1	*	0.4283	0.5717
154	1	0	*	0.5666	0.4334
159	1	0	*	0.6839	0.3161
165	1	0	*	0.5501	0.4499

* *Misclassified observation*

Number of Observations and Percent Classified into GRUPE			
From GRUPE	0	1	Total
0	43 63.24	25 36.76	68 100.00
1	29 29.90	68 70.10	97 100.00
Total	72 43.64	93 56.36	165 100.00
Priors	0.5	0.5	

Error Count Estimates for GRUPE			
	0	1	Total
Rate	0.3676	0.2990	0.3333
Priors	0.5000	0.5000	

Cross-validation Results using Linear Discriminant Function

Posterior Probability of Membership in GRUPE					
Obs	From GRUPE	Classified into GRUPE		0	1
3	1	0	*	0.6848	0.3152
4	1	0	*	0.7658	0.2342
6	1	0	*	0.7627	0.2373
7	1	0	*	0.7824	0.2176
8	1	0	*	0.5752	0.4248
9	1	0	*	0.6055	0.3945
10	0	1	*	0.3314	0.6686
13	0	1	*	0.2491	0.7509
14	1	0	*	0.6601	0.3399
18	0	1	*	0.4539	0.5461
21	0	1	*	0.4604	0.5396
25	1	0	*	0.5344	0.4656
28	1	0	*	0.6101	0.3899
30	1	0	*	0.5371	0.4629
33	0	1	*	0.3474	0.6526
36	1	0	*	0.5176	0.4824
40	1	0	*	0.6390	0.3610

Posterior Probability of Membership in GRUPE					
Obs	From GRUPE	Classified into GRUPE		0	1
42	0	1	*	0.2833	0.7167
43	0	1	*	0.2693	0.7307
51	0	1	*	0.4352	0.5648
53	0	1	*	0.4358	0.5642
54	1	0	*	0.6747	0.3253
55	0	1	*	0.3182	0.6818
57	1	0	*	0.5875	0.4125
61	0	1	*	0.4936	0.5064
64	1	0	*	0.6463	0.3537
66	1	0	*	0.5551	0.4449
68	0	1	*	0.4922	0.5078
78	0	1	*	0.4887	0.5113
80	0	1	*	0.3645	0.6355
83	1	0	*	0.7439	0.2561
84	0	1	*	0.4163	0.5837
90	0	1	*	0.4838	0.5162
94	1	0	*	0.5124	0.4876
100	1	0	*	0.5778	0.4222
105	0	1	*	0.4832	0.5168
108	1	0	*	0.6057	0.3943
109	1	0	*	0.7560	0.2440
111	0	1	*	0.2580	0.7420
113	0	1	*	0.4362	0.5638
114	1	0	*	0.6854	0.3146
117	1	0	*	0.6442	0.3558
120	0	1	*	0.2919	0.7081
121	0	1	*	0.1909	0.8091
123	0	1	*	0.3729	0.6271
128	0	1	*	0.3882	0.6118
130	1	0	*	0.5193	0.4807
132	1	0	*	0.7875	0.2125
133	0	1	*	0.3669	0.6331
136	0	1	*	0.4678	0.5322
139	0	1	*	0.2562	0.7438
140	1	0	*	0.7320	0.2680

Posterior Probability of Membership in GRUPE					
Obs	From GRUPE	Classified into GRUPE		0	1
141	1	0	*	0.7557	0.2443
142	0	1	*	0.3320	0.6680
145	0	1	*	0.3104	0.6896
146	1	0	*	0.5321	0.4679
148	1	0	*	0.5034	0.4966
151	1	0	*	0.5193	0.4807
153	0	1	*	0.3963	0.6037
154	1	0	*	0.5821	0.4179
159	1	0	*	0.7049	0.2951
164	1	0	*	0.5056	0.4944
165	1	0	*	0.5794	0.4206

** Misclassified observation*

Number of Observations and Percent Classified into GRUPE			
From GRUPE	0	1	Total
0	39 57.35	29 42.65	68 100.00
1	34 35.05	63 64.95	97 100.00
Total	73 44.24	92 55.76	165 100.00
Priors	0.5	0.5	

Error Count Estimates for GRUPE			
	0	1	Total
Rate	0.4265	0.3505	0.3885
Priors	0.5000	0.5000	

Moterų imties parametrų atskirose grupėse suderinamumo hipotezių tikrinimo rezultatai

Grup	Parametras	Statistikos reikšm	<i>p</i> reikšm
0	AMZIUS	0.96648	0.27690
1	AMZIUS	0.97915	0.80244
0	BSI	0.78218	0.00000
1	BSI	0.78825	0.00004
0	HF	0.54047	0.00000
1	HF	0.44482	0.00000
0	HFNU	0.95875	0.15172
1	HFNU	0.95050	0.17431
0	JTD	0.98271	0.78848
1	JTD	0.94941	0.16300
0	JTDAPEX	0.90460	0.00261
1	JTDAPEX	0.97799	0.77006
0	LF	0.66579	0.00000
1	LF	0.80752	0.00009
0	LF_HF	0.79131	0.00000
1	LF_HF	0.75479	0.00001
0	LFNU	0.95875	0.15172
1	LFNU	0.95050	0.17431
0	MAXJTC	0.95589	0.12103
1	MAXJTC	0.97655	0.72823
0	MAXNN	0.94530	0.04231
1	MAXNN	0.93323	0.04985
0	MAXQTC	0.95898	0.15451
1	MAXQTC	0.96345	0.37828
0	MINJTC	0.98071	0.71586
1	MINJTC	0.96395	0.38915
0	MINNN	0.97075	0.38003
1	MINNN	0.93322	0.05984
0	MINQTC	0.96462	0.24008
1	MINQTC	0.94455	0.12066
0	PKAMPAS	0.93785	0.02929
1	PKAMPAS	0.87409	0.00207
0	QRS_TNAU	0.79123	0.00000
1	QRS_TNAU	0.88292	0.00329
0	QTD	0.94048	0.03589
1	QTD	0.93983	0.09001
0	QTDAPEX	0.95692	0.13127
1	QTDAPEX	0.97071	0.55875
0	RMSSD	0.86243	0.00018

Grup	Parametras	Statistikos reikšm	<i>p</i> reikšm
1	RMSSD	0.80283	0.00007
0	SDNN	0.77799	0.00000
1	SDNN	0.96498	0.41243
0	TPLOTAS	0.96616	0.27018
1	TPLOTAS	0.95890	0.29031
0	TSANTYK	0.94988	0.07513
1	TSANTYK	0.89375	0.00593
0	VIDNN	0.94300	0.04370
1	VIDNN	0.95353	0.20994
0	VIDSSD	0.94452	0.04920
1	VIDSSD	0.97368	0.64394
0	VK	0.82004	0.00002
1	VK	0.96484	0.40908
0	VLF	0.49088	0.00000
1	VLF	0.65980	0.00000

Moterų imties normalizuotų parametru atskirose grupėse suderinamumo hipotezių tikrinimo rezultatai

Grup	Parametras	Statistikos reikšm	<i>p</i> reikšm
0	BSI	0.96736	0.29594
1	BSI	0.95055	0.17484
0	HF	0.98203	0.76415
1	HF	0.97042	0.55079
0	JTDAPEX	0.96355	0.22113
1	JTDAPEX	0.97596	0.71095
0	LF	0.97233	0.42521
1	LF	0.98229	0.88266
0	LF_HF	0.97664	0.56677
1	LF_HF	0.97191	0.59274
0	MAXNN	0.94975	0.07437
1	MAXNN	0.95553	0.23708
0	QTD	0.95569	0.11909
1	QTD	0.94436	0.11920
0	RMSSD	0.95933	0.15886
1	RMSSD	0.96473	0.40655
0	SDNN	0.93449	0.02263
1	SDNN	0.97476	0.67580

Grup	Parametras	Statistikos reikšm	<i>p</i> reikšm
0	TSANTYK	0.96769	0.30328
1	TSANTYK	0.97136	0.57696
0	VIDNN	0.94732	0.06134
1	VIDNN	0.96663	0.45155
0	VIDSSD	0.94653	0.05764
1	VIDSSD	0.96830	0.49378
0	VK	0.96751	0.29938
1	VK	0.96022	0.31384
0	VLF	0.97074	0.37983
1	VLF	0.97425	0.66072

Parametrinės diskriminantinės analizės modelio, skirto moterų populiacijos tyrimui, rezultatai

Observations	70	DF Total	69
Variables	8	DF Within Classes	68
Classes	2	DF Between Classes	1

Class Level Information					
GRUPE	Variable Name	Frequency	Weight	Proportion	Prior Probability
0	_0	40	40.00	0.571429	0.5
1	_1	30	30.00	0.428571	0.5

Within Covariance Matrix Information		
GRUPE	Covariance Matrix Rank	Natural Log of the Determinant of the Covariance Matrix
0	8	29.10606
1	8	28.76286
Pooled	8	29.99553

Test of Homogeneity of Within Covariance Matrices

Chi-Square	DF	Pr > ChiSq
61.491212	36	0.0051

Since the Chi-Square value is significant at the 0.1 level, the within covariance matrices will be used in the discriminant function. Reference: Morrison, D.F. (1976) *Multivariate Statistical Methods* p252.

Generalized Squared Distance to GRUPE		
From GRUPE	0	1
0	29.10606	30.77513
1	31.04667	28.76286

Posterior Probability of Membership in GRUPE					
Obs	From GRUPE	Classified into GRUPE			
			0	1	
29	0	1 *	0.2520	0.7480	
31	1	0 *	0.8688	0.1312	
38	0	1 *	0.0516	0.9484	
46	0	1 *	0.2514	0.7486	
65	1	0 *	0.6291	0.3709	
68	1	0 *	0.8759	0.1241	

* *Misclassified observation*

Number of Observations and Percent Classified into GRUPE			
From GRUPE	0	1	Total
0	37 92.50	3 7.50	40 100.00
1	3 10.00	27 90.00	30 100.00
Total	40 57.14	30 42.86	70 100.00
Priors	0.5	0.5	

Error Count Estimates for GRUPE			
	0	1	Total
Rate	0.075	0.100	0.0875
Priors	0.500	0.500	

Cross-validation Results using Quadratic Discriminant Function

Posterior Probability of Membership in GRUPE					
Obs	From GRUPE	Classified into GRUPE		0	1
		0	1		
1	1	0	*	0.7036	0.2964
6	0	1	*	0.3238	0.6762
8	1	0	*	0.9451	0.0549
9	0	1	*	0.4175	0.5825
13	0	1	*	0.0246	0.9754
14	0	1	*	0.4542	0.5458
29	0	1	*	0.1408	0.8592
31	1	0	*	0.9961	0.0039
34	1	0	*	0.6435	0.3565
38	0	1	*	0.0129	0.9871
39	0	1	*	0.4165	0.5835
40	1	0	*	0.5266	0.4734
41	1	0	*	0.5794	0.4206
46	0	1	*	0.1507	0.8493
48	0	1	*	0.3841	0.6159
53	0	1	*	0.1046	0.8954
64	0	1	*	0.1282	0.8718
65	1	0	*	0.8728	0.1272
68	1	0	*	0.9997	0.0003

** Misclassified observation*

5 PRIEDAS

NEPARAMETRINĖS DISKRIMINANTINĖS ANALIZĖS MODELIO
TAIKYMO REZULTATAI

Neparametrinės diskriminantinės analizės modelio, skirto vyrų populiacijos tyrimui, rezultatai

Observations	165	DF Total	164
Variables	7	DF Within Classes	163
Classes	2	DF Between Classes	1

Class Level Information					
GRUPE	Variable Name	Frequency	Weight	Proportion	Prior Probability
0	_0	68	68.000	0.412121	0.5
1	_1	97	97.000	0.587879	0.5

Squared Distance to GRUPE			
From GRUPE		0	1
0		0	0.38994
1		0.38994	0

F Statistics, NDF=7, DDF=157 for Squared Distance to GRUPE			
From GRUPE		0	1
0		0	2.14492
1		2.14492	0

Prob > Mahalanobis Distance for Squared Distance to GRUPE			
From GRUPE		0	1
0		1.000	0.042
1		0.042	1.000

Generalized Squared Distance to GRUPE		
From GRUPE	0	1
0	0	0.38994
1	0.38994	0

Posterior Probability of Membership in GRUPE					
Obs	From GRUPE	Classified into GRUPE		0	1
		0	1		
7	1	0	*	0.5335	0.4665
10	0	1	*	0.4184	0.5816
14	1	0	*	0.5543	0.4457
22	1	0	*	0.5058	0.4942
25	1	0	*	0.5311	0.4689
35	1	0	*	0.5158	0.4842
40	1	0	*	0.5466	0.4534
43	0	1	*	0.4970	0.5030
62	1	0	*	0.5363	0.4637
64	1	0	*	0.5156	0.4844
83	1	0	*	0.6313	0.3687
100	1	0	*	0.5506	0.4494
109	1	0	*	0.5101	0.4899
114	1	0	*	0.5292	0.4708
158	0	1	*	0.4277	0.5723
159	1	0	*	0.5136	0.4864
164	1	0	*	0.5697	0.4303

** Misclassified observation*

Number of Observations and Percent Classified into GRUPE			
From GRUPE	0	1	Total
0	65 95.59	3 4.41	68 100.00
1	14 14.43	83 85.57	97 100.00
Total	79 47.88	86 52.12	165 100.00
Priors	0.5	0.5	

Error Count Estimates for GRUPE			
	0	1	Total
Rate	0.0441	0.1443	0.0942
Priors	0.5000	0.5000	

Cross-validation Results using Normal Kernel Density

Posterior Probability of Membership in GRUPE					
Obs	From GRUPE	Classified into GRUPE		0	1
4	1	0 *		0.5826	0.4174
6	1	0 *		0.6615	0.3385
7	1	0 *		0.6307	0.3693
10	0	1 *		0.3499	0.6501
11	1	0 *		0.9271	0.0729
12	1	0 *		0.5171	0.4829
13	0	1 *		0.4546	0.5454
14	1	0 *		0.7425	0.2575
18	0	1 *		0.4764	0.5236
22	1	0 *		0.5498	0.4502
25	1	0 *		0.5996	0.4004
28	1	0 *		0.5121	0.4879
29	0	1 *		0.4151	0.5849
30	1	0 *		0.5172	0.4828
33	0	1 *		0.4535	0.5465
35	1	0 *		0.5930	0.4070

Posterior Probability of Membership in GRUPE					
Obs	From GRUPE	Classified into GRUPE		0	1
36	1	0 *		0.6734	0.3266
37	0	1 *		0.4969	0.5031
40	1	0 *		0.6147	0.3853
43	0	1 *		0.4425	0.5575
44	1	0 *		0.5732	0.4268
54	1	0 *		0.6328	0.3672
57	1	0 *		0.5374	0.4626
62	1	0 *		0.6470	0.3530
64	1	0 *		0.5716	0.4284
69	1	0 *		0.5095	0.4905
79	1	0 *		0.5173	0.4827
80	0	1 *		0.4513	0.5487
83	1	0 *		0.7298	0.2702
84	0	1 *		0.3188	0.6812
90	0	1 *		0.4245	0.5755
91	1	0 *		0.7106	0.2894
96	1	0 *		0.7506	0.2494
100	1	0 *		0.6114	0.3886
102	0	1 *		0.3366	0.6634
104	0	1 *		0.2486	0.7514
109	1	0 *		0.7308	0.2692
111	0	1 *		0.4453	0.5547
113	0	1 *		0.4582	0.5418
114	1	0 *		0.6204	0.3796
117	1	0 *		0.5601	0.4399
120	0	1 *		0.4335	0.5665
121	0	1 *		0.4258	0.5742
128	0	1 *		0.3898	0.6102
130	1	0 *		0.5405	0.4595
132	1	0 *		0.5026	0.4974
133	0	1 *		0.3098	0.6902
135	0	1 *		0.3421	0.6579
136	0	1 *		0.3803	0.6197

Posterior Probability of Membership in GRUPE					
Obs	From GRUPE	Classified into GRUPE			
			0	1	
139	0	1 *	0.3341	0.6659	
140	1	0 *	0.5341	0.4659	
141	1	0 *	0.5191	0.4809	
142	0	1 *	0.2036	0.7964	
143	1	0 *	0.5129	0.4871	
145	0	1 *	0.2806	0.7194	
151	1	0 *	0.5187	0.4813	
157	1	0 *	0.5331	0.4669	
158	0	1 *	0.3071	0.6929	
159	1	0 *	0.6272	0.3728	
164	1	0 *	0.6712	0.3288	
165	1	0 *	0.6188	0.3812	

* *Misclassified observation*

Number of Observations and Percent Classified into GRUPE			
From GRUPE	0	1	Total
0	44 64.71	24 35.29	68 100.00
1	37 38.14	60 61.86	97 100.00
Total	81 49.09	84 50.91	165 100.00
Priors	0.5	0.5	

Error Count Estimates for GRUPE			
	0	1	Total
Rate	0.3529	0.3814	0.3672
Priors	0.5000	0.5000	

Jungtinė kovariacijų matrica

<u>NAME</u>	AMZIUS	VIDNN	VK	HF	LF_HF	QRS_TNAU	TPLOTAS
AMZIUS	99.81608	140.6601	-0.99754	-0.91993	-1.79374	-13.0029	-5.61483
VIDNN	140.6601	17625.07	7.198287	94.17596	-32.0446	-197.595	-627.526
VK	-0.99754	7.198287	0.144372	0.221416	0.08117	0.453563	-1.54795
HF	-0.91993	94.17596	0.221416	1.522313	-0.57887	4.362115	-13.5018
LF_HF	-1.79374	-32.0446	0.08117	-0.57887	0.847531	-3.34383	10.54486
QRS_TNAU	-13.0029	-197.595	0.453563	4.362115	-3.34383	1249.84	-120.59
TPLOTAS	-5.61483	-627.526	-1.54795	-13.5018	10.54486	-120.59	3711.285

Neparametrinės diskriminantinės analizės modelio, skirto moterų populiacijos tyrimui, rezultatai

Observations	70	DF Total	69
Variables	9	DF Within Classes	68
Classes	2	DF Between Classes	1

Class Level Information					
GRUPE	Variable Name	Frequency	Weight	Proportion	Prior Probability
0	_0	40	40.000	0.571429	0.5
1	_1	30	30.000	0.428571	0.5

Squared Distance to GRUPE		
From GRUPE	0	1
0	0	1.40262
1	1.40262	0

F Statistics, NDF=9, DDF=60 for Squared Distance to GRUPE		
From GRUPE	0	1
0	0	2.35735
1	2.35735	0

Prob > Mahalanobis Distance for Squared Distance to GRUPE		
From GRUPE	0	1
0	1.0000	0.0237
1	0.0237	1.0000

Generalized Squared Distance to GRUPE		
From GRUPE	0	1
0	0	1.40262
1	1.40262	0

Posterior Probability of Membership in GRUPE					
Obs	From GRUPE	Classified into GRUPE		0	1
1	1	0	*	0.5141	0.4859
6	0	1	*	0.4431	0.5569
16	0	1	*	0.4895	0.5105
17	1	0	*	0.5236	0.4764
29	0	1	*	0.4898	0.5102
36	1	0	*	0.5173	0.4827
38	0	1	*	0.4697	0.5303
39	0	1	*	0.4528	0.5472
41	1	0	*	0.5386	0.4614
44	1	0	*	0.5088	0.4912
47	0	1	*	0.4655	0.5345

** Misclassified observation*

Number of Observations and Percent Classified into GRUPE			
From GRUPE	0	1	Total
0	34 85.00	6 15.00	40 100.00
1	5 16.67	25 83.33	30 100.00
Total	39 55.71	31 44.29	70 100.00
Priors	0.5	0.5	

Error Count Estimates for GRUPE			
	0	1	Total
Rate	0.150	0.1667	0.1583
Priors	0.500	0.500	

Cross-validation Results using Normal Kernel Density

Posterior Probability of Membership in GRUPE						
Obs	From GRUPE	Classified into GRUPE		0	1	
		0	1			
1	1	0	*	0.5446	0.4554	
6	0	1	*	0.4097	0.5903	
9	0	1	*	0.4784	0.5216	
12	1	0	*	0.5183	0.4817	
13	0	1	*	0.3885	0.6115	
16	0	1	*	0.4712	0.5288	
17	1	0	*	0.5592	0.4408	
26	0	1	*	0.4835	0.5165	
27	0	1	*	0.4877	0.5123	
29	0	1	*	0.4709	0.5291	
30	0	1	*	0.4778	0.5222	
31	1	0	*	0.5227	0.4773	
36	1	0	*	0.5434	0.4566	
38	0	1	*	0.4500	0.5500	
39	0	1	*	0.4156	0.5844	
41	1	0	*	0.5708	0.4292	
44	1	0	*	0.5335	0.4665	
46	0	1	*	0.4941	0.5059	

Posterior Probability of Membership in GRUPE					
Obs	From GRUPE	Classified into GRUPE		0	1
		0	1		
47	0	1	*	0.4428	0.5572
55	0	1	*	0.4872	0.5128
60	1	0	*	0.5019	0.4981
65	1	0	*	0.5290	0.4710
68	1	0	*	0.6182	0.3818

* *Misclassified observation*

Number of Observations and Percent Classified into GRUPE			
From GRUPE	0	1	Total
0	27 67.50	13 32.50	40 100.00
1	10 33.33	20 66.67	30 100.00
Total	37 52.86	33 47.14	70 100.00
Priors	0.5	0.5	

Error Count Estimates for GRUPE			
	0	1	Total
Rate	0.3250	0.3333	0.3292
Priors	0.500	0.500	

Jungtinė kovariacijų matrica

NAME	MAXQTC	MAXJTC	MINJTC	MINNN	VK	VLF	HF	TPLOTAS
MAXQTC	284.3746	213.3772	172.1496	-593.185	-0.91287	-1.62114	-1.10913	294.6772
MAXJTC	213.3772	268.5892	191.5821	-168.871	-0.24626	-0.78705	1.44016	123.2887
MINJTC	172.1496	191.5821	235.0403	-180.891	-0.02188	-0.64421	1.150602	46.85172
MINNN	-593.185	-168.871	-180.891	18659.86	-9.90805	-6.30944	58.18745	-2034.27
VK	-0.91287	-0.24626	-0.02188	-9.90805	0.144369	0.201786	0.158046	2.584004
VLF	-1.62114	-0.78705	-0.64421	-6.30944	0.201786	0.751614	0.140772	4.244102
HF	-1.10913	1.44016	1.150602	58.18745	0.158046	0.140772	1.656827	-8.83023
TPLOTAS	294.6772	123.2887	46.85172	-2034.27	2.584004	4.244102	-8.83023	3758.702

6 PRIEDAS

VAINIKINIŲ ŠIRDIES ARTERIJŲ SUSIAURĖJIMŲ ĮVERTINIMO PROGRAMINIAI MODELIAI

```

/*****
/*      FMMM-3 gr. stud. Doviles Astapenko          */
/*      */
/*      ŠIRDIES VAINIKINIŲ ARTERIJŲ SUSIAURĖJIMŲ VERTINIMO  */
/*      MODELIAI IR PROGRAMINĖS PRIEMONĖS          */
/*      */
/*      Magistro darbas, 2005                        */
/*      */
/*****

/*****
/*      Duomenų paruosimas analizei                */
/*****

proc import datafile="D:\MENIU\Duomenys\duomenys.xls"
    out=duom REPLACE ;
run;

data duom;
    set duom;
    if (amzius^=.) & (qtd^=.) & (jtd^=.) & (qtdapex^=.) & (jtdapex^=.) & (maxqtc^=.)
        & (minqtc^=.) & (maxjtc^=.) & (minjtc^=.) & (qtc^=.) & (jtc^=.)
        & (vidnn^=.) & (vidssd^=.) & (maxnn^=.) & (minnn^=.) & (maxnnskir^=.)
        & (sdnn^=.) & (vk^=.) & (rmssd^=.) & (vlf^=.) & (lf^=.) & (hf^=.) & (bsi^=.)
        & (lfnu^=.) & (hfnu^=.) & (lf_hf^=.) & (pkampas^=.) & (qrs_tnau^=.)
        & (tplotas^=.) & (tsantyk^=.);
run;

data duom_v;
    set duom;
    if lytis=1;
run;

data duom_m;
    set duom;
    if lytis=2;
run;

/*****
/*      Aprasomoji statistika                      */
/*****

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\apras_stat_v.rtf";

proc means data=duom_v mean std p25 p50 p75 min max;
    var amzius qtd jtd qtdapex jtdapex maxqtc minqtc maxjtc
        minjtc qtc jtc vidnn vidssd maxnn minnn maxnnskir
        sdnn vk rmssd vlf lf hf bsi lfnu hfnu lf_hf pkampas
        qrs_tnau tplotas tsantyk ;
run;

proc means data=duom_v mean std p25 p50 p75 min max;
    var amzius qtd jtd qtdapex jtdapex maxqtc minqtc maxjtc
        minjtc qtc jtc vidnn vidssd maxnn minnn maxnnskir
        sdnn vk rmssd vlf lf hf bsi lfnu hfnu lf_hf pkampas

```



```

    qrs_tnau tplotas tsantyk ;
    class grupe;
run;

proc boxplot data=duom_v ;
    plot (AMZIUS)*grupe
        / caxis=BLACK
          cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
          cboxfill=BLUE idcolor=red npanel=15
          boxstyle=schematicid name='BOX'
          description='Boxplot of AMZIUS';

    plot (QTD)*grupe
        / caxis=BLACK
          cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
          cboxfill=BLUE idcolor=red npanel=15
          boxstyle=schematicid name='BOX'
          description='Boxplot of QTD';

    plot (JTD)*grupe
        / caxis=BLACK
          cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
          cboxfill=BLUE idcolor=red npanel=15
          boxstyle=schematicid name='BOX'
          description='Boxplot of JTD';

    plot (QTDAPEX)*grupe
        / caxis=BLACK
          cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
          cboxfill=BLUE idcolor=red npanel=15
          boxstyle=schematicid name='BOX'
          description='Boxplot of QTDAPEX';

    plot (JTDAPEX)*grupe
        / caxis=BLACK
          cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
          cboxfill=BLUE idcolor=red npanel=15
          boxstyle=schematicid name='BOX'
          description='Boxplot of JTDAPEX';

    plot (MAXQTC)*grupe
        / caxis=BLACK
          cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
          cboxfill=BLUE idcolor=red npanel=15
          boxstyle=schematicid name='BOX'
          description='Boxplot of MAXQTC';

    plot (MINQTC)*grupe
        / caxis=BLACK
          cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
          cboxfill=BLUE idcolor=red npanel=15
          boxstyle=schematicid name='BOX'
          description='Boxplot of MINQTC';

    plot (MAXJTC)*grupe
        / caxis=BLACK
          cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
          cboxfill=BLUE idcolor=red npanel=15
          boxstyle=schematicid name='BOX'
          description='Boxplot of MAXJTC';

    plot (MINJTC)*grupe
        / caxis=BLACK
          cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
          cboxfill=BLUE idcolor=red npanel=15
          boxstyle=schematicid name='BOX'
          description='Boxplot of MINJTC';

    plot (QTCD)*grupe
        / caxis=BLACK
          cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
          cboxfill=BLUE idcolor=red npanel=15

```

```

                                boxstyle=schematicid name='BOX'
                                description='Boxplot of QTCD';
plot (JTCD)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of JTCD';
plot (VIDNN)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of VIDNN';
plot (VIDSSD)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of VIDSSD';
plot (MAXNN)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of MAXNN';
plot (MINNN)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of MINNN';
plot (MAXNNSKIR)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of MAXNNSKIR';
plot (SDNN)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of SDNN';
    plot (vk)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of vk';
plot (RMSSD)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of RMSSD';
plot (VLF)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of VLF';
plot (LF)*grupe

```

```

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of LF';

plot (HF)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of HF';

plot (BSI)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of BSI';

plot (LFNU)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of LFNU';

plot (HFNU)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of HFNU';

plot (LF_HF)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of LF_HF';

plot (PKAMPAS)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of PKAMPAS';

plot (QRS_TNAU)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of QRS_TNAU';

plot (TLOTAS)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of Tplotas';

plot (TSANTYK)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of TSANTYK';

run;

ods rtf close;

```

```

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\apras_stat_m.rtf";

proc means data=duom_m mean std p25 p50 p75 min max;
  var amzius qtd jtd qtdapex jtdapex maxqtc minqtc maxjtc
      minjtc qtcd jtcd vidnn vidssd maxnn minnn maxnnskir
      sdnv vk rmssd vlf lf hf bsi lfnu hfnu lf_hf pkampas
      qrs_tnau tplotas tsantyk ;
run;

proc means data=duom_m mean std p25 p50 p75 min max;
  var amzius qtd jtd qtdapex jtdapex maxqtc minqtc maxjtc
      minjtc qtcd jtcd vidnn vidssd maxnn minnn maxnnskir
      sdnv vk rmssd vlf lf hf bsi lfnu hfnu lf_hf pkampas
      qrs_tnau tplotas tsantyk ;
  class grupe;
run;

proc boxplot data=duom_m ;

  plot (AMZIUS)*grupe
      / caxis=BLACK
        cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
        cboxfill=BLUE idcolor=red npanel=15
        boxstyle=schematicid name='BOX'
        description='Boxplot of AMZIUS';

  plot (QTD)*grupe
      / caxis=BLACK
        cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
        cboxfill=BLUE idcolor=red npanel=15
        boxstyle=schematicid name='BOX'
        description='Boxplot of QTD';

  plot (JTD)*grupe
      / caxis=BLACK
        cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
        cboxfill=BLUE idcolor=red npanel=15
        boxstyle=schematicid name='BOX'
        description='Boxplot of JTD';

  plot (QTDAPEX)*grupe
      / caxis=BLACK
        cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
        cboxfill=BLUE idcolor=red npanel=15
        boxstyle=schematicid name='BOX'
        description='Boxplot of QTDAPEX';

  plot (JTDAPEX)*grupe
      / caxis=BLACK
        cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
        cboxfill=BLUE idcolor=red npanel=15
        boxstyle=schematicid name='BOX'
        description='Boxplot of JTDAPEX';

  plot (MAXQTC)*grupe
      / caxis=BLACK
        cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
        cboxfill=BLUE idcolor=red npanel=15
        boxstyle=schematicid name='BOX'
        description='Boxplot of MAXQTC';

  plot (MINQTC)*grupe
      / caxis=BLACK
        cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
        cboxfill=BLUE idcolor=red npanel=15

```

```

                                boxstyle=schematicid name='BOX'
                                description='Boxplot of MINQTC';
plot (MAXJTC)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of MAXJTC';
plot (MINJTC)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of MINJTC';
plot (QTCD)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of QTCD';
plot (JTCD)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of JTCD';
plot (VIDNN)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of VIDNN';
plot (VIDSSD)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of VIDSSD';
plot (MAXNN)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of MAXNN';
plot (MINNN)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of MINNN';
plot (MAXNNSKIR)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of MAXNNSKIR';
plot (SDNN)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of SDNN';
plot (vk)*grupe

```

```

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of vk';

plot (RMSSD)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of RMSSD';

plot (VLF)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of VLF';

plot (LF)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of LF';

plot (HF)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of HF';

plot (BSI)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of BSI';

plot (LFNU)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of LFNU';

plot (HFNU)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of HFNU';

plot (LF_HF)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of LF_HF';

plot (PKAMPAS)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15
boxstyle=schematicid name='BOX'
description='Boxplot of PKAMPAS';

plot (QRS_TNAU)*grupe

/ caxis=BLACK
cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
cboxfill=BLUE idcolor=red npanel=15

```

```

                                boxstyle=schematicid name='BOX'
                                description='Boxplot of QRS_TNAU';

plot (TLOTAS)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of Tplotas';

plot (TSANTYK)*grupe
                                / caxis=BLACK
                                cframe=CXF7E1C2 ctext=BLACK cboxes=BLACK
                                cboxfill=BLUE idcolor=red npanel=15
                                boxstyle=schematicid name='BOX'
                                description='Boxplot of TSANTYK';

run;

ods rtf close;

goptions reset;

/*****
/*                               Kintamuju transformavimas                               */
*****/

data duom_v;
  set duom_v;
  qtd=log(qtd);
  jtd=sqrt(jtd);
  qtdapex=sqrt(qtdapex);
  jtdapex=sqrt(jtdapex);
  maxjtc=-(1/(maxjtc*maxjtc));
  minjtc=-(1/(minjtc*minjtc));
  qtcd=log(qtcd);
  jtcd=sqrt(jtcd);
  vidssd=-(1/(vidssd*vidssd));
  maxnnskir=sqrt(maxnnskir);
  sdn=sqrt(sdn);
  vk=log(vk);
  rmssd=log(rmssd);
  vlf=log(vlf);
  lf=log(lf);
  hf=log(hf);
  lf_hf=log(lf_hf);

run;

data duom_m;
  set duom_m;
  qtd=log(qtd);
  jtdapex=sqrt(jtdapex);
  qtcd=log(qtcd);
  vidnn=log(vidnn);
  vidssd=log(vidssd);
  maxnn=log(maxnn);
  maxnnskir=log(maxnnskir);
  sdn=log(sdn);
  vk=log(vk);
  rmssd=log(rmssd);
  vlf=log(vlf);
  lf=log(lf);
  hf=log(hf);
  bsi=log(bsi);
  lf_hf=log(lf_hf);
  tsantyk=sqrt(tsantyk);

```

```

run;

/*****
/*          Logistines regresijos modeliai          */
*****/

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\logistic_stepwise_v.rtf";

proc logistic data=duom_v descending ;
    model grupe=amzius qtd jtd qtdapex jtdapex maxqtc minqtc maxjtc
        minjtc qtcd jtcd vidnn vidssd maxnn minnn maxnnskir
        sdnn vk rmssd vlf lf hf bsi lfnu hfnu lf_hf pkampas
        qrs_tnau tplotas tsantyk/
    SLENTY=0.1 slstay=0.15 details RSQ SELECTION=stepwise expb PPROB=0.5
CTABLE;
run;

ods rtf close;

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\logistic_v.rtf";

proc logistic DATA=duom_v DESCENDING ;
    MODEL grupe=amzius vidnn minnn sdnn vk rmssd vlf lf hf bsi
        lfnu hfnu lf_hf qrs_tnau tsantyk/
    LACKFIT DETAILS RSQ EXPB PPROB=0.5 PEVENT=0.5 CTABLE OUTROC=roc_v;
    OUTPUT OUT=pred_v P=pred;
    title 'Vyru VA susiaurejimu analize taikant logistines regresijos modeli';
run;

symbol1 i=join v=none c=blue w=4;

proc gplot data=roc_v;
    title 'Vyru VA susiaurejimu analizes ROC kreive';
    plot _sensit_*(_lmspec_)=1 / vaxis=0 to 1 by .1 cframe=ywh;
run;

ods rtf close;

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\logistic_stepwise_m.rtf";

proc logistic data=duom_m descending ;
    model grupe=amzius qtd jtd qtdapex jtdapex maxqtc minqtc maxjtc
        minjtc qtcd jtcd vidnn vidssd maxnn minnn maxnnskir
        sdnn vk rmssd vlf lf hf bsi lfnu hfnu lf_hf pkampas
        qrs_tnau tplotas tsantyk/
    SLENTY=0.1 slstay=0.15 details RSQ SELECTION=stepwise expb PPROB=0.5
CTABLE;
run;

ods rtf close;

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\logistic_m.rtf";

```



```

proc logistic DATA=duom_m DESCENDING ;
  MODEL grupe=jtdapex maxqtc minjtc jtcd vlf lf pkampas qrs_tnau tplotas /
  LACKFIT DETAILS RSQ EXPB PPROB=0.5 PEVENT=0.5 CTABLE OUTROC=roc_m;
  OUTPUT OUT=pred_m P=pred;
  title 'Moteru VA susiaurejimu analize taikant logistines regresijos modeli';
run;

proc gplot data=roc_m;
  title 'Moteru VA susiaurejimu analizes ROC kreive';
  plot _sensit*_lmspec=1 / vaxis=0 to 1 by .1 cframe=ywh;
run;

ods rtf close;

/*****
/*          Duomenų paruosimas          */
/*    daugiamacių skirstinių suderinamumo    */
/*          hipotezės tikrinimui          */
*****/

data duom_v_0;
  set duom_v;
  if grupe=0;
run;
data duom_v_1;
  set duom_v;
  if grupe=1;
run;
data duom_v_0;
  set duom_v_0;
  drop grupe;
run;
data duom_v_1;
  set duom_v_1;
  drop grupe;
run;

data duom_m_0;
  set duom_m;
  if grupe=0;
run;
data duom_m_1;
  set duom_m;
  if grupe=1;
run;
data duom_m_0;
  set duom_m_0;
  drop grupe;
run;
data duom_m_1;
  set duom_m_1;
  drop grupe;
run;

/*****
/*          Suderinamumo hipotezių tikrinimas          */
*****/

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\vienmaciai_skirst_hip_v.rtf";

proc univariate data=duom_v normal ;

```

```

class grupe;
var amzius qtd jtd qtdapex jtdapex maxqtc minqtc maxjtc
    minjtc qtcd jtcd vidnn vidssd maxnn minnn maxnnskir
    sdnv vk rmssd vlf lf hf bsi lfnu hfnu lf_hf pkampas
    grs_tnau tplotas tsantyk ;
run;

ods rtf close;

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\daugiamacio_skirst_hip_v.rtf";

proc iml;
    use duom_v_norm_0;
    read all into y;

    n = nrow(y) ;
    p = ncol(y) ;
    dfchi = p*(p+1)*(p+2)/6 ;

    q = i(n) - (1/n)*j(n,n,1);
    s = (1/(n))*y`*q*y ; s_inv = inv(s) ;
    g_matrix = q*y*s_inv*y`*q;
    betalhat = ( sum(g_matrix#g_matrix#g_matrix) )/(n*n);
    beta2hat =trace( g_matrix#g_matrix )/n ;

    kappal = n*betalhat/6 ;
    kappa2 = (beta2hat - p*(p+2) ) /sqrt(8*p*(p+2)/n) ;

    pvalskew = 1 - probchi(kappal,dfchi) ;
    pvalkurt = 2*( 1 - probnorm(abs(kappa2)) ) ;
    print s ;
    print s_inv ;
    print 'TESTS:' ;
    print 'Based on skewness: ' betalhat kappal pvalskew ;
    print 'Based on kurtosis: ' beta2hat kappa2 pvalkurt;

run;

proc iml;
    use duom_v_norm_1;
    read all into y;

    n = nrow(y) ;
    p = ncol(y) ;
    dfchi = p*(p+1)*(p+2)/6 ;

    q = i(n) - (1/n)*j(n,n,1);
    s = (1/(n))*y`*q*y ; s_inv = inv(s) ;
    g_matrix = q*y*s_inv*y`*q;
    betalhat = ( sum(g_matrix#g_matrix#g_matrix) )/(n*n);
    beta2hat =trace( g_matrix#g_matrix )/n ;

    kappal = n*betalhat/6 ;
    kappa2 = (beta2hat - p*(p+2) ) /sqrt(8*p*(p+2)/n) ;

    pvalskew = 1 - probchi(kappal,dfchi) ;
    pvalkurt = 2*( 1 - probnorm(abs(kappa2)) ) ;
    print s ;
    print s_inv ;
    print 'TESTS:' ;
    print 'Based on skewness: ' betalhat kappal pvalskew ;
    print 'Based on kurtosis: ' beta2hat kappa2 pvalkurt;

```

```

run;

ods rtf close;

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\vienmaciai_skirst_hip_m.rtf";

proc univariate data=duom_m normal;
  class grupe;
  var amzius qtd jtd qtdapex jtdapex maxqtc minqtc maxjtc
      minjtc qtcd jtcd vidnn vidssd maxnn minnn maxnnskir
      sdnv vk rmssd vlf lf hf bsi lfnu hfnu lf_hf pkampas
      qrs_tnau tplotas tsantyk ;
run;

ods rtf close;

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\daugiamacio_skirst_hip_m.rtf";

proc iml;
  use duom_m_norm_0;
  read all into y;

  n = nrow(y) ;
  p = ncol(y) ;
  dfchi = p*(p+1)*(p+2)/6 ;

  q = i(n) - (1/n)*j(n,n,1);
  s = (1/(n))*y`*q*y ; s_inv = inv(s) ;
  g_matrix = q*y*s_inv*y`*q;
  betalhat = ( sum(g_matrix#g_matrix#g_matrix) )/(n*n);
  beta2hat =trace( g_matrix#g_matrix )/n ;

  kappal = n*betalhat/6 ;
  kappa2 = (beta2hat - p*(p+2) ) /sqrt(8*p*(p+2)/n) ;

  pvalskew = 1 - probchi(kappal,dfchi) ;
  pvalkurt = 2*( 1 - probnorm(abs(kappa2)) ) ;
  print s ;
  print s_inv ;
  print 'TESTS:' ;
  print 'Based on skewness: ' betalhat kappal pvalskew ;
  print 'Based on kurtosis: ' beta2hat kappa2 pvalkurt;

run;

proc iml;
  use duom_m_norm_1;
  read all into y;

  n = nrow(y) ;
  p = ncol(y) ;
  dfchi = p*(p+1)*(p+2)/6 ;

  q = i(n) - (1/n)*j(n,n,1);
  s = (1/(n))*y`*q*y ; s_inv = inv(s) ;
  g_matrix = q*y*s_inv*y`*q;
  betalhat = ( sum(g_matrix#g_matrix#g_matrix) )/(n*n);
  beta2hat =trace( g_matrix#g_matrix )/n ;

  kappal = n*betalhat/6 ;

```

```

kappa2 = (beta2hat - p*(p+2) ) /sqrt(8*p*(p+2)/n) ;

pvalskew = 1 - probchi(kappal,dfchi) ;
pvalkurt = 2*( 1 - probnorm(abs(kappa2)) );
print s ;
print s_inv ;
print 'TESTS:';
print 'Based on skewness: ' betalhat kappal pvalskew ;
print 'Based on kurtosis: ' beta2hat kappa2 pvalkurt;

run;
ods rtf close;

/*****
/* Parametrines diskriminantines analizes modeliai */
*****/

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\par_dis_stepwise_v.rtf";

proc stepdisc data=duom_v slentry=.1 slstay=.15;
  class grupe;
  var amzius qtd jtdapex maxjtc vidnn vlf vk lf_hf hf tplotas;
run;

ods rtf close;

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\par_dis_v.rtf";

proc discrim data=duom_v method=normal pool=test outstat=par_info_v
  crosslisterr listerr;
  class grupe;
  var amzius vk vlf hf lf_hf tplotas ;
  title 'Vyru VA susiaurejimu analize taikant parametrines diskriminantines
analizes modeli';
run;

ods rtf close;

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\par_dis_stepwise_m.rtf";

proc stepdisc data=duom_m slentry=.1 slstay=.15;
  class grupe;
  var amzius qtd jtd minqtc maxqtc minjtc maxjtc vidnn
  vidssd maxxnn minnnn vk bsi vlf rmssd lf hf hfnu tplotas;
run;

ods rtf close;

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\par_dis_m.rtf";

proc discrim data=duom_m method=normal pool=test outstat=par_info_m
  crosslisterr listerr;
  class grupe;
  var maxqtc maxjtc minjtc minnnn vk vlf hf tplotas;
  title 'Moteru VA susiaurejimu analize taikant parametrines diskriminantines
analizes modeli';
run;

ods rtf close;

```

```

/*****
/*  Neparimetrines diskriminantines analizes modeliai  */
/*****

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\npar_dis_v.rtf";

proc discrim data=duom_v distance method=npair r=1 kernel=nor pool=yes
outstat=npair_info_v
    crosslisterr listerr;
    class grupe;
    var amzius vidn vk hf lf_hf qrs_tnau tplotas;
    title 'Vyru VA susiaurejimu analize taikant neparimetrines diskriminantines
analizes modeli';
run;

ods rtf close;

ods listing close;
ods rtf file="D:\MENIU\Rezultatai\npar_dis_m.rtf";

proc discrim data=duom_m distance method=npair r=2.1 kernel=nor pool=yes
outstat=npair_info_m
    crosslisterr listerr;
    class grupe;
    var maxqtc maxjtc minjtc minnn vk vlf hf qrs_tnau tplotas;
    title 'Moteru VA susiaurejimu analize taikant neparimetrines
diskriminantines analizes modeli';
run;

ods rtf close;

```