



**KAUNO TECHNOLOGIJOS UNIVERSITETAS**

**FUNDAMENTALIŲJŲ MOKSLŲ FAKULTETAS**

**MATEMATINĖS SISTEMOTYROS KATEDRA**

**Karolis Sokolovas**

**ARBITRAŽO GALIMYBĖS PANAUDOJIMAS  
DAUGIALYPĖS REGRESIJOS MODELyje**

Magistro darbas

**Vadovas**

**doc. dr. E. Valakevičius**

**KAUNAS, 2009**



**KAUNO TECHNOLOGIJOS UNIVERSITETAS**

**FUNDAMENTALIŲJŲ MOKSLŲ FAKULTETAS**

**MATEMATINĖS SISTEMOTYROS KATEDRA**

**TVIRTINU**

**Katedros vedėjas**

**prof. habil.dr. V.Pekarskas**

**2009 06 04**

**ARBITRAŽO GALIMYBĖS PANAUDOJIMAS  
DAUGIALYPĖS REGRESIJOS MODELyje**

Matematikos magistro baigiamasis darbas

**Vadovas**

**doc. dr. E. Valakevičius**

**2009 06 02**

**Recenzentas**

**Doc. dr. Regina Misevičienė**

**2009 06 03**

**Atliko**

**FMMM 7 gr. stud.**

**K. Sokolovas**

**2009 06 01**

**KAUNAS, 2009**

## KVALIFIKACINĖ KOMISIJA

**Pirmininkas:** Leonas Saulis, profesorius (VGTU)

**Sekretorius:** Eimutis Valakevičius, docentas (KTU)

**Nariai:** Algimantas Jonas Aksomaitis, profesorius (KTU)

Arūnas Barauskas, Vice-prezidentas projektams  
(UAB „Baltic Amadeus“),

Vytautas Janilionis, docentas (KTU)

Zenonas Navickas, profesorius (KTU),

Vidmantas Povilas Pekarskas, profesorius (KTU)

Rimantas Rudzkis, habil. dr., vyriausiasis analitikas (DnB NORD Bankas)

**Sokolovas K. Taking arbitrage opportunity in multiple regression model. Master's work in applied mathematics / supervisor dr. assoc. prof. E. Valakevičius; Department of mathematical research in systems. Faculty of Fundamental Sciences, Kaunas University of Technology. – Kaunas, 2009. – 84 p.**

### **SUMMARY**

Asset pricing problems that occur while choosing economic and social factors that are suitable for the rating of an asset are analysed in the work. In the work, a number of those factors is tried to be reduced not reducing the model accuracy. After accomplishing that, it is tried to choose a set of factors that is suitable for finding the value of the asset. The model that is described in the work selects factors to determine the prices of average type of flats in the Kaunas city centre. In the execution of the work, while avoiding the condition of multicollinearity, the time spent on computer-based calculations was reduced. In the outcome of the work it can be seen that the set of factors that best describes the prices of flats is:

1. Unemployment rate;
2. expectations (expectations is greater, when people want greater salary);
3. Investment in Lithuania.

Many of the factors was economic factors, but some was social ones. It has been noticed, that it is important to include some social factors to increase the value of coefficient of determination. In a work there were created an algorithm to select every set of factors of different size.

## SANTRAUKA

Darbe nagrinėjamos aktyvų įkainojimo problemos, išskylančios parenkant ekonominius ir socialinius veiksnius tinkančius aktyvo įkainojimui. Darbe siekiama sumažinti šių veiksnių skaičių. Tą atlikus siekiama parinkti veiksnių rinkinį, tinkantį nagrinėjamo aktyvo vertės nustatymui. Darbe aprašytas modelis parenka veiksnius butų kainoms, Kauno miesto centre nustatyti. Darbo atlikimo metu, išvengiant multikolinearumo sąlygos, pavyko sumažinti kompiuteriniams skaičiavimams reikalingą laiką. Darbe gauta, kad butų kainas Kauno miesto centre geriausiai apibūdina šių veiksnių rinkinys:

1. Vidutinė bedarbystė per paskutinius 3 mėn;
2. Lūkesčiai (Kuo daugiau žmonių įsidarbindami tikisi gauti didesnę atlyginimą);
3. materialinės investicijos Lietuvoje.

Dauguma įtrauktų veiksnių buvo ekonominiai, tačiau socialiniai veiksniai, kurie yra tiesinėje priklausomybėje su vertinamu aktyvu, neša modeliui didesnę naudą negu ekonominiai veiksniai. Jų įtraukimas į modelį yra svarbus modelio reikšmingumui. Taip pat darbe sukurtas algoritmas, skirtas perrinkti visiems skirtingiems veiksnių variantams, kad būtų įvertinta kiekvieno veiksnio sąveika su kitais veiksniais.

## TURINYS

Santrauka.....	5
Paveikslų sąrašas.....	7
Lentelių sąrašas.....	8
1. Įvadas.....	9
2. Teorinė dalis.....	10
2.1. Daugialypės regresijos modelis, jo taikymas finansuose.....	10
2.2. Arbitražo galimybė.....	15
2.3. Aktyvų ir veiksnių parinkimas investicijoms.....	16
2.4. Investicinių modelių parinkimo problemos ir darbe sprendžiami uždaviniai.....	17
3. Metodinė dalis.....	18
3.1. Geriausio veiksnių rinkinio parinkimas modelyje.....	18
3.2. Modelio sudarymas, algoritmai, sudėtingumas.....	19
3.3. Duomenų sudarymas ir parinkimas modeliui.....	21
3.4. Aktyvų įkainojimo statistinis modelis.....	22
3.5. Modelio sudarymo pavyzdys.....	22
4. Tiriamoji dalis.....	29
4.1. Kauno miesto centre esančių butų kainų įvertinimas.....	29
4.2. Programinė realizacija ir instrukcija vartotojui.....	42
5. Rezultatai.....	45
6. Diskusija.....	46
7. Išvados.....	47
8. Rekomendacijos.....	48
9. Padėkos.....	48
10. Nuorodos (šaltiniai ir literatūra).....	49
1 Priedas. Pradiniai veiksniai. Pradiniai duomenys.....	50
2 Priedas. Porinių stebėjimų grafikai.....	56
3 Priedas. Veiksnius apibūdinančios koreliacinės matricos.....	66
4 Priedas. Programų tekstai.....	69
5 Priedas. Algoritmų iliustracijos.....	90

## PAVEIKSLŲ SĄRAŠAS

1 pav. Programos veikimo algoritmas.....	20
2 pav: Pirmasis aktyvų įkainojimo statistinis modelis.....	22
3 pav: Antrasis aktyvų įkainojimo statistinis modelis.....	22
4 pav. Veiksnių tarpusavio priklausomybė. Porinio stebėjimo grafikas. Pavyzdys.....	24
5 pav. Veiksnių A1 ir A2 porinės priklausomybės. Pavyzdys.....	25
6 pav. Veiksnių B1 ir B2 porinės priklausomybės. Pavyzdys.....	25
7 pav. Hipotezės, apie bent vieno koeficiento nelygumą nuliui, tikrinimas. Pavyzdys.....	27
8 pav. Hipotezių, apie visų koeficientų nelygumą nuliui, tikrinimas. Pirmasis koeficientas.....	27
9 pav. Hipotezių, apie visų koeficientų nelygumą nuliui, tikrinimas. Antrasis koeficientas.....	28
10 pav. Hipotezių, apie visų koeficientų nelygumą nuliui tikrinimas. Trečiasis koeficientas.....	28
11 pav. Standartizuotųjų liekanų sklaidos diagrama. Pirmojo kintamojo liekanoms.....	28
12 pav. Standartizuotųjų liekanų sklaidos diagrama. Antrojo kintamojo liekanoms.....	29
13 pav. Vidutinių butų kainų, tūkst. LTL už kvadratinį metrą, kitimas Kauno miesto centre 1999-2008m. Ketvirčiais.....	30
14 pav. Pastebėta ir panaikinta išskirtis paskutiniame periode.....	30
15 pav. Hipotezės, apie bent vieno koeficiento nelygumą nuliui, tikrinimas.....	33
16 pav. Hipotezės tikrinimas apie A13 veiksnį aprašančio koeficiento lygybę nuliui.....	33
17 pav. Hipotezės tikrinimas apie B5 veiksnį aprašančio koeficiento lygybę nuliui.....	34
18 pav. Hipotezės tikrinimas apie B8 veiksnį aprašančio koeficiento lygybę nuliui.....	34
19 pav. Hipotezės apie konstantos lygumą nuliui tikrinimas.....	34
20 pav. Standartizuotųjų liekanų priklausomybė, parodanti veiksnio A13 tiesiškumą su priklausomu kintamuoju.....	35
21 pav. Standartizuotųjų liekanų priklausomybė, parodanti veiksnio B5 tiesiškumą su priklausomu kintamuoju.....	35
22 pav. Standartizuotųjų liekanų priklausomybė, parodanti veiksnio B8 tiesiškumą su priklausomu kintamuoju.....	36
23 pav. Hipotezės apie visų koeficientų lygumą nuliui tikrinimas.....	37
24 pav. Hipotezės tikrinimas apie veiksnį A13 apibūdinančio koeficiento lygybę nuliui.....	37
25 pav. Hipotezės tikrinimas apie veiksnį B5 apibūdinančio koeficiento lygybę nuliui.....	38
26 pav. Hipotezės tikrinimas apie konstantos lygumą nuliui.....	38
27 pav. Standartizuotųjų liekanų priklausomybė, parodanti priklausomo kintamojo tiesinę priklausomybę nuo veiksnio A13.....	38
28 pav. Standartizuotųjų liekanų priklausomybė, parodanti priklausomo kintamojo tiesinę priklausomybę nuo veiksnio B5.....	38

29 pav. Hipotezės apie visų koeficientų lygumą nuliui tikrinimas.....	40
30 pav. Hipotezės apie veiksnį A14 apibūdinančio koeficiento lygybę nuliui, tikrinimas.....	40
31 pav. Hipotezės apie veiksnio B14 lygybę nuliui apibūdinančio koeficiento tikrinimas.....	41
32 pav. Hipotezės apie konstantos lygumą nuliui tikrinimas.....	41
33 pav. Priklausomojo kintamojo tiesinė priklausomybė nuo veiksnio A14. Standartizuotųjų liekanų priklausomybė.....	41
34 pav. Priklausomojo kintamojo tiesinė priklausomybė nuo veiksnio B14. Standartizuotųjų liekanų priklausomybė.....	42
35 pav. Algoritmo dalis.....	90

## LENTELIŲ SĄRAŠAS

1. lentelė: Resursai, reikalingi optimaliam veiksnių rinkiniui rasti.....	19
2. lentelė: Glodinančio arba interpoliacinio splaino skaičiavimo metodo pavyzdys: duomenys ir rezultatai.....	23
3. lentelė: Veiksnių parinkimo pavyzdys. Pradiniai ir papildyti duomenys.....	23
4. lentelė: Veiksnių tarpusavio koreliacija. Koreliacija su priklausomu kintamuoju. Pavyzdys.....	24
5. lentelė: Duomenų apie veiksnius, bylos „x.txt“ ir priklausomojo kintamojo bylos „y1.txt“, pavyzdžiai.....	26
6. lentelė: Pavyzdžio rezultatų palyginimas, įvykdant du skirtingus programos kodus.....	26
7. lentelė: Veiksnių suskirstymas, apibūdinimas. Veiksniai, stipriai koreliuoti tarpusavyje.....	31
8. lentelė: Veiksnių suskirstymas, pažymėjimas, apibūdinimas. Kiti veiksniai.....	32
9. lentelė: Optimalių parametrų modelio rezultatai.....	33
10. lentelė: Patikslinto modelio parametrai.....	37
11. lentelė: Greito įvertinimo modelio parametrų lentelė.....	40
12. lentelė: Stipriai koreliuojantys tarpusavyje veiksniai (pirmoji lentelė).....	50
13. lentelė: Veiksniai, stipriai koreliuojantys tarpusavyje (antroji lentelė).....	51
14. lentelė: Įvairūs veiksniai (pirmoji lentelė).....	52
15. lentelė: Įvairūs veiksniai (antroji lentelė).....	53
16. lentelė: Vidutinės būstų kainos Kauno miesto centre (LTL už kvadratinį metrą).....	54
17. lentelė: Sugludintų ir realių verčių palyginimas valiūrų EUR (euro) ir USD (JAV dolerio) kursų santykiui, 1991.01 - 2007.01 laikotarpiu, mėnesio pirmą darbo dieną.....	55
18. lentelė: Veiksnius apibūdinanti darbinė koreliacinė matrica (pirmoji lentelė).....	66
19. lentelė: Veiksnius apibūdinanti darbinė koreliacinė matrica (antroji lentelė).....	67
20. lentelė: Veiksnius apibūdinanti darbinė koreliacinė matrica (trečioji lentelė).....	68



## 1. ĮVADAS

Kiek dabar verti butai Kaune? Kaip tiksliai galime prognozuoti? Ar pirkti, ar parduoti? Nei vienas matematikas negali žinoti ateities, tačiau kiekvienas turi teisę parašyti tokį matematinį modelį, kuris nurodytų, kokia yra aktyvo vertė, jį vertinant pagal praeities įkainius. Šiame darbe bandysime rasti atsakymą į klausimą, ko reikia geram modeliui? Kokius veiksnius reikia parinkti, kad modelis būtų tikslus ir galėtų būti sudarytas per pakankamai trumpą laiką?

Šaltinyje [7] nurodyta, kad mokslininkai Chen, Roll ir Ross 1986 metais daugialypės regresijos analizės metodu sudaromam arbitražo įkainojimo modeliui pasiūlė taikyti kelių ekonominių veiksnių pokyčius (pavyzdžiui: BVP, infliacijos pokyčiai). Taip pat šie mokslininkai apibūdino, kurie veiksniai galėtų būti geriausi taikant tokius modelius. Kaip viena svarbiausių sąlygų buvo nurodyta, kad tų veiksnių pokyčiai būtų viešai pateikiami dažnai, ir greitai po kainos pokyčio fakto atsiradimo.

Tačiau, suprantama, tuo metu (XX a. 9-ajame dešimtmetyje) kompiuterinis skaičiavimo laikas buvo labai brangus. Todėl dabar atsirado galimybė sudaryti modelį, kuris ne tik nurodytų, kurie veiksniai yra geriausiai tinkami daugialypės regresijos lygtimi apramomam modeliui, tačiau ir padėtų sudaryti patį modelį. Tai yra, parenkant geriausią veiksnių rinkinį dar ir nustatyti, pagal kokius veiksnius kinta Lietuvos aktyvų vertės.

Darbe tikimasi, nustačius geriausią veiksnių rinkinį, parinkti regresijos lygtį, su didžiausiu koreguotu determinacijos koeficientu ir patenkinamu multikolinearumo koeficientu. Taip pat apibūdinti veiksnius, kurie yra turimi, ir kurie duotų didesnę tikslumą, jei egzistuotų. Taip pat darbe aprašomas ir veiksnių parinkimas norimam modeliui sudaryti.

Šiame darbe pirmiausiai aprašoma teorija, reikalinga iškeltas sąlygas atitinkančiam regresijos modeliui sudaryti. Tuo pačiu paminėtos sąlygos, kurias reikia patikrinti, sudarant regresijos modelį. Nurodoma, kaip arbitražo galimybė gali būti išnaudota, taikant regresijos modelį. Aprašyta, kaip parinkti tinkamus aktyvus bei jiems aprašyti gerai tinkančius veiksnius.

Metodinėje dalyje aprašytos ir spęstos problemos, apie tai, kaip galima sudaryti visų veiksnių perrinkimo algoritmą, ir kaip galima sumažinti kompiuterinio skaičiavimo laiką. pradiniam skaičiavimams. Kaip parinkti aktyvo ir veiksnių istorinius duomenis, tinkančius tokiai regresijos lygčiai. Pateikiamos rekomendacijos, kaip pataisyti trūkstamus duomenis. Aprašytas kitas modelis, tokios sąlygos išpildymui. Taip pat šioje dalyje yra aprašomas visas modelio algoritmas ir pateikiamas modelio pavyzdys su mažesniais duomenų masyvais tam, kad skaitytojas galėtų suprasti modelio veikimo principą, o norėdamas – ir pakartoti eksperimentą.

Tiriamąjoje dalyje nagrinėjant butų kainas aprašantį regresijos modelį išnagrinėtos kai kurios

duomenų transformacijos (duomenų ištiesinimas). Toliau nagrinėjamas visas modelis, pradedant nuo duomenų parinkimo, baigiant parinktų modelių tinkamumo hipotezių patikrinimu. Aprašyta naudota programinė įranga.

Pateikiamos išvados ir siūlymai, bei pastabos apie darbą.

Pastebėtina, kad net jei prisirinktume daug įvairiausių veiksnių iš praeities, mes negalėtume žinoti, kiek kurių iš jų parinkti. Kurie geriausiai veikia tarpusavyje. Tuo tikslu buvo sukurtas algoritmas, skirtas visų galimų sąveikų perrinkimui, ir apskaičiavimui, kuri sąveika geriausiai prognozuoja įvertinamo aktyvo reikšmes.

Šiuo darbu siekta parodyti skaitytojams ir artimiems draugams, nuo ko gali priklausyti kažkurio dalyko kainos. Dėl to darbo metu sukurtas universalus modelis tinkantis veiksnių įtakai tam tikram aktyvui patikrinti. Taip pat pastebėta, kad modelis gali būti nesunkiai pritaikomas ir arbitražo įkainojimo modeliui aprašyti.

Darbe siekiama patikrinti, kaip paprasčiausiai galima parinkti veiksnius parinkimui į modelį. Taip pat siekta įvertinti, kaip patogiau pasirinkti įvairius socialinius veiksnius.

## 2. TEORINĖ DALIS

### 2.1. DAUGIALYPĖS REGRESIJOS MODELIS, JO TAIKYMAS FINANSUOSE

Nagrinėkime investicinį portfelį, sudarytą iš vienos rūšies aktyvų, ir valiutos, pagal kurią skaičiuojama tų aktyvų kaina. Tarsime, kad investuojama yra labai daug kartų. Šiame darbe nagrinėsime investicinį aktyvų įvertinimo modelį, kuris aprašomas tiesine daugialype regresijos lygtimi (1), kurios priklausomas kintamasis priklauso nuo  $m$  veiksnių.

$$Y_i = a + b_1 \cdot x_{1i} + b_2 \cdot x_{2i} + \dots + b_m \cdot x_{mi} + e_i \quad (1)$$

šioje regresijos lygtyje  $Y$  yra priklausomas kintamasis, kurio  $i$ -tąją reikšmę norime prognozuoti esant žinomoms ir pastovioms nepriklausomų kintamųjų  $X_1, X_2, \dots, X_m$  reikšmėms, atitinkamai:

$x_{1i}, x_{2i}, \dots, x_{mi}$ . Dydis  $e_i$  laikomas atsitiktine modelio paklaida. Norint pilnai aprašyti šį modelį, reikia rasti lygties koeficientus  $a, b_1, b_2, \dots, b_m$ . Mes, vadovaudamiesi tik kelių periodų statistiniais duomenimis negalime nustatyti, nuo ko tiksliai priklauso priklausomas kintamasis, dėl to ieškosime modelio koeficientų įverčių:  $\hat{a}, \hat{b}_1, \hat{b}_2, \dots, \hat{b}_m$ .

Tiesinės daugialypės regresijos modelio prielaidos, kad modelis galėtų būti taikomas sėkmingai, pagal [2] yra šios:

- 1)  $e_i$  normaliai pasiskirstę atsitiktiniai dydžiai;
- 2) visų  $e_i$  vidurkiai lygūs nuliui;
- 3) dydžių  $e_i$  dispersijos lygios pastoviam skaičiui;
- 4) modelio liekanas aprašantys nariai, t.y. dydžiai  $e_i$ , yra nepriklausomi

Paskaičiuokime priklausomo kintamojo vidurkį:

$$E Y_i = a + b_1 x_{1i} + b_2 x_{2i} + \dots + b_k x_{ki} \quad (2)$$

iš (2) formulės matome, kad investicijose visuomet pasikliaujant (1) lygtimi – dydis  $E e_i$  artės prie nulio, arba kitaip sakant: jei investiciniame portfelyje bus  $n$  vienodas savybes turinčių aktyvų, tuomet gausime, kad tokiems skaičiavimams galios regresijos tiesės lygtis:

$$\hat{y}(x_1, x_2, \dots, x_m) = \hat{a} + \hat{b}_1 \cdot x_1 + \hat{b}_2 \cdot x_2 + \hat{b}_k \cdot x_k \quad (3.1)$$

Arba panašią lygtį, kai  $\hat{a} = 0$  :

$$\hat{y}(x_1, x_2, \dots, x_m) = \hat{b}_1 \cdot x_1 + \hat{b}_2 \cdot x_2 + \hat{b}_k \cdot x_k \quad (3.2)$$

Taip pat regresijos lygčiai taikomi tokie papildomi reikalavimai:

- 1) lygtyje esantys priklausomi kintamieji neturi stipriai koreliuoti tarpusavyje;
- 2) lygtyje esantys priklausomi kintamieji neturi koreliuoti su liekanomis.

Koeficientų įverčiai turi būti gaunami tokie, kad funkcijos (3.1) reikšmės taškuose ( $x_{1i}, x_{2i}, \dots, x_{mi}$ ) kuo mažiau skirtųsi nuo  $y_i$  verčių. Arba kitais žodžiais: visos liekanosios paklaidos būtų kiek įmanoma mažesnės.

Įverčiai  $\hat{a}, \hat{b}_1, \hat{b}_2, \dots, \hat{b}_m$  programiniu būdu nesunkiai apskaičiuojami. Apskaičiavimo metodai aprašomi [8] šaltinyje. Tam, kad galėtume apskaičiuoti koeficientus, pirmiausiai suvedame regresijos lygtį į matricinę formą:

$$Y = X \cdot B + \hat{\epsilon} \quad (4)$$

Čia

$$B = (a \quad b_1 \quad \dots \quad b_m)^T \quad (5)$$

$$\epsilon_i = (\epsilon_{1i} \quad \epsilon_{2i} \quad \dots \quad \epsilon_{ni})^T \quad (6)$$

$$X = \begin{pmatrix} 1 & \hat{x}_{11} & \dots & \hat{x}_{1m} \\ 1 & \hat{x}_{21} & \dots & \hat{x}_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & \hat{x}_{n1} & \dots & \hat{x}_{nm} \end{pmatrix} \quad (7)$$

$$Y_i = (Y_{1i} \quad Y_{2i} \quad \dots \quad Y_{ni})^T \quad (8)$$

tuomet įverčių matrica:

$$\hat{B} = (X^T \cdot X)^{-1} \cdot X^T \cdot Y \quad (9)$$

Toliau koeficientą  $a$  žymėsime  $b_0$ .

Tokiu būdu gauti lygties koeficientai įrašomi į regresijos lygties modelį. Tačiau tokia lygtis dar gali ir netikti taikymui. Šaltinyje [2] nurodomos tokios galimos kliūtys taikyti regresijos modeliui:

1) Reikia patikrinti hipotezę apie bent vieno koeficiento  $b_j$  nelygumą nuliui (tikrinamas F kriterijus). Tuomet statistinės hipotezės formuluotė:

$$\begin{cases} H_0: b_1 = b_2 = \dots = b_m = 0 \\ H_1: \text{bent vienas } b_j \neq 0 \end{cases}, \text{ kai } j = 1 \dots m.$$

2) Jei 1-osios sąlygos nulinė hipotezė atmetama, tuomet dar reikia patikrinti ir studento kriterijų, t.y. šiame žingsnyje tikrinama hipotezė apie kiekvieno koeficiento  $b_j$  lygumą nuliui. Tikrinamos hipotezės visiems koeficientams:

$$\begin{cases} H_0: b_j = 0, \\ H_1: b_j \neq 0. \end{cases}, \text{ kai } j = 1 \dots m$$

3) Jei pirmos dvi sąlygos yra patenkinamos, tuomet modelio koeficientų stabilumui gali trukdyti *multikolinearumo* problema. Jei multikolinearumas yra didelis, tuomet reikia atmesti kai kuriuos tarpusavyje stipriai koreliuojančius veiksnius, atsižvelgiant į jų įtaką modelio determinacijos koeficientui.

4) Ketvirtoji sąlyga reikalauja, kad modelio liekanos būtų pasiskirsčiusios pagal normalųjį skirstinį. Tikrinama modelio liekanų normalumo hipotezė:

$$\begin{cases} H_0: \text{liekamosios paklaidos nepasiskirsčiusios pagal normalųjį skirstinį,} \\ H_1: \text{liekamosios paklaidos pasiskirsčiusios pagal normalųjį skirstinį.} \end{cases}$$

5) Paskutinė sąlyga yra nesunkiai įvertinama grafiškai. Reikia atlikti liekamųjų paklaidų grafinę analizę, ir stebėti, ar tikrai visos modelio liekanos yra išsibarsčiusios apie tiesę  $y=0$  maždaug vienodai ir ar nėra nuo šios tiesės per daug nutolusios. Jei sąlygos tenkinamos, tuomet regresijos modelis tinka.

**Pirmajai sąlygai** patikrinti skaičiuojamos trys sumos:

$$SST = SSR + SSE \quad (10)$$

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (11)$$

$$SSR = \sum_{i=1}^n (\hat{y}(\mathbf{x}_i) - \bar{y})^2 \quad (12)$$

$$SSE = \sum_{i=1}^n \hat{e}_i^2 \quad (13)$$

čia  $y_i$  - turėta priklausomo kintamojo  $i$ -toji reikšmė,  $\hat{y}(\mathbf{x}_i)$  - pagal modelį gauta priklausomojo kintamojo reikšmė pagal  $i$ -tąsias visų nepriklausomų kintamųjų reikšmes,  $\bar{y}$  - visų priklausomo kintamojo reikšmių vidurkis, o  $\hat{e}_i = \hat{y}(\mathbf{x}_i) - y_i$  - regresijos lygties liekamosios paklaidos

(liekanos). Dydis SST yra vadinamas *visa kvadratų suma*, SSR – *regresijos kvadratų suma*, SSE – *liekamųjų paklaidų kvadratų suma*.

Tuomet yra normuojamos sumos SSR ir SSE:

$$MSR = \frac{SSR}{m} \quad (12.1)$$

$$MSE = \frac{SSE}{n-m-1} \quad (13.1)$$

kriterijaus statistika:

$$F = \frac{MSR}{MSE} \quad (14)$$

Hipotezė  $H_0$  neatmetama, jeigu  $F \leq F_{\alpha}(m, n-m-1)$ .

**Antrajai sąlygai** tikrinti yra sudaromas naujas regresijos modelis, kuriame nepriklausomi kintamieji yra  $X_1, \dots, X_{j-1}, X_{j+1}, \dots, X_n$  o kintamasis  $X_j$  yra šio modelio priklausomas kintamasis. Apskaičiuojama tokio modelio liekamųjų kvadratų suma:  $SSE_j$ . Tokiu atveju Stjudento kriterijaus statistika yra:

$$t = \frac{\hat{b}_j}{\sqrt{MSE/SSE_j}} \quad (15)$$

Tokiu atveju hipotezė  $H_0$  atmetama, jei su reikšmingumo lygmeniu  $\alpha$  gauname, jog

$$|t| > t_{\alpha/2}(n-m-1) \quad (15.1)$$

Čia  $(n-m-1)$  – Stjudento kriterijaus laisvės laispniai, o  $\alpha/2$  – kritinė reikšmė.

**Trečioji sąlyga** patikrinama paskaičiuojant *dispersijos mažėjimo daugiklį* VIF (angl. „Variance Inflation Factor“):

$$VIF = \frac{1}{1-r_j^2} \quad (16)$$

čia  $r_j^2$  yra tokio regresijos modelio, kuriame  $X_j$  yra priklausomas kintamasis, o  $X_1, \dots, X_{j-1}, X_{j+1}, \dots, X_m$  - nepriklausomi kintamieji, determinacijos koeficientas (žr. 20 formulę). Literatūroje [2] laikoma, kad „kintamasis  $X_j$  yra per daug multikolinearus, jeigu  $VIF > 4$ “. Šis koeficientas interpretuojamas, kaip regresijos lygties koeficiento įverčio  $\hat{b}_j$  dispersijos santykis su ta dispersija, kurią šis koeficientas turėtų, jei veiksny  $X_j$  nekoreliuotų su likusiais veiksniais. Trečiaja sąlyga darbe ir remsimės, atskirdami tinkamus veiksnius nuo per daug multikolinearių.

**Ketvirtoji sąlyga** darbe liekamųjų paklaidų pasiskirstymo pagal normalųjį skirstinį hipotezė yra tikrinama Kolmogorovo kriterijumi pagal [9] šaltinį. Tikrinama tokia suderinamumo hipotezė:

$H_0: F_f(x) \equiv F_0(x)$ .  $F_f(x)$  - tam tikro, stebėto, tolydaus skirstinio funkcija.  $F_0(x)$  - nepriklausantis nuo nežinomų parametru skirstinys. Nagrinėjamo modelio atveju – Normaliojo skirstinio funkcija. Hipotezė tikrinama tokiu būdu: paimamas visų liekanų vektorius  $\{e_i\}$ ,

surikiavus didėjimo tvarka gaunama variacinė seka  $\{e_{(i)}\}$ . Tuomet paskaičiuojamos funkcijos reikšmės gautuose variacinės sekos reikšmėse:  $\{F_0(e_{(i)})\}$ . Šios gautos reikšmės reikalingos dydžio  $D_m$  įvertinimui, kai

$$D_m = \max(D_m^a, D_m^b) \quad (17)$$

$$\text{Be to: } D_m^a = \max_{1 \leq k \leq m} \left( \frac{k}{m} - F_0(e_{(k)}) \right) \quad (18.1)$$

$$\text{ir } D_m^b = \max_{1 \leq k \leq m} \left( F_0(e_{(k)}) - \frac{k-1}{n} \right) \quad (18.2)$$

čia  $e_{(k)}$  – k-tasis variacinės eilutės narys. Tuomet jei tenkinama sąlyga:

$k_{1-\alpha} > D_n$  tuomet hipotezė  $H_0$  yra atmetama, t.y. skirstinys normalusis su tikėtinumu  $1-\alpha$ .

$$k_{1-\alpha} \approx \sqrt{\frac{-\ln\left(\frac{\alpha}{2}\right)}{2 \cdot m}} - \frac{1}{6 \cdot m} \quad (19)$$

kai  $n > 50$ . Čia  $\alpha$  – reikšmingumo lygmuo,  $m$  – liekamųjų paklaidų imties dydis.

Tikrinant **penktąją sąlygą**, tam, kad pamatytume, kaip priklausomas kintamasis  $Y$  priklauso nuo konkretaus veiksnio  $X_j$  - atliekami tokie veiksmai:

- pirmiausiai sudaromas regresijos modelis su veiksnių rinkiniu, neįtraukiant to veiksnio, nuo kurio priklausomybė yra nagrinėjama, ir tuo pačiu priklausomu kintamuoju. Randamos šio modelio liekamosios paklaidos  $e_k(y, j)$ .

- Po to sudaromas regresijos modelis su veiksnių rinkiniu, neįtraukiant to veiksnio, kurio priklausomybė yra nagrinėjama, priklausomu kintamuoju naudojant tą veiksnį, kuris išrinktas iš veiksnių rinkinio. Randamos šio modelio liekamosios paklaidos  $e_k(x_j, j)$ .

- Braižomas grafikas iš reikšmių  $(e_k(x_j, j); e_j(y, j))$ . Jei priklausomybė yra artima tiesinei, tuomet  $X_j$  tinka modeliui.

Kai tampa aišku, kuris modelis yra priimtinas, o kuris ne – reikia pasirinkti, kuris modelis yra geresnis, o kuris prastesnis. Tam literatūroje [1], [2] yra rekomenduojama naudoti determinacijos koeficientą:  $r^2$ . Jį galima apskaičiuoti žinant (11) ir (12) sumų reikšmes nagrinėjamam modeliui. Šio koeficiento išraiška (20):

$$r^2 = \frac{SSR}{SST} \quad (20)$$

determinacijos koeficientas nurodo, kurią priklausomo kintamojo pokyčių dalį paaiškina regresijos modelis. Nagrinėjamame modelyje yra naudojamas *koreguotasis determinacijos koeficientas* (21).

$$r_{adj}^2 = 1 - \frac{n-1}{n-m-1} \cdot (1-r^2) \quad (21)$$

Šis koeficientas yra naudojamas tuomet, kai kintamųjų skaičius  $m$  nedaug skiriasi nuo stebėjimų skaičiaus  $n$ . Šis koeficientas, kaip ir aprašytas (20) formule, interpretuojamas taip pat: kuo jis artimesnis vienetui, tuo geriau priklausomojo kintamojo  $Y$  reikšmes aprašo regresijos modelyje esančių nepriklausomų kintamųjų pokyčiai.

Tokiu būdu yra parenkamas modelis, turintis mums tinkamos vertės multikolinearumą ir didžiausią determinacijos koeficientą.

Pastebėjime, kad nagrinėtame modelyje visus nepriklausomus kintamuosius pakeitę į ekonominius ar socialinius veiksnius gauname sąryšį, kuriame aktyvo grąžą galime išreikšti per  $m$  veiksmų:  $(\hat{F}_1, \hat{F}_2, \dots, \hat{F}_m)$ . Tokiu būdu yra sudaroma regresijos funkcija, įvertinti aktyvo vertei, esant tam tikroms nagrinėjamų veiksmų reikšmėms.

## 2.2. ARBITRAŽO GALIMYBĖ

Arbitražo galimybe yra laikoma tokia situacija, kai dvejose vietose vienu metu aktyvas yra įvertintas nevienodai. Pats arbitražas (angl. - „arbitrage“) literatūroje [7] apibrėžiamas taip:

„Arbitražas yra galimybė, pasinaudojant kainų skirtumu tarp dviejų arba daugiau rinkų, atsidurti patogesnėje prekybos pozicijoje: tokiu atveju pelnas yra aktyvo verčių skirtumas tarp rinkos, kur yra didžiausia ir mažiausia kaina“. Žinodami determinacijos koeficientą pagal jį galime įvertinti, kiek rizikinga yra pasinaudoti arbitražo galimybe. Tai yra – modelio determinacijos koeficientas padeda mums apsispręsti, kurį metodą taikyti ieškant arbitražo.

Literatūroje [1] ir [5] nurodoma, kad arbitražo galimybę galima taikyti dviem skirtingais atvejais: Pasinaudojant arbitražo įkainojimo teorija (AIT - angl. „Arbitrage Pricing Theory – APT“) arba siekiant didesnio vertės nustatymo tikslumo. Nagrinėjant pastarąjį modelį galima įvertinti, kiek pinigų reikia siūlyti akcijų biržoj už vertybinius popierius, ūkininkui už mėsą, ar pardavėjui už parduodamą butą pirmiau, negu rinka spėja sureaguoti į kainų pokyčius. Taip pat, jei į lygtį įtraukti nepriklausomi priežastiniai veiksniai, tuomet pagal naudingą ekonominę informaciją investuotojas gali spėti apie vieno ar kito veiksmo pokyčius. Tuomet pasinaudodamas lygtimi investuotojas gali spėti, kiek daug keisis aktyvo kaina, ir tuo pačiu gali spėti, ar verta pradėti pirkimo/pardavimo veiksmus, ar geriau dar kurį laiką palaukti.

Darbe aprašytas ir programiškai sukurtas modelis gali būti naudojamas išnaudoti arbitražo galimybę pelnui gauti tiek daugialypės regresijos metodu, tiek naudojant arbitražo įkainojimo teorijos pagrindus. Tačiau toliau bus daugiau gilinamasi į daugialypės regresijos metodu įkainotus aktyvus, nes darbe daugiau nagrinėjamos rinkų tendencijos, o ne didelis skaičius aktyvų, kuris yra reikalingas

arbitražo įkainojimo modeliui. Tačiau, jei teigsime, kad visi aktyvai yra perkami vienoje rinkoje – tuomet rinkos tendencijas galima aprašyti kaip vieno investicinio portfelio vertės kitimą. Tokia galimybė detaliau aprašoma šaltinyje [1].

Kaip nurodyta [3] – arbitražu įvertinti galima vieną aktyvą, kai pastebima, jog pagal modelį nustatyta aktyvo vertė statistiškai reikšmingai skiriasi nuo dabartinės rinkos vertės. Tai yra – jei aktyvas realybėje kainuoja pastebimai brangiau, negu apskaičiuojama pagal didelio patikimumo modelį, tuomet aktyvą reikia pasiskolinti ir parduoti (angl – „short sell“). Po to, aktyvo kainai rinkoje sumažėjus – aktyvas nuperkamas pigiau, negu buvo parduotas ankstesniu laiko momentu. Kitu atveju, jei aktyvo kaina rinkoje yra mažesnė negu apskaičiuota pagal modelį - nusiperkamas aktyvas, ir rinkoje jo kainai padidėjus iki realios kainos – aktyvas parduodamas brangiau, negu buvo nupirktas. Kaip nurodoma [6] – Arbitražo įkainojimas, skirtingai negu daugelis kitų modelių, yra laikojimas vieno periodo modeliu.

### 2.3. AKTYVŲ IR VEIKSNIŲ PARINKIMAS INVESTICIJOMS

Bendru atveju literatūroje [1] laikoma, jog aktyvas gali būti bet koks vertybinis popierius, ar investicinis portfelis, sudarytas iš vertybinių popierių. Tokiu atveju laikoma, kad vertybiniai popieriai gali būti:

- buto nuosavybės teisės;
- automobilio techninis pasas;
- metalo nuosavybės teisės;
- kiti dokumentai, nurodantys teisę į tam tikrą vertę turintį turtą.

Darbe nagrinėjamas butų vertės pokytis bėgant laikui: tiriamas vidutinio būsto, esančio Kauno miesto centre, kvadratinio metro kainos pokytis. Taip pat analizuojamos kitų aktyvų kainos:

- vidutinės apvaliosios medienos kainos Kauno rajono urėdijoje (litais už kubinį metrą);
- vidutinis butų kainos pagal S&P indeksą Los Andželo mieste, JAV;
- vištienos kainos pokytis JAV.

Nagrinėti įvairių veiksnių įtaką labai skirtingiems aktyvams yra gerai tuo, kad skirtingu laikotarpiu gali būti skirtinga paklausa ir pasiūla skirtingose rinkose.

Literatūroje [1] ir [3] nurodomi ekonomistų Chen, Roll ir Ross siūlomi veiksniai:

Daugialypiams modeliams geriausiai tinka tie veiksniai, apie kurių pokyčius galima sužinoti beveik iš karto, tai gali būti tokie ekonominiai veiksniai, kaip:

- infliacijos pokyčiai;
- nagrinėjamos šalies BVP pokyčiai;
- ilgalaikių vyriausybinių obligacijų pokyčiai;



– investuotojų pasitikėjimas investicijomis, priklausantis nuo gražos, gaunamos iš turimų aktyvų.

Pavyzdžiui infliaciją šie ekonomistai pasiūlė aprašyti tokiu būdu: „infliacijos dydis, tikėtinas mėnesio pradžioje, minus infliacijos dydis, išmatuotas mėnesio pabaigoje.“ (pagal [1]).

Sukurtoje programoje yra aprašomi du modeliai, pirmasis nagrinėja visus galimus veiksmų rinkinius. Antrasis modelis leidžia pasirinkti tuos veiksmų rinkinius, dėl kurių didelės tarpusavio koreliacijos mes esame užtikrinti; tai yra investuotojas yra užtikrintas, kad dėl multikolinearumo sąlygos nepatenkinimo tie du veiksniai tikrai nebus parinkti viename modelyje. Tokiu būdu galime atrinkti daug daugiau įvairių veiksmų rinkinių per daug trumpesnį laiką.

## 2.4. INVESTICINIŲ MODELIŲ PARINKIMO PROBLEMOS IR DARBE SPRENDŽIAMŲ UŽDAVINIAI

Kaip nurodyta [1] šaltinyje – galima kurti ir maišytus modelius (angl. „mixed-model“). Juose galima apjungti skirtingus modelius, gaunant iš jų norimus rezultatus. Savo darbe taikau arbitražo įkainojimo teorijos ir daugialypės regresijos modelius. Pirmiausiai parenkami ekonominiai ir socialiniai veiksniai, kurie, tikimasi, turės įtaką priklausomam kintamajam. Tuomet parenkamas geriausias regresijos modelis. Galiausiai įvertinamas modelio tikslumas, ir tokiu būdu galime įvertinti, ar galime pasinaudoti arbitražo galimybe konkrečiam aktyvui, ar bandymas pasinaudoti arbitražo galimybe yra per daug rizikingas dėl prekybos mokesčių ir mums nežinomų veiksmų įtakos. Laikoma, kad nagrinėjama visa rinka, iš kurios parinka daug tos pačios rūšies aktyvų, tokiu būdu sumažinant diversifikuojamą riziką.

Apibūdindami daugialypės regresijos su ekonominiais ir socialiniais veiksniais aktyvų įkainojimo modelį, paprasčiausiais žodžiais galime sakyti, kad šio modelio pagalba galime lengviau apsispręsti, ar verta pirkti aktyvą už mums pasiūlytą kainą. Arba kitu atveju: ar verta parduoti aktyvą už tą kainą, kurią pasiūlė galimas pirkėjas. Ir tuo pačiu galime sužinoti, kokio pelno tikėtis tą aktyvą pardavus.

Trumpai aprašysime arbitražo įkainojimo teoriją. APT modelį aprašo toks daugialypės regresijos lygties atskiras atvejis:

$$E[\hat{R}_i] - R_f = \lambda_1 b_{i1} + \lambda_2 b_{i2} + \dots + \lambda_m b_{im} \quad (22)$$

Čia  $R_f$  - nerizikinga palūkanų norma nagrinėjamu momentu. Darbe laikysime,  $\bar{R}_i$  - priklausomojo kintamojo graža.  $\lambda_1, \dots, \lambda_m$  yra ekonominiai veiksniai sunormuoti taip, kad vidurkis būtų lygus nuliui, ir jie būtų paskirstę pagal normalųjį skirstinį. Vidurkio lygumas nuliui yra reikalingas todėl, kad modelyje neatsirastų konstanta. Akivaizdu, kad skaičiuojant vidutinę tokio

modelio reikšmę ir esant lygties konstantai, nelygiai nuliui, bus gautas garantuotas pelnas, nepriklausantis nuo veiksnių. O tai reiškia, kad galima arbitražo sąlyga pasinaudoti bet kuriuo momentu. Gauta sąlyga leistų gauti neribotą pelną. O tai prieštarauja arbitražo sąlygos apibrėžimui. Taip pat kitos sąlygos galioja tokios pačios, kaip ir daugialypės regresijos lygtčiai. Kairėje (22) lygybės pusėje esantis skirtumas skaičiavimo metu gali būti suvedamas į vieną veiksnį; iš priklausomojo kintamojo  $i$ -tosios reikšmės atimama nerizikinga palūkanų norma tuo momentu. Toliau lygtis nagrinėjama kaip atskiras (3.2) funkcijos atvejis. Šio modelio rizika yra tame, jog esant mažam determinacijos koeficientui, reikia imti daugiau aktyvų, kad būtų galima išlyginti nesisteminę (diversifikuojamą) riziką. Dėl to arbitražo įkainojimo modelis geriau tinka aktyvams, kurie gali būti perkami didesniais kiekiais ir kurių kaina yra vienareikšmė. Mūsų darbe yra nagrinėjami butai, kurie dažniausiai kainuoja didesnius pinigus negu paprastos akcijos. Todėl šiuo atveju mums reikia taikyti modelį, kuris turi didesnę determinacijos koeficientą.

Darbe siekiama sukurti modelį, kurio pagalba būtų galima parinkti veiksnių rinkinį, tiksliausiai prognozuojantį aktyvo kainas. Gautų veiksnių rinkinio tiesinio darinio pokyčiai turėtų gerai paaiškinti priklausomojo kintamojo pokyčius, kad pasinaudojus šiuo modeliu, būtų galima pasinaudoti arbitražo galimybe, esant palankiai situacijai. Sukūrus tokį modelį siekiama išnagrinėti veiksnių rinkinius geriausiai apibūdinančius Kauno miesto centro būstų kainų kitimą, ar bet kokius kitus aktyvus. Taip pat parinkti, kurį modelį kurio aktyvo vertinimui yra geriau taikyti.

### 3. METODINĖ DALIS

#### 3.1. GERIAUSIO VEIKSNIŲ RINKINIO PARINKIMAS MODELyje

Darbo užduoties vykdymo eigoje buvo spręsta problema – kaip rasti geriausią veiksnių rinkinį daugialypės regresijos lygtyje. Pirmiausiai didesnio aiškumo dėlei buvo išsikelta sąlyga rezultatus pateikti kompiuterinėje rezultatų tekstinėje byloje. Dėstoma tokiu būdu: pradžioje išrenkamas geriausias rinkinys iš tų, kurie turi mažiausią galimą veiksnių skaičių. Geriausiu rinkiniu laikomas tas, kurio multikolinearumą aprašantis dispersijos mažėjimo daugiklis VIF nei vienam veiksniai neviršija 4, ir kurio determinacijos koeficientas yra didžiausias tarp tų patį veiksnių skaičių turinčių rinkinių. Po to rašomas to modelio rezultatas, kuris duoda tiksliausius rezultatus, turėdamas vienu veiksnium daugiau. Ir taip toliau, kol galiausiai įrašomas visus veiksnius apimantis modelis. Vartotojas pasižiūrėjęs į šią bylą gali nuspręsti, kiek veiksnių turintis modelis jam yra priimtinausias.

Aišku, kadnagrinėsime modelį, priklausantį nuo  $m$  skirtingų veiksnių, tuomet programiniu būdu turės būti išnagrinėta iš viso  $K = \sum_{i=1}^m C_m^i = 2^m - 1$  galimybių. Pavyzdžiui, kai nagrinėjama 15 veiksnių, tai yra nagrinėjama 32767 skirtingų rinkinių, kai 17 veiksnių – 131071 veiksnių, o kai 20 – tuomet jau

nagrinėjami 1048575 veiksniai. Turint 1.6GHz spartos procesorių, buvo atliktas testas, skirtas nustatyti laikui, reikalingam rasti optimalų veiksmų rinkinį, atitinkantį nustatytus optimalumo kriterijus. Laikas, per kurį parenkamas geriausių veiksmų rinkinys, ir kiti dydžiai, gauti eksperimente yra nurodyti 1 lentelėje.

**1. lentelė: Resursai, reikalingi optimaliam veiksmų rinkiniui rasti**

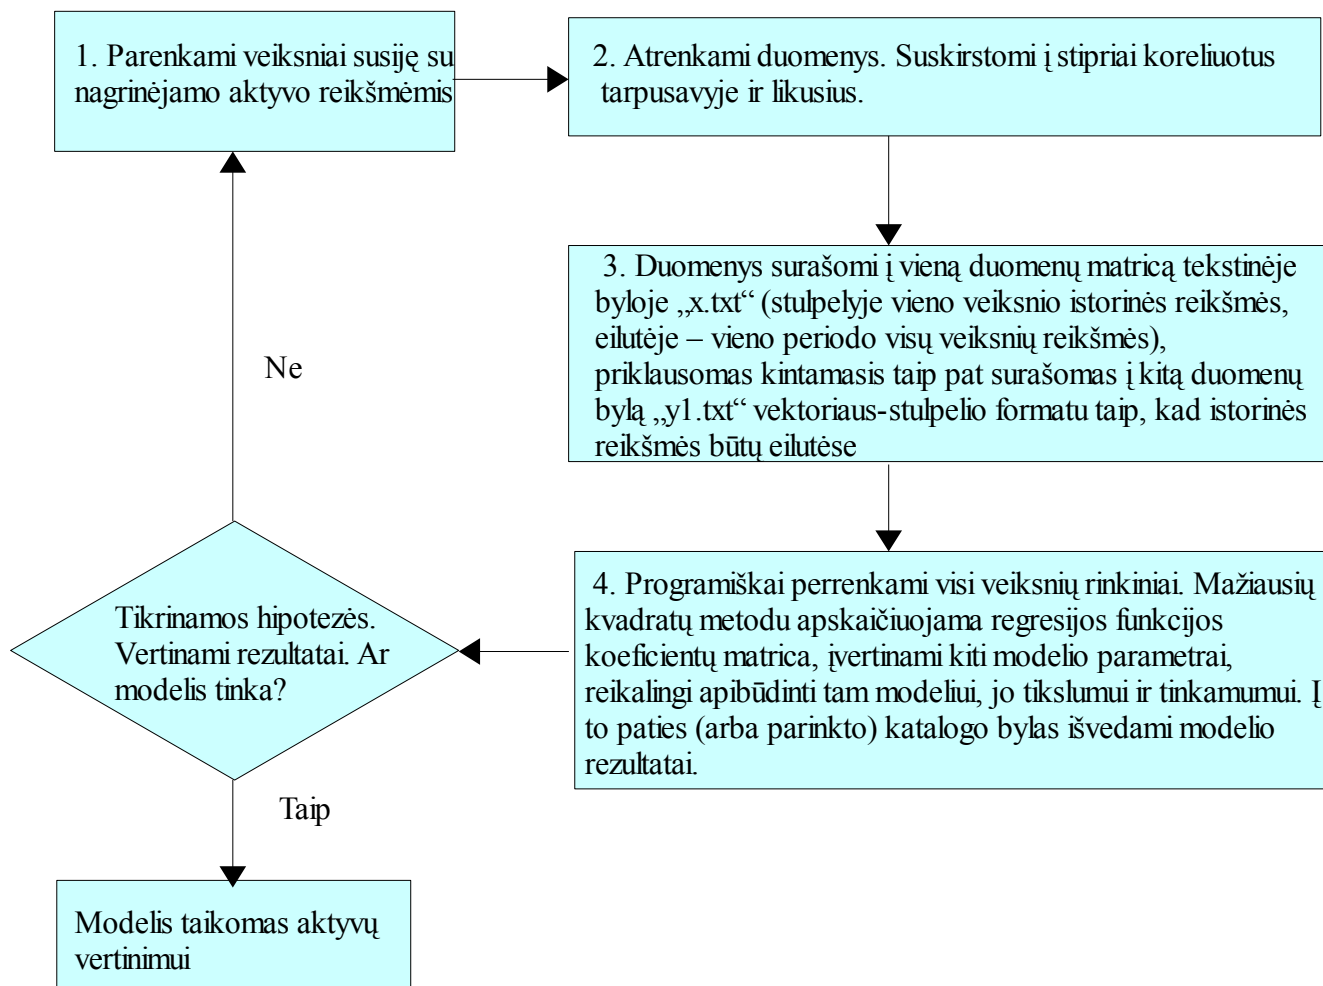
Veiksmų sk. (m)	Kompiuterio laikas (sekundėm)	Galimybių skaičius ( $2^m - 1$ )	Vidutinis laikas, skirtas patikrinti vienai galimybei
9	10.39	511	0.020
10	24.14	1023	0.023
11	51.39	2047	0.025
12	116.81	4095	0.029
13	330.16	8191	0.040
14	1651.3	16383	0.1

Iš 1 lentelės matome, kad kompiuteriu tiesiogiai parenkant optimalų modelį iš, sakykime, 20 veiksmų ( $2^{20} - 1 = 1048575$ ), reiktų nagrinėti ilgą laiką (net jei laikytume, kad vienai galimybei apskaičiuoti reikės vidutiniškai 0.11 sekundės – apdoroti 20 veiksmų duomenų bazei reiktų apie 32 valandų. Nors aišku tai, kad su kiekvienu papildomu veiksmu vidutinis laikas, reikalingas apdoroti vienai galimybei, didėja). Darbe spręsimė ir šią problemą: kaip sutrumpinti optimalių veiksmų rinkinių parinkimui reikalingą laiką.

### 3.2. MODELIO SUDARYMAS, ALGORITMAI, SUDĖTINGUMAS

Modeliui sudaryti buvo sukurti keli skaičiavimo algoritmai (interpoliavimui, rezultatų apskaičiavimui ir išvedimui) su matematinio skaičiavimo įranga SCILAB, o pagalbiniai skaičiavimai (duomenų parinkimas, suskirstymas, hipotezių patikrinimas) su Open Office „Spreadsheet“ programa. Programa yra panaši į paketo MS Office skaičiuoklę „Excel“.

1 pav. Programos veikimo algoritmas



Rezultatuose pateikiamas tiek modelio determinacijos koeficientas, tiek koreguotasis determinacijos koeficientas. Į koreguotąjį determinacijos koeficientą reikia atsižvelgti tuomet, kai koeficientų skaičius  $k$  nedaug skiriasi nuo matavimų skaičiaus  $n$ . Toliau darbe remsimės tik koreguotuoju determinacijos koeficientu, nes didėjant stebėjimų skaičiui  $n$  šis koeficientas artėja prie

determinacijos koeficiento.

Regresijos funkcija yra tinkama naudoti tuomet, kai prognozuojamos reikšmės nėra didesnės už priklausomojo kintamojo, pagal kurį prognozė atlikta, didžiausią reikšmę, ir nėra mažesnė už to kintamojo mažiausią reikšmę.

### 3.3. DUOMENŲ SUDARYMAS IR PARINKIMAS MODELIUI

Duomenys nepriklausomiems kintamiesiems parenkami taip, kad būtų bendruose perioduose su priklausomu kintamuoju. Tuo atveju, kai veiksniai ankstesnio periodo koreliacija su priklausomu kintamuoju yra didesnė, ar pakankamai didelė, skaičiavimuose galima naudoti keliais periodais paslinktus duomenis. Toks būdas leistų įvertinti galima kainų pokytį ateityje, arba tiesiog lengviau gauti ankstesnių periodų duomenis. Jei duomenys nėra pakankami, tuomet užpildyti trūkstamas spragas galima naudojant glodinantį splainą su vienodais arba skirtingais svoriais prie įverčių, jei duomenų skaičius skirtingiems periodams yra nevienodai patikimas.

Jau turint visus duomenis ir priklausomojo kintamojo statistines reikšmes reikia atlikti tų duomenų pradinę analizę – suskirstyti veiksnius į stipriai koreliuotus tarpusavyje, ir į tuos, tarp kurių koreliacija nėra didelė. Šį didumą turėtų nustatyti pats investuotojas, priklausomai nuo jo kompiuterio galimybių. Parinkęs mažesnę dydį, investuotojas rizikuoja netekti kai kurių veiksmų rinkinių tolesnėje analizėje, tačiau tokiu atveju išlošia programinio laiko. Į rinkinį, kur kintamieji yra stipriai koreliuoti tarpusavyje, parenkami tie veiksniai, kurie tikrai neįeis į vieną geriausią rinkinį dėl multikolinearumo sąlygos (žr. (16) ir (23) formules). Dėl to į koreliuotų veiksmų rinkinį rekomenduojame parinkti tuos kintamuosius, kurių  $j$ -tojo veiksmo determinacijos koeficientas, kai jis yra priklausomas kintamasis regresijos lygtyje nuo kitų veiksmų, yra didesnis negu 0.75. Iš (16) sąlygos turime, kad jei egzistuoja multikolinearumas, tuomet veiksmo determinacijos koeficientas anksčiau minėtame modelyje turės būti ne mažesnis, negu:

$$r_j^2 = \lim_{VIF \rightarrow 4} \frac{(VIF - 1)}{VIF} = 0.75 \quad (23)$$

Kai  $VIF \rightarrow +\infty$ , tuomet  $r_j^2 \rightarrow 1$ .

Į geriausią parinktą modelį gali įeiti vienas veiksnys iš gerai koreliuotų tarpusavyje, ir keli veiksniai iš kito veiksmų rinkinio. Suprantama, kad tuomet, kai yra labai daug ekonominių veiksmų (tiek, kad modelio įvykdymas kompiuteriu užtruktų ilgiau, negu investuotojas tikisi), prioritetu reikėtų patinkinti tuos, kurių koreliacija su priklausomu kintamuoju statistiškai reikšmingai skiriasi nuo nulio.


Pasinaudojant modeliu ir parinkus geriausią veiksmų rinkinį reikia patikrinti hipotezes, apie to rinkinio tinkamumą regresijos lygčiai. Tuo atveju, kai bent viena hipotezė nėra atmetama (nepriimama bent viena alternatyvi hipotezė), reikia išsiaiškinti, kas tą įtakojo. Šias kliūtis pašalinus (pavyzdžiui

vieną periodą, buvo išskirtis ar pan.) modelį reikėtų perskaičiuoti iš naujo, taip parenkant optimalų veiksmų rinkinį, tokį, kurį naudojant būtų tenkinamos visos statistinės hipotezės, naudojamos apibūdinti regresijos lygčiai.

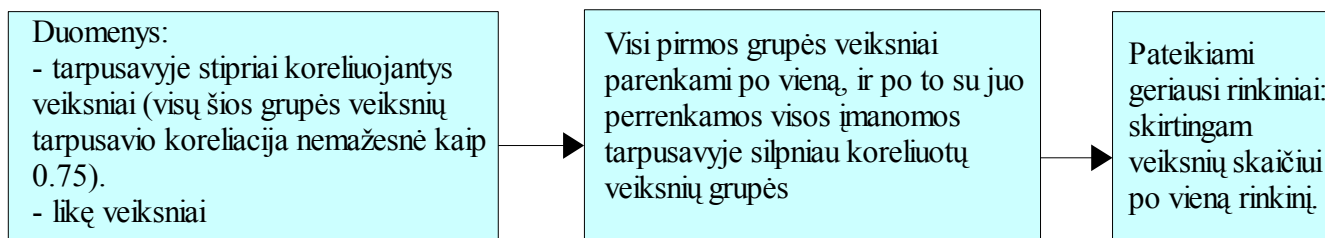
### 3.4. AKTYVŲ ĮKAINOJIMO STATISTINIS MODELIS

Yra sukurti du modeliai, vienas skirtas greitesniam skaičiavimui, kai keli veiksniai yra stipriai koreliuoti tarpusavyje, kitas – visų galimų veiksmų grupių perrinkimui, kai koreliacijos yra įvairios. Suprantama, kad kuo daugiau yra veiksmų, tuo daugiau skiriasi šių modelių veikimo laikas (iki 1000 kartų ir daugiau). Trumpai šie du modeliai apibūdinti 2. ir 3. paveiksluose.

#### 2 pav: Pirmasis aktyvų įkainojimo statistinis modelis



#### 3 pav: Antrasis aktyvų įkainojimo statistinis modelis



### 3.5. MODELIO SUDARYMO PAVYZDYS

Sakykime, kad turime dviejų metų sklypų kainas už arą ketvirčių pabaigoje. Regionas yra vienas ir tas pats, o kainos, tūkstančiais litų, yra pateiktos 2 lentelėje. Toliau, sakykime, kad mums reikia parinkti įvairius veiksmus, galbūt įtakosiančius sklypų kainas (žr. 2 lentelė).

**2. lentelė: Glodinančio arba interpoliacinio splaino skaičiavimo metodo pavyzdys: duomenys ir rezultatai**

Periodas	Vieno aro kaina (tūkst. LT)	Svoriai (svorių failas)	Aritmetinis vidurkis (duomenų failas)	Prognozuotos reikšmės (tt =2 ) „smoothingy.txt“ (PPzingsn = 1)
I	10 12 13 9	4	11	11
II	-	0	0	9.12336
III	11 9.5	2	10.25	10.25
IV	13	1	13.5	12.50164
V	14 12 16	3	14	14
VI	20	1	20	13.52632
VII	13 12	2	12.5	12.5
VIII	13 11 15	3	13	13
IX	11 9 10	3	10	10
X	10 8.5 8.5	3	9	9
XI	9 10.5 9	3	9.5	9.5
XII	9.3 9.5 10	3	9.6	9.6

Sakykime, pasirenkame keturių veiksnių istorinius duomenis, apibūdinančios pačių periodų, kaip ir nagrinėjamos sklypų kainos. Duomenys pateikti 3 lentelėje.

**3. lentelė: Veiksnių parinkimo pavyzdys. Pradiniai ir papildyti duomenys**

Periodas	Veiksny nr. 1	Veiksny nr. 2	Veiksny nr. 3	Veiksny nr. 4
	Pradiniai	Pradiniai	Pradiniai	Pradiniai
I	10	2.5	1	1.8
II	11	3	0.9	2.1
III	11.2	2.8	0.8	1.9
IV	12.8	3.1	1.1	1.65
V	12.2	3.8	1.4	1.6
VI	12.6	3.3	1.3	1.45
VII	11.5	2.9	1.2	1.6
VIII	9.9	3.2	1.1	1.5
IX	9.2	3.5	1	1.9
X	9.3	3.2	0.7	2.1
XI	9.4	2.8	0.8	2
XII	9.1	2.6	0.7	1.95

Jei kurio nors veiksnio vienas duomuo yra nežinomas, tuomet jį galima prognozuoti apskaičiuojant splainą su programiniu kodu „spline.sci“. Tuomet tam, kad žinotume, ar modelyje nebus multikolinearumo, paskaičiuojame koreliacijas tarp visų veiksnių. Gauta koreliacinė matrica pateikta 4 lentelėje.

**4. lentelė: Veiksnių tarpusavio koreliacija. Koreliacija su priklausomu kintamuoju. Pavyzdys.**

veiksny	1/B1	2/B2	3/A1	4/A2
<b>1/B1</b>	1	0.33	0.72	-0.61
<b>2/B2</b>	0.33	1	0.59	-0.35
<b>3/A1</b>	0.72	0.59	1	-0.86
<b>4/A2</b>	-0.61	-0.35	-0.86	1
<b>sklypai</b>	<b>0.71</b>	<b>0.47</b>	<b>0.92</b>	<b>-0.96</b>

Taip pat parenkant veiksnis priklausomam kintamajam būtina atlikti porinio stebėjimo grafikų analizę, o tikrinant konkretaus metodo tinkamumą – liekamųjų paklaidų arba standartizuotųjų liekanų grafikų analizę. Porinio stebėjimo grafikas parodo, ar dviejų kintamųjų priklausomybė yra tiesinė. Tuo tarpu liekamųjų paklaidų grafikas nurodo, kad regresios modelis tinka, jei visos liekanos yra išsibarsčiusios apie tiesę  $y=0$  maždaug vienodai nelabai dideliu atstumu.

Prieš toliau nagrinėdami modelį patikrinkime, ar visi veiksniai su priklausomu kintamuoju susiję tiesiniu ryšiu.

**4 pav. Veiksnių tarpusavio priklausomybė. Porinio stebėjimo grafikas. Pavyzdys**




Iš 4 lentelės ir 4 pav. galime matyti, kad 3 ir 4 veiksnys yra stipriai koreliuoti ir tarpusavyje




tiesiškai priklausomi, todėl aišku, kad jie į vieną modelį neįeis. Šiuos veiksnius galėtume atskirti. Veiksnį nr. 1 pavadinkime B1, veiksnį nr. 2 – B2, veiksnį nr. 3 – A1, veiksnį nr. 4 – A2. Tuomet Galutinius veiksmių duomenis iš 3 lentelės išdėliokime duomenų byloje „x.txt“ stulpeliuose tokia tvarka: A1 A2 B1 B2 1, kai „1“ reiškia stulpelį iš vienetų, apibrėžiantį konstantą. Nubraižę veiksmių porines priklausomybes nuo priklausomo kintamojo (žr 5 ir 6 pav.), pastebime, kad A1 ir A2 veiksmių tiesinė priklausomybė nuo priklausomo kintamojo yra geresnė. Byloje „y1.txt“ tegul būna surašytos atitinkamų periodų sklypų vertės reikšmės.

**5 pav. Veiksmių A1 ir A2 porinės priklausomybės. Pavyzdys**



**6 pav. Veiksmių B1 ir B2 porinės priklausomybės. Pavyzdys**



Toliau per Scilab programą įvykdome pograminį kodą iš bylos „koreliuotiems.sci“. Pasirenkame katalogą, kuriame yra dvi ką tik sukurtos bylos, ir programos prašymu įvedame „2“. Tai reiškia, kad pirmi du veiksniai yra stipriai koreliuoti, ir kad jų nebus viename modelyje. Suprantama, jei padarysime klaidą – silpną priklausomybę įvertinsime kaip reikšmingą – ši programa gali ir nepateikti geriausio rezultato. Gautą rezultatą galime patikrinti programa „nekoreliuotiems.sci“, tačiau įvykdymas užtruks ilgiau (žr 6 lentelę).

Duomenų bylų „x.txt“ ir „y1.txt“ turinys pateiktas 5 lentelėje.

**5. lentelė: Duomenų apie veiksnius, bylos „x.txt“ ir priklausomojo kintamojo bylos „y1.txt“, pavyzdžiai**

„x.txt“					„y1.txt“
10	2.5	1	1.8	1	11
11	3	0.9	2.1	1	9.12
11.2	2.8	0.8	1.9	1	10.25
12.8	3.1	1.1	1.65	1	12.5
12.2	3.8	1.4	1.6	1	14
12.6	3.3	1.3	1.45	1	13.53
11.5	2.9	1.2	1.6	1	12.5
9.9	3.2	1.1	1.5	1	13
9.2	3.5	1	1.9	1	10
9.3	3.2	0.7	2.1	1	9
9.4	2.8	0.8	2	1	9.5
9.1	2.6	0.7	1.95	1	9.6

Programos kodo „koreliuotiems.sci“ ir programos kodo „nekoreliuotiems.sci“ įvykdymu gauti rezultatai palyginti 6 lentelėje.

**6. lentelė: Pavyzdžio rezultatų palyginimas, įvykdant du skirtingus programos kodus**

Pavadinimas	„koreliuotiems.sci“						„nekoreliuotiems.sci“					
Kai kurie rezultatai:	0.92	0	0	0	-7.71	25.01	0.6	0	0	10.99	0	0
$r^2_{Adj}$ ,	0.95	0	0	2.89	-5.23	17.66	0.92	0	0	0	-7.71	25.01
koef. $b_j$ .	0.95	0.13	0	2.35	-5.22	16.83	0.95	0.13	0	2.35	-5.22	16.83
							0	0	0	0	0	0
Laikas (sek.)	0.16						0.39					

Iš 6 lentelės matome, kad pavykus nustatyti veiksnius, kurie gerai koreliuoja tarpusavyje ir turi stiprią tiesinę priklausomybę, galima išlošti daug kompiuterinio laiko.

Gavę atsakymus turime patikrinti modelio tinkamumą. Tai yra, turime patikrinti anksčiau aprašytas penkias modelio tinkamumo sąlygas. Tuo tikslu pirmiausiai pasirenkame mums priimtina modelį. Šiame pavyzdyje sakykime, kad visi duomenys yra vienodai prieinami ir įmanomi gauti vienodu dažniu. Tuomet pasirenkame modelį iš tirjų veiksnų: B1 ir B2 ir konstantos. Įvykdytos programos kataloge esančioje byloje „SeSrR2adj.txt“ koeficientai išdėstyti tokia tvarka: Koreguotasis determinacijos koeficientas, liekamųjų paklaidų kvadratų suma (13), regresijos kvadratų suma (12). Paskutiniai du skaičiai reikalingi hipotezei patikrinti. Be to, prisiminkime, kad pasirinkome modelį su  $k=3$  ir naudojome duomenis su  $n=12$ . Tuomet, kai  $SSE = 1.25$ , o  $SSR = 35.62$  gauname:

### 7 pav. Hipotezės, apie bent vieno koeficiento nelygumą nuliui, tikrinimas. Pavyzdys

<b>3</b>	K-lygties koeficientų skaičius					
<b>12</b>	N – imties dydis					
<b>35.62</b>	SSR					
<b>1.25</b>	SSE					
			<b>0.05</b>	alfa(reikšmingumo lygmuo)		
ANOVA	kvad.suma	laisv.laipsniai	Disp. įverčiai	F	F(alfa)	
regresijos	35.62	3	11.87	75.98	3.59	
paklaidų	1.25	8	0.16			
viso	36.87	11				

Čia  $F$  – gautos statistikos reikšmė, o  $F(\alpha)$  – Fišerio statistikos reikšmė su užsiduotu lygmeniu. Pastebime, kad hipotezė apie visų koeficientų lygumą nuliui yra atmetama, tai yra, bent vienas koeficientas

yra statistiškai reikšmingas su tikimybe 0.95.

Tuomet kiekvienam koeficientui atskirai tikrinama hipotezė apie konkretaus koeficiento nelygumą nuliui. Rezultatų byloje „issirink.txt“ randame pasirinktą modelį ir pasirenkame reikiamus dydžius. Eilutėje  $SSE(k)$  yra nurodyta liekanų suma, kai priklausomu kintamuoju naudojamas  $k$ -tasis pasirinktas koeficientas. Byloje „Bmatrix.txt“ yra nurodyti visų modelių  $b$  koeficientai. Tuomet pirmam koeficientui gauname:

### 8 pav. Hipotezių, apie visų koeficientų nelygumą nuliui, tikrinimas. Pirmasis koeficientas.

0.05		Bj įvertis	<b>2.89</b>
<b>2.31</b>	<?>	<b>2.89</b> SSE	<b>1.25</b>
		SSEj	0.16
	Jei < tai H0 atmetama	k	3
	t.y. regr. Koeficientas tinka	n	12
			0.16

**9 pav. Hipotezių, apie visų koeficientų nelygumą nuliui, tikrinimas. Antrasis koeficientas.**

0.05			Bj įvertis	-5.23
2.31	<?>	5.21	SSE	1.25
			SSEj	0.16
	Jei < tai H0 atmetama		k	3
	t.y. regr. Koeficientas tinka		n	12

**10 pav. Hipotezių, apie visų koeficientų nelygumą nuliui tikrinimas. Trečiasis koeficientas.**

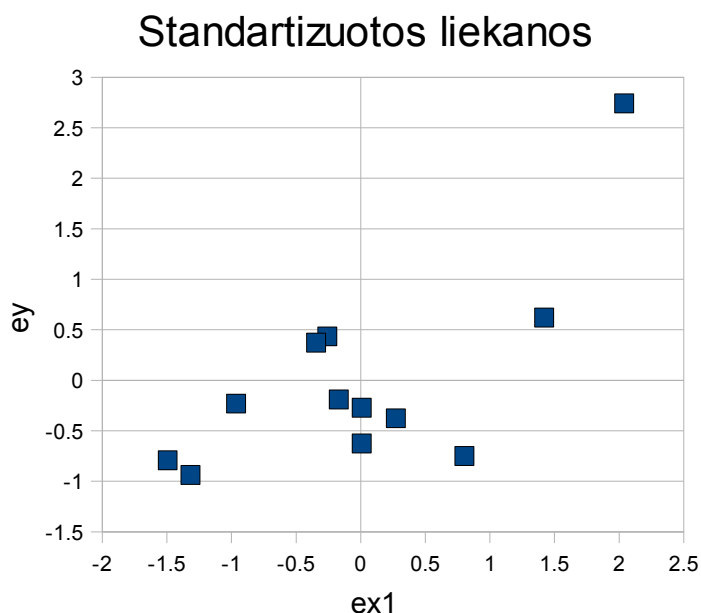
0.05			Bj įvertis	17.66
2.31	<?>	6.47	SSE	1.25
			SSEj	0.02
	Jei < tai H0 atmetama		k	3
	t.y. regr. Koeficientas tinka		n	12

Taigi nulinė hipotezė visiems koeficientams yra atmetama (žr 8, 9 ir 10 pav.). Tai yra, visi koeficientai su 0.95 tikimybe statistiškai reikšmingai skiriasi nuo nulio.

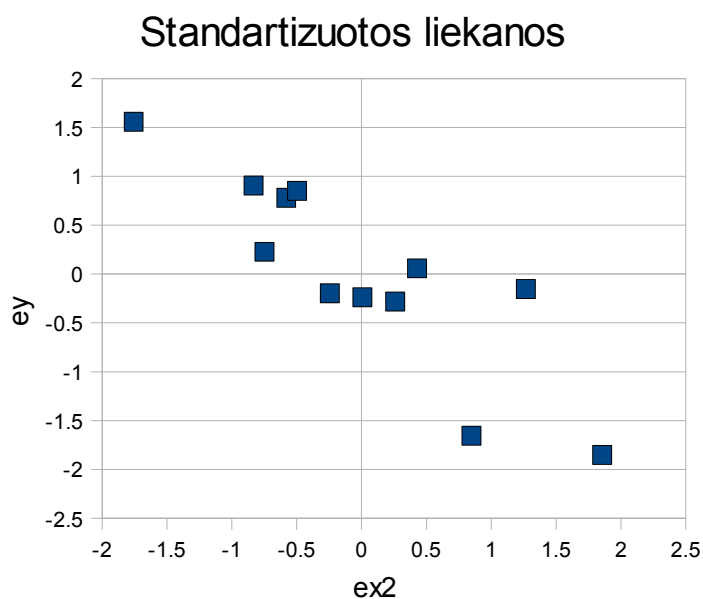
Modelio tinkamumo trečioji sąlyga yra automatiškai patikrinama programos skaičiavimo metu. Taigi, tikriname ketvirtąją ir penktąją sąlygas. Ketvirtąją sąlygą, apie liekanų pasiskirstymą pagal normalųjį skirstinį, tikrinsime Kolmogorovo dėsnio. Byloje „liekanos.txt“ yra pateiktos pasirinkto modelio liekanos. Patikrinę hipotezę gauname, jog skirstinys yra normalusis su tikimybe 0.99 (Nulinė hipotezė yra atmetama).

Tikriname penktąją sąlygą:

**11 pav. Standartizuotųjų liekanų sklaidos diagrama. Pirmojo kintamojo liekanoms**



## 12 pav. Standartizuotųjų liekanų sklaidos diagrama. Antrojo kintamojo liekanoms



Pastebėjime, kad antroji priklausomybė yra panaši į tiesinę (žr. 12 pav.), o pirmojoje yra kelios liekanos, kurios šią priklausomybę daro neaiškia (žr. 11 pav.). Tačiau kitos prielaidos yra geros, dėl to sakysime, kad modelis tinka. Tokį modelį aprašys regresijos funkcija:

$$\hat{y}(B_1, B_2) = 17.661 + 2.895 \cdot B_1 - 5.228 \cdot B_2 \quad (24)$$

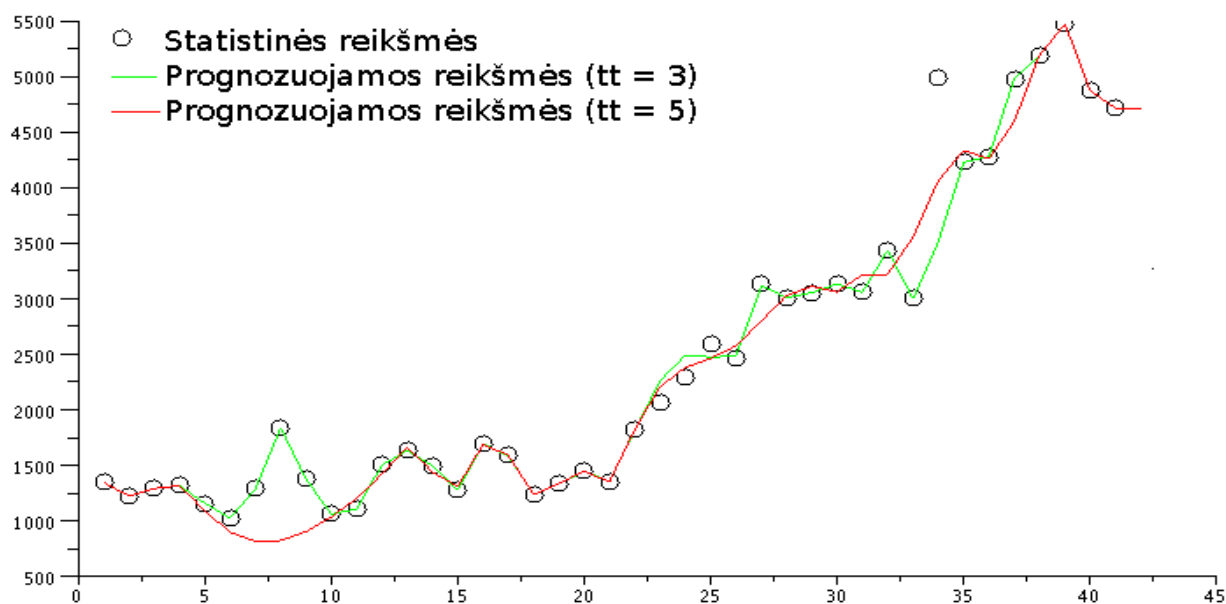
## 4. TIRIAMOJI DALIS

### 4.1. KAUNO MIESTO CENTRE ESANČIŲ BUTŲ KAINŲ ĮVERTINIMAS



Toliau ieškosime regresijos modelio, geriausiai aprašančio butų kainas Kauno miesto centre. Turime vidutines būstų kainas Kauno miesto centre (16 lentelė, 1 priedas). Pirmiausiai turime kelis istorinius duomenis. Paskaičiuojame kiekvieno periodo vidurkį. Tuomet pagal duomenų kiekį periode, braižome interpoliacinį splainą, ieškodami trūkstamų reikšmių. Mažiausių kvadratų metodu gauname trūkstamas reikšmes. Prie kiekvieno glodinančio splaino nario yra nurodomas koeficientas, atitinkantis duomenų kiekį tame periode. Jei duomenų nėra – koeficientas nurodomas nulis, o prie duomenų įrašomas bet koks skaičius. Tai yra svarbiai nurodo, kiek duomenų iš to periodo buvo gauta. Prognozuodami darbo duomenis (16 lentelė, 1 priedas) pastebėsime, kad jautresni gauti tie rezultatai, kur mažesnis svoris buvo nurodytas kaip svarbesnis. Tačiau, pagal aktyvo likvidumą investuotojas turėtų nustatyti šį dydį pats. Suprantama, kad kuo aktyvas daugiau likvidus, tuo greičiau gali keistis jo kaina. Toliau nagrinėsime tą prognozavimo atvejį, kai kintamasis „tt“ buvo parinktas lygus 5. Taip pasirinkome dėl to, kad būstai yra mažiau likvidūs, ir dėl to mažesnis pardavimų skaičius taip pat nurodo ir paklausos sumažėjimą, kas reiškia ir kainos mažesnę pokytį (13 pav).

Pastebėsime, kad daugelis veiksnių yra nurodomi tik nuo 2000 metų 2 ketvirčio. Todėl tolesnė analizė bus atliekama periodui nuo 2000 metų antro ketvirčio iki 2007 metų paskutinio ketvirčio. Pirmą 2008 metų ketvirtį jau buvo pakitę daug veiksnių, tačiau į juos nebuvo spėjusios sureaguoti būsto kainos, ir dėl to atsirado išskirtys tuo periodu (žr. 14 pav.).

**13 pav. Vidutinių butų kainų, tūkst. LTL už kvadratinį metrą, kitimas Kauno miesto centre 1999-2008m. Ketvirčiais.**



**14 pav. Pastebėta ir panaikinta išskirtis paskutiniame periode**



Veiksnius parenkame visus tuos, kurie koreliuoja su butų kainomis. Jei veiksnio koreliacija yra silpna – tikriname, ar veiksnio ankstesnių periodų pokyčiai nekoreliuoja statistiškai reikšmingai stipriau su butų kainų pokyčiais tarp periodų. Jei egzistuoja statistiškai reikšminga priklausomybė, tuomet toliau parenkame kelias (dažniausiai dvi) to veiksnio reikšmes skirtingiems periodams, kad programa galėtų parinkti, kuris veiksnys, sąveikaudamas su kitais, duoda geresnius rezultatus

prognozuojamam kintamajam. Parinkti veiksniai yra nurodyti pirmame priede.

Tuomet, kad būtų kuo daugiau kartų sutrumpintas kompiuterinio skaičiavimo laikas, reikia pastebėti, kurie kintamieji seka vieną nežinomą veiksnį (yra smarkiai koreliuoti tarpusavyje) ir kurie keičiasi kitaip. Tie, kurie yra stipriai koreliuoti tarpusavyje – priskiriami vienai grupei. Toliau darbe tokie veiksniai bus priskiriami „A“ grupei. O patys veiksniai žymimi A raide su prie jos esančiu veiksnį identifikuojančiu numeriu. Kiti veiksniai priskiriami grupei B, ir žymimi B raide, su prie jos esančiu veiksnį identifikuojančiu numeriu.

Stebint koreliaciją tarp veiksmių, tuo pačiu metu verta nusibrėžti porinių stebėjimų grafikus. Porinių stebėjimų grafikai daugialypės regresijos lygties modeliuose yra taikomi, kai norima paviršutiniškai įvertinti, ar kintamieji yra tiesiškai priklausomi, ar nėra. O jei yra – tuomet, kiek tiesiškai priklausomi. Nubraižę šiuos grafikus (žr. 2 priedą) galime pastebėti, kad kai kurie veiksniai yra netinkami tolesnei regresinei analizei, o kai kurie gali būti tinkami panaudojus duomenų ištiesinimo galimybę. Ištiesinus kai kuriuos duomenis, apskaičiuojama „darbinė“ koreliacinė matrica (žr. 3 priedą).

Pagal ją suskirstome kintamuosius, ir juos pažymime raidėmis. Toliau darbe visi veiksniai bus žymimi tokiais žymėjimais, kaip parodyta 7 ir 8 lentelėse.

#### **7. lentelė: Veiksmių suskirstymas, apibūdinimas. Veiksniai, stipriai koreliuoti tarpusavyje**

Pavadinimas	Apibūdinimas
A1	Bendrasis vidaus produktas, sukurtas per paskutinius 12 mėnesių, milijardais litų.
A2	Vilniaus vertybinių popierių biržos indeksas (OMXV)
A3	Vidutinis mėnesinis atlyginimas (NETO), tūkstančiais litų.
A4	Eksportas per paskutinius 12 mėnesių, milijardais litų.
A5	Importas per paskutinius 12 mėnesių, su metiniu vėlavimu, milijardais litų.
A6	Importas per paskutinius 12 mėnesių, milijardais litų.
A7	Bedarbystė einamu momentu, procentais.
A8	Žaliavinės naftos kainos, doleriais už barelį.
A9	Statybos leidimų, išduotų per paskutinius 12 mėnesių, skaičius, vienetais.
A10	Statybos sąnaudų indeksas
A11	Cukraus importas į Europos Sąjungą, doleriais už svarą.
A12	Bedarbystės lygis miestuose, buvęs prieš pusmetį, procentais.
A13	Bedarbystės lygis miestuose, esantis vertinimo momentu, procentais.
A14	Bedarbystės lygis miestuose, buvęs prieš 9 mėn, procentais.
A15	Gimstamumas, buvęs prieš 22 metus, gimusių skaičius per tris mėnesius, tūkst.

**8. lentelė: Veiksnių suskirstymas, pažymėjimas, apibūdinimas. Kiti veiksniai.**

Pavadinimas	Apibūdinimas
B1	Eksporto ir importo skirtumas, milijardais litų, per paskutinius 12 mėn.
B2	Emigracija per paskutinius 3 mėn, tūkstančiais litų.
B3	EURIBOR palūkanų indeksas 3 mėn laikotarpiui, buvęs prieš 3 mėn nuo skaičiavimo momento, procentais.
B4	Ištuokų kiekis per paskutinius 3 mėnesius, tūkstančiais žmonių
B5	Lūkesčiai (kiek tūkstančių bedarbių tikisi gauti daugiau negu 1500LTL atlyginimą)
B6	Valiutų USD ir EUR vertės santykis vertinimo momentu
B7	Skirtumas tarp VILIBOR ir EURIBOR palūkanų normų
B8	Materialinės investicijos į šalį, per paskutinius 12 mėn. Milijardais litų.
B9	EURIBOR palūkanos 3 mėn laikotarpiui vertinimo momentu, procentais.
B10	Santuokos, per paskutinius tris mėn, tūkstančiais.
B11	Valiutų USD ir EUR vertės santykis, buvęs prieš mėnesį, nuo vertinimo momento
B12	Valiutų USD ir EUR vertės santykis, buvęs prieš tris ketvirčius nuo vertinimo momento
B13	Valiutų USD ir EUR vertės santykis vertinimo momentu. Ištiesinti duomenys (laipsnyje 1/3)
B14	Vidutinės paskutinių 3 mėnesių apvaliosios medienos kainos Kauno rajono urėdijoje, litais už kubinį metrą.

Kai jau suskirstyti kintamieji, tuomet porinių stebėjimo grafikų pagalba galima nustatyti, kurie kintamieji tikrai nėra tiesinėje priklausomybėje su priklausomu kintamuoju. Dėl netiesinės priklausomybės atmetame šiuos veiksnius:

A2, A7, A8, A11, B2, B3, B4, B6, B7, B9, B10, B11, B12

taigi lieka veiksniai:

A1, A3, A4, A5, A6, A9, A10, A12, A13, A14, A15

ir iš kitos grupės:

B1, B5, B8, B13, B14.

Perskaičiavę visus galimus variantus, gauname, jog geriausias veiksnių rinkinys yra:

A13, B5, B8 ir konstanta. Koreguotasis determinacijos koeficientas šiam modeliui yra 0.96102 kiti duomenys pateikti 9 lentelėje.



### 9. lentelė: Optimalių parametru modelio rezultatai

Parametras	reikšmės							
Regresijos lygties koeficientai: A13; B5; B8; konstanta.	-0.204909411839991	0.104229326752084	-0.132663212937029	4.661788669925179				
Koreguotasis determinacijos koeficientas	0.961019751189							
SSE(j) - modelio, kuriame j-tasis veiksnys yra priklausomas kintamasis, liekamųjų paklaidų kvadratų suma.	296.036	265.278	14.476	0.642				
Multikolinearumas tarp koeficientų	2.404	2.584	3.632	0.900				
Modelio liekanos (iš kairės į dešinę ir žemyn)	-0.36	0.32	0.15	0.62	0.45	-0.03	-0.36	0.14
	-0.06	-0.18	-0.43	-0.28	-0.36	-0.24	-0.11	-0.38
	-0.37	0.28	-0.36	-0.03	-0.45	0.02	-0.81	0.26
	0.77	0.98	-0.04	0.24	0.53	0.51	-0.41	
Modelio liekamųjų paklaidų kvadratų suma	1.790465146280							
Modelio regresijos kvadratų suma	51.208717404688							

Tikriname hipotezes apie gauto modelio tinkamumą.

1) Hipotezės, apie bent vieno koeficiento nelygumą nuliui, tikrinimas (15 pav):

#### 15 pav. Hipotezės, apie bent vieno koeficiento nelygumą nuliui, tikrinimas

<b>4</b>	K-lygties koeficientų skaičius					
<b>31</b>	N – imties dydis					
<b>51.21</b>	SSR					
<b>1.79</b>	SSE					
	<b>0.01</b> alfa(reikšmingumo lygmuo)					
ANOVA	kvad.suma	laisv.laisniai	Disp.	įverčiai	F	F(alfa)
regresijos	51.21	4	12.8	185.91	4.02	
paklaidų	1.79	26	0.07			
viso	53	30				

2) Hipotezių tikrinimas apie kiekvieno koeficiento lygumą nuliui.

#### 16 pav. Hipotezės tikrinimas apie A13 veiksnį aprašančio koeficiento lygumą nuliui

0.01		Bj įvertis	-0.2
<b>2.78</b>	<?>	<b>13.44</b>	<b>1.79</b>
		SSE	0.07
Jei < tai H0 atmetama		SSEj	296.04
t.y. regr. Koeficientas tinka		k	4
		n	31

### 17 pav. Hipotezės tikrinimas apie B5 veiksnį aprašančio koeficiento lygumą nuliui

0.01			Bj įvertis	0.1	
2.78	<?>	6.47	SSE	1.79	0.07 MSE
Jei < tai H0 atmetama			SSEj	265.28	
t.y. regr. Koeficientas tinka			k	4	
			n	31	

### 18 pav. Hipotezės tikrinimas apie B8 veiksnį aprašančio koeficiento lygumą nuliui

0.07			Bj įvertis	-0.13	
1.89	<?>	1.92	SSE	1.79	0.07 MSE
Jei < tai H0 atmetama			SSEj	14.48	
t.y. regr. Koeficientas tinka			k	4	
			n	31	

### 19 pav. Hipotezės apie konstantos lygumą nuliui tikrinimas

0.01			Bj įvertis	4.66	
2.78	<?>	14.23	SSE	1.79	0.07 MSE
Jei < tai H0 atmetama			SSEj	0.64	
t.y. regr. Koeficientas tinka			k	4	
			n	31	


Pastebėsime, kad trečiojo koeficiento nelygumą nuliui galime garantuoti su 0.93 tikimybe (žr. 18 pav.), kai, tuo tarpu, kitų koeficientų nelygumą nuliui galime garantuoti su 0.99 tikimybe (žr. 16, 17, 19 pav.).

- 3) Multikolinearumo sąlyga (patikrinama modelio parinkimo metu);
- 4) Hipotezė apie modelio liekanų pasiskirstymą pagal normalųjį skirstinį:


Pagal Kolmogorovo kriterijų liekanos yra pasiskirsčiusios pagal normalųjį skirstinį su 0.99 tikimybe.

- 5) Tiesiškos priklausomybės tikrinimas, braižant standartizuotų liekanų sklaidos diagramas (20, 21, 22 pav)


20 pav. Standartizuotųjų liekanų priklausomybė, parodanti veiksnio A13 tiesiškumą su priklausomu kintamuoju



21 pav. Standartizuotųjų liekanų priklausomybė, parodanti veiksnio B5 tiesiškumą su priklausomu kintamuoju



## 22 pav. Standartizuotųjų liekanų priklausomybė, parodanti veiksnio B8 tiesiškumą su priklausomu kintamuoju



Galime pastebėti, kad koeficientas B8 tiek antrame tiek penktame modelio patikimumo testuose yra mažiau patikimas. Dėl to galime daryti išvadą, kad koeficientas B8 iš tolesnės analizės gali būti pašalintas, jei reikalaujama didelio modelio tikslumo. Modelio tinkamumas, pagal antrosios tinkamumo savybės tikrinimą, yra 0.93. Toks skaičius parinktas pagal mažiausio patikimumo koeficientą.

Šį modelį aprašanti regresijos funkcija:

$$\hat{y}(a_{13}, b_5, b_8) = 4.66179 - 0.20491 \cdot a_{13} + 0.10423 \cdot b_5 - 0.13266 \cdot b_8 \quad (25)$$

čia  $a_{13}$ ,  $b_5$  ir  $b_8$  yra reikšmės, atitinkamai veiksnių: A13, B5 ir B8 tuo periodu, kai vertinamos kainos.

Pastebėsime, kad nors dispersijos mažėjimo daugiklis yra mažesnis už 4, tačiau prie veiksnio B8 atsirado neigiamas daugiklis, nors šio veiksnio koreliacija su priklausomu kintamuoju yra teigiama ( $\sim 0.8$ ). Tačiau, kadangi multikolinearumas nėra didelis, galima įtarti, kad šis koeficientas atimamas dėl to, kad jo padidėjimą silpnai jau aprašo kitas koeficientas. Tai yra, šis veiksnys didėja kartu su koku nors kitu lygtyje esančiu veiksniu su dideliu patikimumu.

Toliau teigsime, kad mums yra reikalingas modelis su tinkamumu, lygiu 0.99. Iš tolesnės analizės pašaliname koeficientą B8. Tuomet geriausias rezultatas apskaičiuojamas iš šių veiksnių:

A13, B5 ir konstanta. Kiti šio modelio parametrai nurodyti 10 lentelėje

### 10. lentelė: Patikslinto modelio parametrai

Parametras	reikšmės							
Regresijos lygties koeficientai: A13; B5; konstanta.	-0.188804570051413 0.085893291220251 4.242638287762211							
Koreguotasis determinacijos koeficientas	0.957122268280							
SSE(j) - modelio, kuriame j-tasis veiksnys yra priklausomas kintamasis, liekamųjų paklaidų kvadratų suma.	423.728	408.177	1.152					
Multikolinearumas tarp koeficientų	1.742	1.742	0.933					
Modelio liekanos (iš kairės į dešinę ir žemyn)	-0.42	0.49	0.28	0.47	0.53	-0.05	-0.23	-0.07
	-0.03	-0.15	-0.29	-0.43	-0.42	-0.27	0	-0.74
	-0.48	0.4	-0.3	-0.29	-0.64	0.02	-0.67	-0.02
	0.76	1.19	0.3	0	0.5	0.55	-0.01	
Modelio liekamųjų paklaidų kvadratų suma	2.045236257730							
Modelio regresijos kvadratų suma	50.953946293237							

Tikriname hipotezes apie gauto modelio tinkamumą.

- 1) Hipotezės, apie bent vieno koeficiento nelygumą nuliui, tikrinimas (23 pav):

### 23 pav. Hipotezės apie visų koeficientų lygumą nuliui tikrinimas

<b>3</b>	K-lygties koeficientų skaičius					
<b>31</b>	N – imties dydis					
<b>50.95</b>	SSR					
<b>2.05</b>	SSE					
	<b>0.01</b> alfa(reikšmingumo lygmuo)					
ANOVA	kvad.suma	laisv.laipsniai	Disp. įverčiai	F	F(alfa)	
regresijos	50.95	3	16.98	224.22	4.51	
paklaidų	2.05	27	0.08			
viso	53	30				

Matome, kad nulinė hipotezė, apie visų koeficientų lygumą nuliui, yra atmetama.

- 2) Hipotezių, apie kiekvieno koeficiento nelygumą nuliui, tikrinimas (24, 25, 26 pav.):

### 24 pav. Hipotezės tikrinimas apie veiksnį A13 apibūdinančio koeficiento lygybę nuliui

0.01		Bj įvertis	-0.19
<b>2.77</b>	<?>	<b>14.12</b>	<b>2.05</b>
		SSE	0.08
		SSEj	423.73
		k	3
		n	31
			MSE

Jei <math>t < t\_{\alpha}</math> tai H0 atmetama  
t.y. regr. Koeficientas tinka

### 25 pav. Hipotezės tikrinimas apie veiksnį B5 apibūdinančio koeficiento lygumą nuliui

0.01			Bj įvertis	0.09	
2.77	<?>	6.31	SSE	2.05	0.08 MSE
Jei < tai H0 atmetama			SSEj	408.18	
t.y. regr. Koeficientas tinka			k	3	
			n	31	

### 26 pav. Hipotezės tikrinimas apie konstantos lygumą nuliui

0.01			Bj įvertis	4.24	
2.77	<?>	16.55	SSE	2.05	0.08 MSE
Jei < tai H0 atmetama			SSEj	1.15	
t.y. regr. Koeficientas tinka			k	3	
			n	31	


3) Multikolinearumo sąlyga (patikrinama modelio parinkimo metu);

4) Hipotezė apie modelio liekanų pasiskirstymą pagal normalųjį skirstinį:


Tikriname pagal Kolmogorovo kriterijų. Pagal šį kriterijų liekanos pasiskirsčiusios pagal normalųjį skirstinį su tikimybe 0.99.

5) Tiesiškos priklausomybės tikrinimas, braižant standartizuotų liekanų sklaidos diagramas (27, 28 pav.).

### 27 pav. Standartizuotųjų liekanų priklausomybė, parodanti priklausomo kintamojo tiesinę priklausomybę nuo veiksnio A13



## 28 pav. Standartizuotųjų liekanų priklausomybė, parodanti priklausomo kintamojo tiesinę priklausomybę nuo veiksnio B5



Matome, kad šiame modelyje penktasis testas veiksniams A13 ir B5 duoda ne tokius gerus rezultatus, kurie buvo duoti ankstesnio testo metu. Tačiau tiesiškumas, nors ir neakivaizdus, išlieka. Visgi, jei norima gauti didesnę tiesiškumą veiksnių A13 ir B5 atžvilgiu, reikėtų naudoti ankstesnį modelį. Nes veiksnys B8, nors ir neturi geros tiesinio prognozavimo savybės būtų kainoms, tačiau sąveikoje su šiais dviem veiksniais duoda labai gerą rezultatą.

Aprašytą modelį apibendrinanti regresijos funkcijos forma yra tokia:

$$\hat{y}(a_{13}, a_5) = 4.24264 - 0.1888 \cdot a_{13} + 0.08589 \cdot b_5 \quad (26)$$

čia  $a_{13}$  ir  $b_5$  yra reikšmės, atitinkamai veiksnių: A13 ir B5 prognozuojamu periodu.

Darbe buvo minėta, kad kai kurių veiksnių reikšmės yra sunkiai įvertinamos praktikoje. Todėl dabar atliksime lyginamąją analizę, siekdami pastebėti, kaip keičiasi modelio tikslumas, jei parenkami veiksniai, kurių reikšmės galime įvertinti dažniau ir paprasčiau. Tokiai analizei tinka veiksniai:

A5, A12, A14, A15, B13, B14. Tiesą sakant yra sunku objektyviai nustatyti lūkesčių veiksnį, ar jam ekvivalentų. Nes naudojant duomenis iš Lietuvos statistikos departamento yra tikėtinas labai stiprus duomenų vėlavimas, netinkamas momentinei analizei.

Naudojant šiuos veiksnius gautas, didžiausią determinacijos koeficientą turintis modelis, turintis tokį nepriklausomų kintamųjų rinkinį:

A14, B14 ir konstantą. Šio modelio parametrai nurodyti 11 lentelėje

### 11. lentelė: Greito įvertinimo modelio parametrų lentelė

Parametras	reikšmės
Regresijos lygties koeficientai: A14; B14; konstanta.	-0.226598979414066 0.013305856383248 4.212165860046144
Koreguotasis determinacijos koeficientas	0.945394352102
SSE(j) - modelio, kuriame j-tasis veiksnys yra priklausomas kintamasis, liekamųjų paklaidų kvadratų suma.	187.299      3694.861      0.135
Multikolinearumas tarp koeficientų	3.243    3.243    0.933
Modelio liekanos (iš kairės į dešinę ir žemyn)	-0.42   0.49   0.28   0.47   0.53   -0.05   -0.23   -0.07 -0.03   -0.15   -0.29   -0.43   -0.42   -0.27   0      -0.74 -0.48   0.4    -0.3   -0.29   -0.64   0.02   -0.67   -0.02 0.76   1.19   0.3    0      0.5    0.55   -0.01
Modelio liekamųjų paklaidų kvadratų suma	2.604649231125
Modelio regresijos kvadratų suma	50.394533319842

Tikriname hipotezes apie gauto modelio tinkamumą.

1) Hipotezės, apie bent vieno koeficiento nelygumą nuliui, tikrinimas (29 pav):

### 29 pav. Hipotezės apie visų koeficientų lygumą nuliui tikrinimas

<b>3</b>	K-lygties koeficientų skaičius					
<b>31</b>	N – imties dydis					
<b>50.39</b>	SSR					
<b>2.6</b>	SSE					
	<b>0.01</b> alfa(reikšmingumo lygmuo)					
ANOVA	kvad.suma	laisv.laipsniai	Disp. įverčiai	F	F(alfa)	
regresijos	50.39	3	16.8	174.13	4.51	
paklaidų	2.6	27	0.1			
viso	53	30				

Matome, kad nulinė hipotezė, apie visų koeficientų lygumą nuliui, yra atmetama.

2) Hipotezių, apie kiekvieno koeficiento nelygumą nuliui, tikrinimas (30,31,32 pav.):

### 30 pav. Hipotezės apie veiksnį A14 apibūdinančio koeficiento lygybę nuliui, tikrinimas

0.01		Bj įvertis	-0.23
<b>2.77</b>	<?>	<b>9.98</b> SSE	<b>2.6</b> 0.1 MSE
Jei < tai H0 atmetama		SSEj	187.3
t.y. regr. Koeficientas tinka		k	3
		n	31



### 31 pav. Hipotezės apie veiksnio B14 lygybę nuliui apibūdinančio koeficiento tikrinimas

0.02		Bj įvertis	0.01
2.47	<?>	2.6	0.1 MSE
Jei < tai H0 atmetama		SSEj	3694.86
t.y. regr. Koeficientas tinka		k	3
		n	31

### 32 pav. Hipotezės apie konstantos lygumą nuliui tikrinimas

0.01		Bj įvertis	4.21
2.77	<?>	4.98	0.1 MSE
Jei < tai H0 atmetama		SSEj	0.14
t.y. regr. Koeficientas tinka		k	3
		n	31


3) Multikolinearumo sąlyga (patikrinama modelio parinkimo metu);

4) Hipotezė apie modelio liekanų pasiskirstymą pagal normalųjį skirstinį:


Tikriname pagal Kolmogorovo kriterijų. Pagal šį kriterijų liekanos pasiskirsčiusios pagal normalųjį skirstinį su tikimybe 0.99.

Tiesiškos priklausomybės tikrinimas, braižant standartizuotų liekanų sklaidos diagramas (33 ir 34 pav.). Standartizuotų liekanų priklausomybė, parodanti priklausomo kintamojo tiesinę priklausomybę nuo veiksnio A14.

### 33 pav. Priklausomojo kintamojo tiesinė priklausomybė nuo veiksnio A14. Standartizuotųjų liekanų priklausomybė.



### 34 pav. Priklausomojo kintamojo tiesinė priklausomybė nuo veiksnio B14. Standartizuotųjų liekanų priklausomybė



. Galime pastebėti, kad hipotezės tenkinamos pakankamai tiksliai, tačiau tarp standartizuotųjų liekanų nėra labai tikslios tiesinės priklausomybės.

Aprašytą modelį apibendrinanti regresijos funkcijos forma yra tokia:

$$\hat{y}(a_{14}, a_{14}) = 4.24264 - 0.1888 \cdot a_{14} + 0.08589 \cdot b_{14} \quad (27)$$

čia  $a_{14}$  ir  $b_{14}$  yra reikšmės, atitinkamai veiksnių: A14 ir B14 prognozuojamu periodu.

Apibendrinamas pabandysiu įvertinti vieną aktyvą pagal (25) funkciją. Yra žinoma (statistikos departamento duomenimis), kad 2009 metų pirmą ketvirtį materialinės investicijos Lietuvoje sudarė 2.4227 mlrd litų. Taip pat, sakykime, kad nedarbas tuomet buvo 9proc. Jei spėsime, kad Lietuvoje tik 100 žmonių teigė norintys didesnio negu 1500 atlyginimo (2009 m, I ketvirčio ekonominėmis sąlygomis tas yra tikėtina). Tuomet pagal modelį vidutinio buto Kauno miesto centre vieno kvadratinio metro vertė 2009 metų pirmą ketvirtį buvo lygi maždaug 2510LT. Tai yra, vidutinis 45 kvadratinių metrų ploto dviejų kambarių butas Kauno miesto centre turėjo kainuoti apie 112 800LTL. Kiek ši kaina atrodo reali – tegul sprendžia skaitytojas.

## 4.2. PROGRAMINĖ REALIZACIJA IR INSTRUKCIJA VARTOTOJUI

Pirmas svarbus programos aspektas reikalingas dar duomenų surinkimo metu yra glodinančio ar/ir interpoliacinio splainio naudojimas. Kai turimi skirtingų periodų ir galbūt skirtingo patikimumo duomenys, tuomet duomenų papildymui ir susistemimui naudojama procedūra:

```

file1 = uigetfile(["*"],"/home", "Pasirinkite duomenų failą", %f);
direktorija = dirname(file1);
file2 = uigetfile(["*"],"/home", "Pasirinkite svorių failą", %f);
BtPk=fscanfMat(file1)';
svoriai = fscanfMat(file2)';
dydis = size(BtPk);
kk = 0;
kkk = 0;
tt = 5; // koks svoris jau yra laikomas svarbiu
for j = 1:dydis(2)
    if svoriai(j) >= tt then kkk = kkk+1;
    end;
end;
xx = zeros(kkk);
for i = 1:dydis(2)
    if svoriai(i) >= tt then
        kk = kk+1;
        xx(kk) = i; // nurodomi numeriai, kuriuose yra svarbesni taškai
    end;
end;
x = linspace(1,dydis(2), dydis(2)); // graduojama nuo 1 iki paskutinės x
koordinatės
[y, d] = lsq_splin(x, BtPk, svoriai, xx); // y - mažiausių kvadratų metodu
sudarytas splainas
PPzingsn = 1/3;
nai = smooth([xx';y'], PPzingsn); // 0.33 - žingsnis, kurio norima. Galima
padaryti mažesnę
nai1 = nai(1,:); // gautų naujų duomenų x koordinatė
nai2 = nai(2,:); // gautų naujų duomenų y koordinatė

file3 = direktorija + '/smoothingx.txt';
file4 = direktorija + '/smoothingy.txt';
fprintfMat(file3, (nai1'), '%8.5f');
fprintfMat(file4, (nai2'), '%8.5f');

```

Šiai procedūrai įvykdyti reikalingos dvi bylos, kuriose yra vienodas skaičius duomenų. Pirmoji (duomenų) byla aprašo turimus duomenis pastoviais periodais. Tais pastoviais periodais, kuriuose duomenų neturime, reikia palikti nulius. Vėliau, kuriant svorių vektorių kitoje byloje, prie atitinkamų pastovių periodų, kuriose informacija yra visiškai nepatikima arba nėra žinoma, reikia įrašyti nulius (arba kitus koeficientus, priklausomai nuo duomenų patikimumo). Programoje taip pat galima pakeisti kintamąjį „tt“, kuris aprašo tuos taškus, kuriuose informacija yra laikoma patikima. Realiai tai reiškia,

koks skaičius duomenų užtikrina patikimą informaciją. Ši procedūra rezultatus palieka tame pačiame kataloge, kuriame yra ir parinkta duomenų byla. Rezultatų failas „smoothingy.txt“, kuriame nurodytos naujos gautos reikšmės. Duomenys šios programos metu bus suglodinti mažiausių kvadratų metodu.

Iš 17 lentelės (1 priedas) matome, kad suglodintu splainu prognozuotos reikšmės nedaug skiriasi nuo tikrųjų reikšmių (prognozuotų euro ir JAV dolerio valiutų santykio vidutinis reikšmių skirtumas 1.42proc).

Vėliau, jau turint visus reikiamus duomenis (veiksniai ir priklausomi kintamieji), veiksmų vertės atitinkamais periodais surašomos į stulpelius. Vienas stulpelis turi būti sudarytas vien tik iš vienetų. Šitas faktas nurodo, kad modelyje gali būti parinkta konstanta.

Jei programa taikoma įvertinti arbitražo įkainojimo teorijos modelį, tuomet duomenų sutvarkymui išskyla kai kurie papildomi reikalavimai:

visi veiksniai turi būti centruoti (jų vidurkis turi būti lygus nuliui);

priklausomas kintamasis turi būti nurodytas ne realia jo verte, tačiau suskaičiuotos gražos per atitinkamus periodus, ir po to turėtų būti sukuriamas fiktyvus kintamasis, kuris būtų lygus priklausomojo kintamojo ir nerizikingos palūkanų normos tame periode skirtumui. Esant tokioms sąlygoms modelis skaičiuos arbitražo įkainojimo teorijos modeliui reikalingus aprašyti parametrus. Suprantama, kad kitos sąlygos, aprašytos darbe, turi būti patikrintos ir tokiam modeliui.

Jau parinkus veiksmus, ir surašius juos į matricą, kurioje vieno veiksmo istorinėm reikšmėm yra skiriama  $m$  eilučių ( $i$ -toji eilutė –  $i$ -tajam periodui), tokią matricą reikia įrašyti į bylą „x.txt“, ir palikti tame pačiame kataloge, kaip ir bylą „y1.txt“, kurioje būtų priklausomojo kintamojo reikšmės, atitinkančios tuos pačius  $m$  periodų. Programos naudojimas yra glaudžiai susijęs su matematinėmis žiniomis, todėl teisingai parenkant ir suskirstant duomenis galima išlošti nemažai kompiuterinio skaičiavimo laiko. Šių dviejų bylų, esančių viename kataloge, jau užtenka darbo programai. Programos tekstas „nekoreliuotiems.sci“ arba „koreliuotiems.sci“ pirmiausiai turi būti atidarytas scilab aplinkoje, ir įvykdytas klavišais [Ctrl] ir [L], juos paspaudžiant vienu metu. Tuomet pasirodo dialogo langas, kuriame vartotojas turėtų nurodyti, kuriame kataloge yra darbui paruoštos bylos „x.txt“ ir „y1.txt“. Vykdydamas programinį kodą „koreliuotiems.sci“ - po dialogo lango dar kompiuteris per vartotojo sąsają paklausia vartotojo, kiek pirmų veiksmų yra koreliuoti. Tokiu atveju, kai vartotojui žinoma, kad dėl per didelio multikolinearumo (dispersijos mažėjimo koeficientas ne didesnis kaip 4) keli veiksniai tikrai nebus įtraukti į vieną modelį, šiuos veiksmus vartotojas gali įdėti bylos „x.txt“ pradiniuose stulpeliuose, ir vykdydamas programą, sutaupyti daug kompiuterinio laiko, nes šie veiksniai jau nebus perrinkinėjami vienas su kitu. Jei veiksmų skaičius yra nedidelis, tuomet paprastumo ir aiškumo dėlei geriau naudoti programos kodą „nekoreliuotiems.sci“. Programai baigus savo darbą, vartotojui nurodytame darbiname kataloge yra pateikiamos kelios rezultatų bylos. Byloje „issirink.txt“ yra nurodoma, kurie veiksniai parinkti, koks yra gautas modelio tikslumas, taip pat čia nurodomos

vidutinės liekanų kvadratų sumos, kai priklausomu kintamuoju yra nustatomas vienas iš tame modelyje parinktų veiksnių. Byloje „Bmatrix.txt“ i-tąją eilutę yra iš eilės surašomi kiekvienam koeficientui priskiriami regresijos lygties koeficientai. Jei koeficientas nėra parinktas, aiškumo dėlei jis yra prilygintas nuliui. Taip yra surašomos visų parinktų geriausių modelių eilutės. Byloje „SeSrR2sdj.txt“ yra iš eilės, kiekvienam modeliui, surašyti tokie koeficientai: pirmame stulpelyje įrašytas koreguotasis determinacijos koeficientas, antrame – modelio liekamųjų narių kvadratų suma, trečiame stulpelyje – regresijos kvadratų suma. Paskutiniai du koeficientai yra reikalingi hipotezėms tikrinti. Taip pat pateikiama byla „liekanos.txt“. Joje nurodomi kiekvieno parinkto modelio regresijos lygties liekamieji nariai. Pirmame stulpelyje pateikiami nariai to modelio, kuris turi vieną koeficientą, antrame to, kuris turi du koeficientus, ir taip toliau, iki to, kuris pateikiamas paskutinis.

Šią programą taip pat galima naudoti ir tikrinant penktąją modelio patikimumo sąlygą. Tuomet ypač naudingas yra bylos „liekanos.txt“ paskutinis stulpelis.

Taip pat prie programos pridamos ir kelios skaičiuoklių „Open Office Spreadsheets“ arba „Microsoft Excel“ bylos, kuriose yra paprasta tikrinti hipotezes. Tačiau jei yra galimybė – galima hipotezes tikrinti ir kitais paketais. Šios programos esmė yra parinkti geriausio koreguoto determinacijos koeficiento modelį, turint labai daug veiksnių.

Reikia pastebėti, kad Scilab programa savo veikimo principu yra labai panaši į programą Matlab, dėl to šias procedūras galima nesunkiai pakeisti į matlab programinį kodą. Programos „nekoreliuoti.sci“ ir programos „koreliuoti.sci“ tekstai pateikti 4 priede.

## 5. REZULTATAI

Pagal modelį, kurį aprašo (25) lygtis, vidutinio buto Kauno miesto centre vieno kvadratinio metro vertė 2009 metų pirmą ketvirtį buvo lygi maždaug 2510LT. Tai yra, vidutinis 45 kvadratinio metrų ploto dviejų kambarių butas Kauno miesto centre turėjo kainuoti apie 112 800LTL. Todėl tikėtina, kad investuotojui turint vidutinį butą, už kurį siūloma daug didesnė suma – jį apsimoka parduoti (arbitražo galimybė). Ir atvirkščiai – jei investuotojas turi galimybę nusipirkti daug pigesni butą – jis pasinaudos arbitražo galimybe, jei šiuos veiksmus atliks.

Pastebėta, kad daugelis veiksnių, esančių tiesinėj priklausomybėj su kitais veiksniais, stipriai koreliuoja tarpusavyje, taigi ir su vienu nežinomu ekonominiu veiksmiu.

## 6. DISKUSIJA

Atliekant darbą buvo pastebėta, kad vengiant multikolinearumo dažnai pavykdavo gauti koeficientus prie veiksmų tais pačiais ženklais, kaip ir veiksmų koreliacijos su priklausomu kintamuoju koeficiento ženklas. Darbo metu buvo pastebėta, kad daug viešai pateikiamų ekonominių veiksmų gerai koreliuoja tarpusavyje, vadinasi – seka vieną ir tą patį nežinomą ekonominį veiksmą. Aišku tai, kad dažniausiai daugelis aktyvų su tam tikru vėlavimu taip pat seka tą patį veiksmą. Tačiau nagrinėjant daugialypės regresijos modelius yra naudinga rasti kitus veiksmus, kurie nekoreliuotų su pirmaisiais. Darbo metu buvo bandyta susieti ekonominius pokyčius su socialiniais pokyčiais. Atvirose rinkose perkant aktyvus labai stipriai veikia socialiniai veiksniai. Taip pat, tose atvirose rinkose yra daug didesnis šansas užimti patogią padėtį arbitražo pozicijoje. Mano nuomone – jei pavyktų gerai įvertinti kelis socialinius veiksmus, kurio priklausomybę nuo priklausomojo kintamojo pavyktų paversti į tiesinę, tuomet galima būtų statistiškai žymiai pagerinti daugialypės regresijos modeliais vertinamus įkainojimo metodus. Tai yra, kaip vertinti žmogiškąjį veiksmą įkainojime?

Anksčiau ekonomistai rinkdavosi daugiausia ekonominius veiksmus, ir pasitikėdavo pačia rinka. Tačiau dabar aktyvai nėra padengti dažnai niekuo, tik pasitikėjimu. Be to, paprastai aktyvų palūkanos keičiais dėl atsiradusio ar dingusio patikimumo. Tačiau įdomu, kad JAV obligacijų vertę gali pakeisti ir Federalinio rezervų banko spausdinami doleriai. Ir nors nuo 1971m. Šie doleriai nėra padengti auksu ar kuo kitu, tačiau obligacijų patikimumas lieka panašus su panašią graža. Nuo kokių veiksmų tai priklauso? Kokiais veiksniais galima įvertinti patikimumą?

Radus veiksmą, apibūdinantį žmonių lūkesčius, tačiau nesunkiai nustatomą iš kitų rodiklių, labai tikėtina, būtų galima patikslinti būstų kainų prognozavimą. Tas pats pasakytina apie atlyginimus. Yra labai sunku nustatyti momentinį vidutinį atlyginimą, ir pagal jį įkainoti aktyvus, dėl to geriau naudoti veiksmus, gerai koreliuojančius su ateities aktyvo kainomis.

Mano manymu - tyrimui gerai parinkti tuos ekonominius ar socialinius veiksmus, kuriuos lengva nuspėti iš anksto. Kalbant apie Chen, Roll ir Ross siūlytus veiksmus reikia suprasti, jog nuo tada, kai 1971m. USD valiuta nėra padengta auksu, o JAV valstybės skola nuolatos auga – šios valstybės skolos popieriai nebėra tokie patikimi pasaulio rinkose [4], ir dėl to galima kritiškiau žiūrėti į veiksmus, kurių parinkimas buvo siūlytas prieš 20 metų. Be to [4] nurodoma, kad infliacijos skaičiavimas ES šalyse ir JAV skiriasi.

## 7. IŠVADOS

Pritaikius kompiuterinį veiksnių perrinkimą tapo įmanoma daug greičiau surasti gerus modelius; Kuo didesnė koreguotojo determinacijos koeficiento reikšmė, tuo didesnis gali būti multikolinearumas;

Butų kainas gerai apibūdina vienas ekonominis veiksnys, su kuriuo gerai koreliuoja daugelis darbe nagrinėtų veiksnių (priklausantys darbe nagrinėti grupei A);

Butų kainas gerai apibūdina žmonių lūkesčiai. Darbe jie buvo vertinti pagal žmonių skaičių, kurie tikisi gauti didelį atlyginimą. Tačiau tikslesnis socialinis veiksnys vis dar lieka nežinomas.

Butų kainas gerai apibūdina populiaros valiutos palūkanos. Tačiau nagrinėti veiksniai, gerai koreliuojantys su butų kainomis, neturėjo tiesinės priklausomybės, dėl to negalėjo būti taikomi tiesinėje prognozėje (žr. Veiksniu B3 ir butų kainų porinių stebėjimų grafiką, 2 priedas)

Modelis, gerai apibūdinantis butų kainų pokyčius (koreguotasis determinacijos koeficientas 0.96), gautas iš veiksnių: bedarbystė miestuose (proc), gyventojų lūkesčiai, matuojami bedarbių, siekiančių gauti daugiau, negu 1500LTL per mėnesį, skaičiumi (tūkstančiais), taip pat materialinėmis investicijomis į šalį (milijardais litų).

Jei aktyvo gražos stipriai koreliuoja su kokiais nors veiksniais, ypač, jei ši priklausomybė tiesinė, tuomet naudingiau yra naudoti arbitražo įkainojimo teorijos modelį. Kitu atveju – paprastos daugialypės regresijos lygties prognozavimo modelį.

## 8. REKOMENDACIJOS

- Šis darbas yra labai gera pradžia platesnei ir gilesnei daugialypių regresijos lygčių analizei, ir arbitražo modelių sudarymui. Esminė dalis, ant kurios pastatyta ši programa, yra visų galimų rinkinių perrinkimas, ir kai kurių sąlygų patikrinimas skaitmeniniais metodais.
- Tęsiant darbą būtų galima automatizuoti kitus patikrinimus apie modelio koeficientus ir apie patį modelį, tokiu būdu dar skaičiavimo metu atmetant netinkamus modelius.
- Taip pat galima plėsti duomenų paiešką. Kad duomenys ne tik būtų dažnai atnaujinami, tačiau ir lengvai prieinami, nebrangūs, ir gerai koreliuotų ne su vienu pagrindiniu rinkos veiksniu, tačiau su kitu (tokiu, kaip žmonių lūkesčiai).
- Būtų įdomu pabandyti įkainoti apvaliąją medieną. Medienos kainos koreliuoja su daugelio veiksnių reikšmėmis, buvusiomis prieš kelis mėnesius. Naudojant tokią analizę galima pasinaudoti arbitražo situacija, jau iš anksto įvertinant būsimas medienos kainas.

## 9. PADĖKOS

1. Dėkoju darbo vadovui, už literatūrą ir patarimus;
2. Dėkoju šeimai už pagalbą ieškant medžiagos ir atliekant šį darbą;
3. Dėkoju universitetui, kad suteikė galimybes giliau žiūrėti į mokslą.



## 10. NUORODOS (ŠALTINIAI IR LITERATŪRA)

- [1] – Investment science, David G. Luenberger, p. 197-223, Oxford University Press, USA 1997;
- [2] – Statistika ir jos taikymai II, V. Čekanavičius, G. Murauskas, p122-196, TEV, Vilnius, 2008
- [3] - [http://en.wikipedia.org/wiki/Arbitrage\\_pricing\\_theory](http://en.wikipedia.org/wiki/Arbitrage_pricing_theory)
- [4] - [http://www.marketnews.lt/naujiena/apie\\_jav\\_kinija\\_ir\\_rinku\\_sugriuvima\\_2009-01-30](http://www.marketnews.lt/naujiena/apie_jav_kinija_ir_rinku_sugriuvima_2009-01-30)
- [5] – Analysis of financial data, Gary Koop, p. 91-135, John Wiley & Sons, 2006
- [6] - [www.newyorkfed.org/research/staff\\_reports/sr216.pdf](http://www.newyorkfed.org/research/staff_reports/sr216.pdf)
- [7] - <http://en.wikipedia.org/wiki/Arbitrage>
- [8] - [http://en.wikipedia.org/wiki/Least-squares\\_estimation\\_of\\_linear\\_regression\\_coefficients](http://en.wikipedia.org/wiki/Least-squares_estimation_of_linear_regression_coefficients)
- [9] – Modulio „Matematinė statistika P160B101“ paskaitų konspektai. Dėstytojas doc. A. Jokimaitis.
- [10] – <http://www.scilab.org/product/man/> - išsamus kai kurių funkcijų aprašymas
- [11] - Modern portfolio theory and investment analysis, Edwin J. Elton, Martin J. Gruber, Stephen J. Brown, William N. Goetzmann, p. 159-177, John Wiley & Sons, 7 edition, 2006;

# 1 PRIEDAS. PRADINIAI VEIKSNIAI. PRADINIAI DUOMENYS.

Parinkti pradiniai veiksniai, jų reikšmės. Parinktų butų kainų reikšmės.

**12. lentelė: Stipriai koreliuojantys tarpusavyje veiksniai (pirmoji lentelė)**

	A1	A2	A3	A4	A5	A6	A7	A8
2000	11.57	102.34	0.65	3.27	4.93	5.07	17.70	23.98
	11.71	92.33	0.67	3.74	4.57	5.19	17.65	28.03
	12.06	92.26	0.67	3.70	4.92	5.85	17.60	29.05
2001	10.98	92.70	0.63	4.06	4.77	5.48	17.95	21.15
	12.26	87.39	0.65	4.41	5.07	5.98	18.30	23.10
	12.50	82.13	0.67	4.27	5.19	5.76	18.60	24.18
2002	12.90	69.80	0.65	4.38	5.85	7.03	18.90	20.88
	11.41	75.56	0.63	4.07	5.48	5.84	18.70	18.90
	13.13	89.78	0.67	5.12	5.98	7.25	15.10	25.20
2003	13.68	83.49	0.70	4.93	5.76	6.64	13.60	23.38
	13.86	88.17	0.70	5.00	7.03	7.74	14.30	27.47
	12.68	84.78	0.67	5.05	5.84	6.53	14.80	27.85
2004	14.13	96.77	0.71	4.92	7.25	7.12	14.30	24.35
	14.82	134.95	0.73	5.50	6.64	7.35	12.70	25.32
	15.33	173.94	0.73	5.78	7.74	8.45	12.40	27.43
2005	13.52	174.48	0.74	5.52	6.53	7.29	14.40	28.67
	15.48	222.91	0.81	6.11	7.12	8.55	11.60	29.62
	16.37	206.25	0.85	6.73	7.35	8.89	11.40	31.02
2006	17.33	224.19	0.87	7.45	8.45	9.64	10.90	41.17
	15.06	293.97	0.86	6.82	7.29	8.43	10.30	35.73
	17.74	342.38	0.89	7.80	8.55	10.70	8.80	49.20
2007	19.15	411.78	0.95	8.56	8.89	11.26	7.70	54.68
	20.12	527.05	1.00	9.59	9.64	12.76	7.40	56.07
	17.34	451.47	1.00	9.07	8.43	11.86	6.10	56.07
2008	20.25	436.67	1.06	10.13	10.70	13.35	5.70	62.78
	22.21	387.66	1.12	10.03	11.26	13.93	5.60	68.03
	23.00	420.92	1.17	9.65	12.76	14.13	4.60	55.05
2009	20.22	493.48	1.18	9.65	11.86	13.72	5.00	53.77
	24.38	492.01	1.29	10.94	13.35	15.87	4.10	63.03
	26.20	529.42	1.36	11.56	13.93	15.97	4.00	70.41
2010	27.34	569.79	1.42	11.03	14.13	15.95	3.80	76.23
	12.97	73.15	0.66	4.40	5.71	6.78	18.76	22.30

**13. lentelė: Veiksniai, stipriai koreliuojantys tarpusavyje (antroji lentelė)**

	A9	A10	A11	A12	A13	A14	A15
2000	546	149.56	26.25	17.88	18.35	15.66	8.30
	471	151.81	25.02	19.01	17.51	17.88	8.34
	497	151.96	24.07	18.35	17.43	19.01	8.39
2001	324	148.18	24.52	17.51	17.75	18.35	8.42
	596	149.52	23.80	17.43	18.10	17.51	8.45
	519	149.20	23.45	17.75	18.37	17.43	8.46
	503	147.69	24.07	18.10	18.61	17.75	8.47
2002	309	144.46	23.75	18.37	19.11	18.10	8.49
	721	147.51	23.92	18.61	17.68	18.37	8.52
	584	149.28	25.77	19.11	14.23	18.61	8.56
	678	149.86	25.83	17.68	13.72	19.11	8.60
2003	424	146.12	26.81	14.23	14.55	17.68	8.61
	835	149.35	26.11	13.72	14.77	14.23	8.61
	820	151.45	26.95	14.55	13.82	13.72	8.62
	780	150.36	27.79	14.77	12.26	14.55	8.66
2004	589	152.30	30.19	13.82	13.22	14.77	8.78
	1200	157.05	29.93	12.26	13.76	13.82	8.99
	1085	164.04	30.54	13.22	11.21	12.26	9.25
	1127	167.67	29.95	13.76	11.34	13.22	9.50
2005	781	167.50	31.15	11.21	10.73	13.76	9.69
	1592	169.17	31.42	11.34	9.88	11.21	9.77
	1484	176.20	29.03	10.73	8.31	11.34	9.77
	1631	181.71	29.25	9.88	7.62	10.73	9.73
2006	1151	183.17	29.29	8.31	7.02	9.88	9.70
	1923	188.70	29.29	7.62	5.83	8.31	9.69
	1971	195.18	30.59	7.02	5.75	7.62	9.72
	2441	199.89	31.10	5.83	5.24	7.02	9.77
2007	1760	203.27	32.49	5.75	4.68	5.83	9.83
	2268	217.99	32.97	5.24	4.79	5.75	9.90
	2459	227.49	33.72	4.68	3.99	5.24	9.95
	2313	235.28	33.89	4.79	3.90	4.68	10.00
2008	530	150.24	24.26	3.99	4.03	4.79	10.02

**14. lentelė: Įvairūs veiksniai (pirmoji lentelė)**

	B1	B2	B3	B4	B5	B6	B7
2000	1.796	1.427	2.942	2.507	0.700	1.047	3.917
	1.457	1.739	2.655	3.014	1.799	1.049	3.709
	2.148	2.232	3.126	2.799	5.500	1.138	2.099
2001	1.427	1.855	3.338	2.704	7.279	1.062	3.916
	1.563	1.427	3.833	2.507	8.017	1.144	2.359
	1.489	1.739	4.551	3.014	8.592	1.177	1.895
2002	2.646	2.232	4.991	2.799	9.337	1.099	0.664
	1.778	1.549	4.844	2.395	8.402	1.122	1.851
	2.133	1.661	4.571	2.452	4.841	1.147	0.084
2003	1.711	2.004	4.435	2.550	2.989	1.009	0.312
	2.739	1.872	3.656	3.182	4.503	1.013	0.251
	1.475	1.544	3.279	2.665	4.199	0.953	0.619
2004	2.194	2.879	3.446	2.518	3.300	0.915	0.466
	1.843	3.683	3.438	2.454	6.500	0.869	0.555
	2.663	2.926	3.279	2.962	5.400	0.857	0.459
2005	1.771	3.023	2.861	2.507	5.800	0.795	0.610
	2.438	3.469	2.514	2.790	9.600	0.813	0.710
	2.161	4.667	2.145	2.358	6.700	0.820	0.584
2006	2.194	4.006	2.121	3.342	8.300	0.804	0.532
	1.612	3.722	2.120	2.689	6.400	0.737	0.490
	2.903	4.137	1.960	2.849	6.000	0.772	0.293
2007	2.695	4.740	2.116	2.447	6.200	0.826	0.243
	3.174	2.972	2.148	3.112	8.600	0.832	0.132
	2.786	2.653	2.150	2.750	9.100	0.845	0.051
2008	3.218	3.074	2.147	2.733	8.800	0.824	0.002
	3.902	3.749	2.107	2.414	9.200	0.786	0.035
	4.480	3.126	2.178	3.305	16.700	0.789	0.046
2009	4.061	3.011	2.489	2.827	12.500	0.758	0.065
	4.926	3.545	2.818	2.876	20.500	0.749	0.233
	4.405	4.311	3.055	2.387	20.000	0.739	0.724
2010	4.920	2.986	3.424	3.246	20.300	0.701	0.869
	5.382	2.183	4.906	2.951	22.800	0.680	0.871

**15. lentelė: Įvairūs veiksniai (antroji lentelė)**

	B8	B9	B10	B11	B12	B13	B14
2000	1.518	3.833	3.897	1.037	0.967	1.012	88
	1.761	4.551	6.398	1.067	0.933	1.022	65
	2.319	4.991	3.189	1.126	0.993	1.040	87
2001	1.076	4.844	2.280	1.147	1.047	1.047	84
	1.560	4.571	3.897	1.083	1.049	1.027	84
	1.985	4.435	6.398	1.183	1.138	1.057	99
2002	3.203	3.656	3.189	1.098	1.062	1.032	104
	1.315	3.279	2.244	1.116	1.144	1.037	106
	2.009	3.446	3.992	1.151	1.177	1.048	101
2003	2.089	3.438	6.564	1.071	1.099	1.023	104
	2.712	3.279	3.351	1.020	1.122	1.007	93
	1.362	2.861	2.399	1.006	1.147	1.002	87
2004	2.071	2.514	3.821	0.926	1.009	0.975	99
	2.231	2.145	7.206	0.850	1.013	0.947	101
	3.013	2.121	3.549	0.910	0.953	0.969	100
2005	1.508	2.120	2.903	0.835	0.915	0.942	128
	2.236	1.960	4.445	0.801	0.869	0.929	108
	2.711	2.116	7.977	0.821	0.857	0.936	89
2006	3.642	2.148	3.805	0.821	0.795	0.937	123
	1.807	2.150	2.551	0.752	0.813	0.909	110
	2.545	2.147	4.470	0.755	0.820	0.911	121
2007	3.137	2.107	8.864	0.813	0.804	0.933	100
	4.697	2.178	4.053	0.811	0.737	0.932	132
	2.303	2.489	2.863	0.846	0.772	0.946	119
2008	3.365	2.818	4.698	0.842	0.826	0.944	123
	3.880	3.055	9.576	0.778	0.832	0.920	97
	5.621	3.424	4.109	0.779	0.845	0.920	118
2009	3.554	3.725	2.976	0.758	0.824	0.912	153
	4.627	3.927	5.268	0.757	0.786	0.911	145
	5.209	4.176	10.462	0.744	0.789	0.906	159
2010	6.923	4.791	4.359	0.732	0.758	0.901	159
	3.067	3.934	4.446	0.679	0.749	0.879	180

**16. lentelė: Vidutinės būstų kainos Kauno miesto centre (LTL už kvadratinį metrą)**

Periodas	Svoriai	Vidutinės vertės (LTL už kvadratinį metrą tą ketvirtį)	Prognozuotos reikšmės (tt=5)	Prognozuotos reikšmės (t =3)
1998 I	8	1345	1345	1345
1998 II	11	1224.91	1224.91	1224.91
1998 III	11	1292.27	1292.27	1292.27
1998 IV	8	1318	1318	1318
1999 I	5	1158.4	1090.33	1158.4
1999 II	1	1016	898.12	1023.44
1999 III	3	1288	815.44	1288
1999 IV	4	1838	823.31	1838
2000 I	3	1378.67	902.8	1378.67
2000 II	4	1060	1034.95	1060
2000 III	5	1108.4	1200.8	1108.4
2000 IV	7	1501.43	1420.25	1501.43
2001 I	10	1635.7	1664.42	1635.7
2001 II	4	1498.67	1440.52	1498.67
2001 III	5	1275.4	1307.74	1275.41
2001 IV	18	1692.11	1688.43	1692.1
2002 I	6	1588.17	1591.18	1588.29
2002 II	12	1238.75	1238.25	1238.53
2002 III	7	1337.14	1337.98	1338.52
2002 IV	10	1448.8	1447.05	1445.21
2003 I	12	1345.5	1350.85	1356.68
2003 II	15	1828.71	1822.08	1814.04
2003 III	0	2060.61	2210.41	2264.77
2003 IV	2	2292.5	2382.9	2492
2004 I	4	2592.5	2463.62	2477.06
2004 II	9	2458.11	2576.62	2483.05
2004 III	3	3137	2800.2	3116.95
2004 IV	4	3008	3029.55	3012.03
2005 I	9	3056.71	3114.1	3056.23
2005 II	7	3132.86	3062.82	3133.03
2005 III	5	3060.2	3218.98	3060.14
2005 IV	8	3437.88	3220.76	3437.89
2006 I	4	3001	3555.75	3000.99
2006 II	2	4994	4064.5	3513.52
2006 III	7	4229.75	4338.17	4229.75
2006 IV	11	4280.5	4262.05	4280.5
2007 I	4	4982.75	4596.92	4982.75
2007 II	15	5193.71	5193.34	5193.71
2007 III	5	5476.4	5476.4	5476.4
2007 IV	5	4877.2	4877.2	4877.2
2008 I	8	4716.88	4716.88	4716.88


**17. lentelė: Suglodontų ir realių verčių palyginimas valiūrų EUR (euro) ir USD (JAV dolerio) kursų santykiui, 1991.01 - 2007.01 laikotarpiu, mėnesio pirmą darbo dieną**

Tikros istorinės reikšmės	Reikšmės, prognozuotos glodinančiu ir interpoliaciniu spline
0.8570 1.0670 1.0994 0.9290 0.8207 0.8320	0.8570 1.0390 1.0994 0.9370 0.8201 0.8320
0.8814 1.0491 1.1113 0.9261 0.8201 0.8290	0.8775 1.0491 1.0932 0.9266 0.8201 0.8360
0.9105 1.0787 1.1162 0.9153 0.8315 0.8462	0.9028 1.0821 1.1024 0.9153 0.8202 0.8414
0.9287 1.1264 1.1218 0.8952 0.8214 0.8446	0.9287 1.1199 1.1218 0.8989 0.8165 0.8446
0.9453 1.1375 1.1655 0.8495 0.8041 0.8258	0.9510 1.1375 1.1446 0.8815 0.8041 0.8426
0.9588 1.1786 1.1510 0.8693 0.7809 0.8422	0.9653 1.1192 1.1580 0.8693 0.7806 0.8355
0.9674 1.1468 1.1474 0.8904 0.7522 0.8240	0.9674 1.0845 1.1474 0.8660 0.7545 0.8240
0.9334 1.0620 1.1111 0.9103 0.7372 0.7921	0.9558 1.0620 1.1051 0.8651 0.7372 0.8095
0.9427 1.0679 1.0709 0.8573 0.7674 0.7777	0.9401 1.0725 1.0503 0.8573 0.7371 0.7956
0.9326 1.0832 1.0088 0.8635 0.7552 0.7862	0.9326 1.1058 1.0088 0.8370 0.7507 0.7862
0.9483 1.1439 1.0234 0.8349 0.7715 0.7837	0.9423 1.1439 0.9988 0.8124 0.7715 0.7841
0.9908 1.1274 1.0201 0.7952 0.7768 0.7794	0.9650 1.1714 1.0071 0.7952 0.7937 0.7865
0.9930 1.1826 1.0129 0.8026 0.8127 0.7893	0.9930 1.1833 1.0129 0.7936 0.8131 0.7893
1.0308 1.1772 1.0104 0.8007 0.8264 0.7862	1.0192 1.1772 1.0007 0.8024 0.8264 0.7882
1.0365 1.1423 1.0062 0.8130 0.8249 0.7582	1.0388 1.1535 0.9767 0.8130 0.8314 0.7792
1.0472 1.0976 0.9526 0.8347 0.8106 0.7580	1.0472 1.1230 0.9526 0.8186 0.8316 0.7580
1.0975	1.0433


## 2 PRIEDAS. PORINIŲ STEBĖJIMŲ GRAFIKAI

Veiksnių ir butų kainų porinių stebėjimų grafikai. Pagal veiksnio pavadinimą.


### A1. Porinių stebėjimų grafikas



### A2. Porinių stebėjimų grafikas




### A3. Porinių stebėjimų grafikas







A4. Porinių stebėjimų grafikas



A5. Porinių stebėjimų grafikas




A6. Porinių stebėjimų grafikas




A7. Porinių stebėjimų grafikas


A8. Porinių stebėjimų grafikas



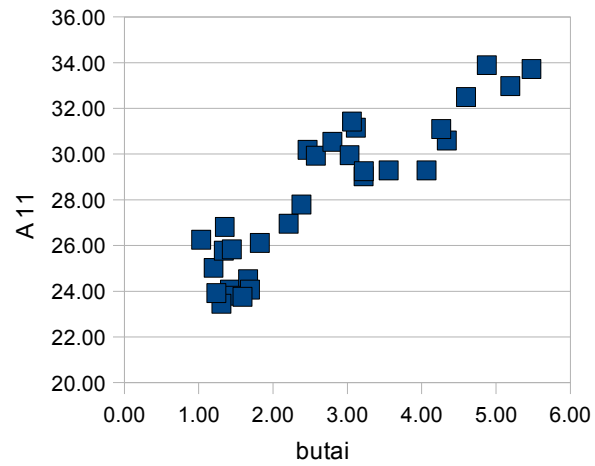
A9. Porinių stebėjimų grafikas




A10. Porinių stebėjimų grafikas



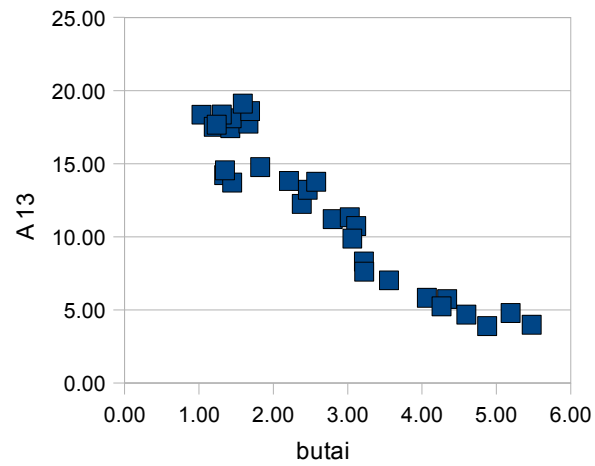
A11. Porinių stebėjimų grafikas




A12. Porinių stebėjimų grafikas




A13. Porinių stebėjimų grafikas



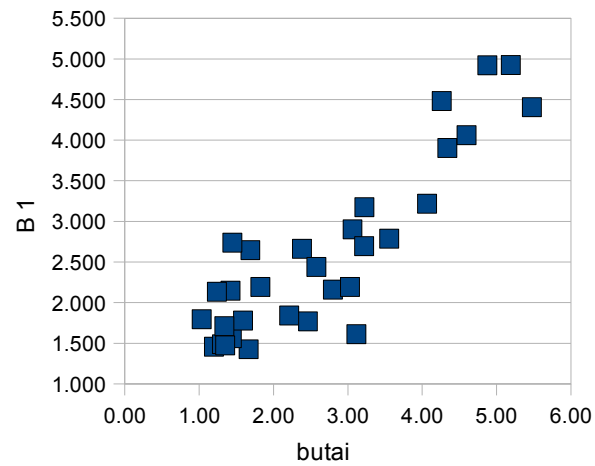
A14. Porinių stebėjimų grafikas




A15. Porinių stebėjimų grafikas




B 1. Porinių stebėjimų grafikas




B 2. Porinių stebėjimų grafikas




B 3. Porinių stebėjimų grafikas




B 4. Porinių stebėjimų grafikas




B 5. Porinių stebėjimų grafikas




B 6. Porinių stebėjimų grafikas




B 7. porinių stebėjimų grafikas




B 8. Porinių stebėjimų grafikas




B 9. Porinių stebėjimų grafikas




B 10. Porinių stebėjimų grafikas




B 11. Porinių stebėjimų grafikas



B 12. Porinių stebėjimų grafikas




B 13. Porinių stebėjimų grafikas





A14. Porinių stebėjimų grafikas



### 3 PRIEDAS. VEIKSNIUS APIBŪDINANČIOS KORELIACINĖS MATRICOS

18. lentelė: Veiksnius apibūdinanti darbinė koreliacinė matrica (pirmoji lentelė)

	A1	A2	A3	A4	A5	A6	A7	A8	A9	A10
A1	1	0.92	0.98	0.96	0.98	0.98	-0.94	0.95	0.98	0.97
A2	0.92	1	0.95	0.97	0.91	0.95	-0.95	0.96	0.91	0.93
A3	0.98	0.95	1	0.96	0.98	0.98	-0.94	0.95	0.96	0.99
A4	0.96	0.97	0.96	1	0.96	0.99	-0.97	0.96	0.95	0.94
A5	0.98	0.91	0.98	0.96	1	0.98	-0.93	0.92	0.97	0.96
A6	0.98	0.95	0.98	0.99	0.98	1	-0.96	0.96	0.97	0.96
A7	-0.94	-0.95	-0.94	-0.97	-0.93	-0.96	1	-0.93	-0.93	-0.9
A8	0.95	0.96	0.95	0.96	0.92	0.96	-0.93	1	0.93	0.95
A9	0.98	0.91	0.96	0.95	0.97	0.97	-0.93	0.93	1	0.94
A10	0.97	0.93	0.99	0.94	0.96	0.96	-0.9	0.95	0.94	1
A11	0.86	0.86	0.87	0.87	0.86	0.85	-0.9	0.81	0.84	0.84
A12	-0.93	-0.94	-0.95	-0.96	-0.94	-0.95	0.96	-0.92	-0.93	-0.92
A13	-0.94	-0.95	-0.94	-0.97	-0.94	-0.96	0.99	-0.94	-0.92	-0.91
A14	-0.95	-0.94	-0.96	-0.95	-0.95	-0.95	0.94	-0.92	-0.95	-0.94
A15	0.9	0.95	0.91	0.96	0.89	0.93	-0.95	0.92	0.89	0.87
B1	0.93	0.84	0.92	0.87	0.95	0.93	-0.84	0.86	0.93	0.91
B2	0.63	0.61	0.58	0.65	0.59	0.61	-0.69	0.57	0.63	0.52
B3	-0.47	-0.61	-0.49	-0.57	-0.45	-0.51	0.64	-0.58	-0.53	-0.44
B4	0.25	0.23	0.23	0.2	0.26	0.24	-0.2	0.23	0.24	0.23
B5	0.82	0.72	0.84	0.76	0.83	0.81	-0.67	0.72	0.79	0.86
B6	-0.78	-0.8	-0.78	-0.81	-0.78	-0.78	0.87	-0.74	-0.76	-0.72
B7	-0.53	-0.49	-0.46	-0.6	-0.55	-0.58	0.64	-0.46	-0.51	-0.38
B8	0.92	0.79	0.87	0.82	0.9	0.87	-0.78	0.82	0.88	0.87
B9	-0.04	-0.12	0.03	-0.16	-0.04	-0.08	0.25	-0.02	-0.05	0.14
B10	0.42	0.28	0.36	0.36	0.33	0.34	-0.34	0.38	0.42	0.35
B11	-0.8	-0.82	-0.79	-0.83	-0.79	-0.8	0.88	-0.76	-0.79	-0.73
B12	-0.76	-0.87	-0.78	-0.81	-0.73	-0.78	0.82	-0.81	-0.76	-0.75
B13	-0.81	-0.83	-0.8	-0.84	-0.8	-0.81	0.89	-0.77	-0.8	-0.74
B14	0.79	0.8	0.82	0.8	0.82	0.81	-0.75	0.73	0.74	0.81

**19. lentelē: Veiksnius apibūdinanti darbinē koreliacinē matrica (antroji lentelē)**

	A11	A12	A13	A14	A15	B1	B2	B3	B4
A1	0.86	-0.93	-0.94	-0.95	0.9	0.93	0.63	-0.47	0.25
A2	0.86	-0.94	-0.95	-0.94	0.95	0.84	0.61	-0.61	0.23
A3	0.87	-0.95	-0.94	-0.96	0.91	0.92	0.58	-0.49	0.23
A4	0.87	-0.96	-0.97	-0.95	0.96	0.87	0.65	-0.57	0.2
A5	0.86	-0.94	-0.94	-0.95	0.89	0.95	0.59	-0.45	0.26
A6	0.85	-0.95	-0.96	-0.95	0.93	0.93	0.61	-0.51	0.24
A7	-0.9	0.96	0.99	0.94	-0.95	-0.84	-0.69	0.64	-0.2
A8	0.81	-0.92	-0.94	-0.92	0.92	0.86	0.57	-0.58	0.23
A9	0.84	-0.93	-0.92	-0.95	0.89	0.93	0.63	-0.53	0.24
A10	0.84	-0.92	-0.91	-0.94	0.87	0.91	0.52	-0.44	0.23
A11	1	-0.9	-0.9	-0.9	0.9	0.74	0.76	-0.68	0.17
A12	-0.9	1	0.96	0.97	-0.93	-0.85	-0.64	0.62	-0.17
A13	-0.9	0.96	1	0.94	-0.95	-0.85	-0.68	0.64	-0.22
A14	-0.9	0.97	0.94	1	-0.91	-0.87	-0.66	0.59	-0.15
A15	0.9	-0.93	-0.95	-0.91	1	0.77	0.74	-0.68	0.22
B1	0.74	-0.85	-0.85	-0.87	0.77	1	0.45	-0.32	0.31
B2	0.76	-0.64	-0.68	-0.66	0.74	0.45	1	-0.66	-0.06
B3	-0.68	0.62	0.64	0.59	-0.68	-0.32	-0.66	1	-0.17
B4	0.17	-0.17	-0.22	-0.15	0.22	0.31	-0.06	-0.17	1
B5	0.65	-0.76	-0.68	-0.76	0.67	0.84	0.37	-0.12	0.27
B6	-0.96	0.86	0.88	0.84	-0.86	-0.64	-0.81	0.73	-0.16
B7	-0.52	0.55	0.62	0.48	-0.59	-0.49	-0.54	0.24	-0.07
B8	0.69	-0.76	-0.79	-0.8	0.74	0.91	0.47	-0.29	0.47
B9	-0.3	0.17	0.22	0.12	-0.27	0.1	-0.55	0.43	0.12
B10	0.28	-0.27	-0.33	-0.35	0.29	0.26	0.53	-0.18	-0.33
B11	-0.95	0.87	0.88	0.86	-0.88	-0.66	-0.84	0.75	-0.13
B12	-0.86	0.81	0.82	0.83	-0.87	-0.63	-0.75	0.83	-0.25
B13	-0.96	0.88	0.88	0.87	-0.89	-0.67	-0.84	0.75	-0.14
B14	0.77	-0.77	-0.76	-0.78	0.75	0.76	0.45	-0.22	0.23

**20. lentelė: Veiksnius apibūdinanti darbinė koreliacinė matrica (trečioji lentelė)**

	B5	B6	B7	B8	B9	B10	B11	B12	B13	B14
A1	0.82	-0.78	-0.53	0.92	-0.04	0.42	-0.8	-0.76	-0.81	0.85
A2	0.72	-0.8	-0.49	0.79	-0.12	0.28	-0.82	-0.87	-0.83	0.87
A3	0.84	-0.78	-0.46	0.87	0.03	0.36	-0.79	-0.78	-0.8	0.88
A4	0.76	-0.81	-0.6	0.82	-0.16	0.36	-0.83	-0.81	-0.84	0.86
A5	0.83	-0.78	-0.55	0.9	-0.04	0.33	-0.79	-0.73	-0.8	0.88
A6	0.81	-0.78	-0.58	0.87	-0.08	0.34	-0.8	-0.78	-0.81	0.88
A7	-0.67	0.87	0.64	-0.78	0.25	-0.34	0.88	0.82	0.89	-0.82
A8	0.72	-0.74	-0.46	0.82	-0.02	0.38	-0.76	-0.81	-0.77	0.81
A9	0.79	-0.76	-0.51	0.88	-0.05	0.42	-0.79	-0.76	-0.8	0.81
A10	0.86	-0.72	-0.38	0.87	0.14	0.35	-0.73	-0.75	-0.74	0.87
A11	0.65	-0.96	-0.52	0.69	-0.3	0.28	-0.95	-0.86	-0.96	0.79
A12	-0.76	0.86	0.55	-0.76	0.17	-0.27	0.87	0.81	0.88	-0.85
A13	-0.68	0.88	0.62	-0.79	0.22	-0.33	0.88	0.82	0.88	-0.82
A14	-0.76	0.84	0.48	-0.8	0.12	-0.35	0.86	0.83	0.87	-0.84
A15	0.67	-0.86	-0.59	0.74	-0.27	0.29	-0.88	-0.87	-0.89	0.83
B1	0.84	-0.64	-0.49	0.91	0.1	0.26	-0.66	-0.63	-0.67	0.84
B2	0.37	-0.81	-0.54	0.47	-0.55	0.53	-0.84	-0.75	-0.84	0.48
B3	-0.12	0.73	0.24	-0.29	0.43	-0.18	0.75	0.83	0.75	-0.31
B4	0.27	-0.16	-0.07	0.47	0.12	-0.33	-0.13	-0.25	-0.14	0.29
B5	1	-0.51	-0.31	0.8	0.26	0.2	-0.52	-0.51	-0.54	0.83
B6	-0.51	1	0.58	-0.6	0.49	-0.25	0.98	0.85	0.98	-0.7
B7	-0.31	0.58	1	-0.45	0.6	-0.14	0.59	0.33	0.59	-0.53
B8	0.8	-0.6	-0.45	1	0.1	0.32	-0.62	-0.63	-0.63	0.77
B9	0.26	0.49	0.6	0.1	1	-0.02	0.5	0.29	0.48	-0.05
B10	0.2	-0.25	-0.14	0.32	-0.02	1	-0.28	-0.26	-0.29	0.08
B11	-0.52	0.98	0.59	-0.62	0.5	-0.28	1	0.87	1	-0.7
B12	-0.51	0.85	0.33	-0.63	0.29	-0.26	0.87	1	0.88	-0.66
B13	-0.54	0.98	0.59	-0.63	0.48	-0.29	1	0.88	1	-0.71
B14	0.83	-0.7	-0.53	0.77	-0.05	0.08	-0.7	-0.66	-0.71	1

## 4 PRIEDAS. PROGRAMŲ TEKSTAI

Programos tekstas „nekoreliuotiems.sci“

```
//answ=messagebox("Ar su vienu katalogu dirbsite?", "Klausimas", "question",
["Taip" "Ne"], "modal");
answ = 1
//pasirenkame darbinę direktoriją, su failais "x.txt" ir "y.txt" bei "10proc"

if (answ == 1) then
    printf('\n Pasirinkite direktorija su: \n matrica X (stulp. sk. nurodo
parametru sk.) [n x m]; \n Vektoriumi Y [n x t];')

    directory = uigetdir('/home', "pasirink kataloga")
    filename = directory + "/x.txt"
    X = fscanfMat(filename);

    filename = directory + "/y"+ string(1) + ".txt"
    Y = fscanfMat(filename);

// šie taikomi, jei norima X ir Y pasirinkti kitus
else
    printf('pasirinkite matrica X (stulp. sk. nurodo parametru sk.) [n x m]')
    X = fscanfMat(uigetfile());
    printf('pasirinkite vektorių stulpelį Y (eil. sk. nurodo duomenų sk.) (n x t)')
    Y = fscanfMat(uigetfile());

    directory = uigetdir()
end

// --- AA - modelio išmatuotos reikšmės,
// --- BB - turėtos reikšmės
// funkcijoms paduodamas vektorius-stulpelis
function [yse] = sserr(AA, BB)
    tt = size(AA);
    yse = zeros(tt(2))
    for i = 1:tt(2),
        ss = 0;
        for j = 1:tt(1) ,
            ss = ss + (AA(j, i) - BB(j, i))^2 ,
        end;
    yse(i)=ss;
end;
```

```

endfunction;

// --- AA - Y teorinių arba praktinių reikšmių vektorius
// --- pilnoji kvadratų arba regresijos modelio suma
function [yse] = ssTR(AA, k)
    tt = size(AA);
    for i = 1:tt(2),
        ss = 0;
        for j = 1:tt(1) ,
            ss = ss + (AA(j, i) - k(i))^2 ,
        end;
    yse(i) = ss;
end;
endfunction;

// -- skaičiuojamas vektoriaus AA vidurkis
function [ym] = ymean(AA)
    tt = size(AA);
    for i = 1:tt(2),
        yysum = 0;
        for j = 1:tt(1), yysum = yysum + AA(j, i);
        end;
    ym(i) = yysum/tt(1);
end;
endfunction;

function [nai] = lyginti(failoVardas, rsqr, XX)
    pada = fscanfMat(failoVardas);
    param = size(XX);
    n = param(1); // duomenų skaičius
    m = param(2); // parametrų skaičius
    ff = (rsqr*(n-m) )/((1-rsqr)*(m-1));
    if pada(n, m) <= ff then nai = 1, else nai = 0,
        end;
endfunction;

// vektorius A nurodo iš n po k. t.y. iš viso ilgio, po tiek, kiek yra vienetų.
// A = [0 0 1 1] ir pan

// funkcija gražina 0, jei eilutės nelygios ir 1, jei lygios
function [ga] = arlygios(A, t)
    ga = 1;
    d = size(A);

```

```

for j = 1:1:d(2) ,
    if ( A(t, j) <> A(t+1, j) ) then
        ga = 0
        break
    end;
end;
endfunction;

// šaliname pasikartojančias eilutes
function [B] = mazinti(A)
    dyd=size(A)
    kk = 1;
    for i = 1:1:(dyd(1)-1),
        if ( arlygios(A, i) == 1 ) then
            continue
        end;
        for j = 1:1:dyd(2),
            B(kk, j) = A(i, j)
        end;
        kk = kk + 1 // pastumiame B masyvo eilutę
    end;
//if ( arlygios(A, dyd(1)-1) == 0 ) then
    for j = 1:dyd(2), B(kk, j) = A(dyd(1), j)
    end;
//end;
endfunction;

// gautoje B matricoje yra tiek gauti kėlinių vektoriai, eilutėmis

// k - prieš tai buvusio stulpelio ilgis
// t = { 0 ; 1 } prieš tai buvusio stulpelio skaičiai
// d - braizomo stulpelio vardiklis
// d1 - koeficiento skaitiklis braizomame stulpelyje

function A = comb( k, t, d, d1)
    if d1 < 0 | d < 1 then
        A = [];
        return
    end;
    if t == 1 then
        A = [ [ ones((k*d1)/d, 1), comb((k*d1)/d, 1, d-1, d1-1)];[zeros((k*(d-d1))/d,
1), comb((k*(d-d1))/d, 0, d-1, d-d1-1) ] ]
    end; // if t 1 pabaiga
    if t == 0 then

```

```

    A = [ [ ones((k*(d-d1))/d, 1), comb( (k*(d-d1))/d , 1, d-1, d-d1-1)];
[ zeros((k*d1)/d, 1), comb((d1*k)/d, 0, d-1, d1-1) ] ]
end; // if t 0 pabaiga
endfunction;

// gražina koeficientų, su kuriais modelio Rsq didžiausias, numerius
// KfNrMas - masyvas, nurodantis, kurie koeficientai buvo parinkti didžiausio Rsq
modeliui
// Rsqur - gražinamas gauto modelio maksimalus Rsq dydis
// KfSk - funkcijai pateikiamas dydis, nurodantis, kiek koeficientų įtraukti į
modelį
// Tai yra, gaunamame rezultate pateiktus KfSk koeficientus,
// su kuriais Rsq didžiausias KfSk koeficientų modelyje
// XXX - X nepriklausomų kintamųjų(faktorių) matrica (n x m)
// YYY - Y priklausomo kintamojo matrica (n x 1)
// funkcija ymean(Y) gražina vektoriaus stulpelio "Y" vidurkį
// ssTr(Y, ymid) - pilnoji kvadratų arba regresijos modelio suma, ymid - vidurkis,
Y - vektorius
function [KfNrMas, Rsqur, ZbB, RsqrAdj, SE1, SR1, aaa, liekanE, SEk, a] =
KfRink(KfSk, XXX, YYY)
Ysize = size(YYY); //[m x t]
Xsize = size(XXX) // [m x n]
Rsqur = zeros(Ysize(2), 1); //[t x 1]
RsqrAdj = zeros(Ysize(2), 1) // [t x 1]
SE1 = zeros(Ysize(2), 1)
SR1 = zeros(Ysize(2), 1)
ZbB = zeros(Xsize(2), Ysize(2)); // [n x t]
KfNrMas = zeros(Xsize(2), Ysize(2))
zz = factorial(Xsize(2))/(factorial(Xsize(2)-KfSk)*factorial(KfSk))
TTT = comb( zz, 1, Xsize(2), KfSk)

Tsize = size(TTT)
aaa = []
a = 1;
SEk = []
for tt = 1:1:Tsize(1), // ciklas per visus galimus TTT variantus
Zx = zeros(Xsize(1), KfSk)
jj = 0;
for kkk = 1:1:Xsize(2), // ciklas per X matricos stulpelius ir TTT matricos
eilutes
KfNrMasD(kkk) = TTT(tt, kkk)
if( TTT(tt, kkk) == 1 ) then // jei tt-ame vektoriuje yra kkk-tas vienetas
jj = jj + 1

```



```

    for i = 1:1:Xsize(1), // ciklas per matricos X eilutes
        Zx(i, jj) = XXX(i, kkk); // [m x p]; p = KfSk
    end; // for i pabaiga
end; // if pabaiga
end; // for kkk pabaiga
ZZb = inv(Zx'*Zx)*Zx'*YYY; // [p x t] = [[p x m][m x p]] [p x m][m x t]
YYYstg = Zx * ZZb; // [m x p][p x t] ZZb seniau buvo 1 x t
[aaaa, SEkk] = Multikolinearus(Zx)
SEk = [SEk, SEkk]
aaa = [aaa, aaaa]
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
/////-- sia vieta isskiriu ja pritaikydamas papildomiems aktyvams --//
/////-- tai yra - didesnio (t) matavimo Y ir B masyvui -----//
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
    YYYaverage = ymean(YYY);
    liekanE = zeros(YYY)
    liekanE = liekanos(YYY, YYYstg)
    SSST = ssTR(YYY, YYYaverage); // YYYstg
    SSSE = sserr(YYY, YYYstg);
// aukščiau esantys dydžiai ir taip yra [m x t] formato
// dėl to jiems žemiau esantis 'for it' ciklas netaikomas
for it = 1:Ysize(2),
    // šis ciklas pereina per t aktyvų
    RRRsq(it) = 1 - SSSE(it)/SSST(it), // else RRRsq(it) = 1
    SSSR(it) = SSST(it) - SSSE(it)
    if ( RRRsq(it) > Rsqur(it) ) & ( nedidesni(aaa, tt, 4) == 1) then
        Rsqur(it) = RRRsq(it);
        RsqrAdj(it) = 1 - ((Ysize(1)-1)/(Ysize(1)-KfSk-1))*(1-Rsqur(it))
        SE1(it) = SSSE(it)
        SR1(it) = SSSR(it)
        purp = 1;
        a = tt;
        for iii = 1:Xsize(2), // nuo 1 iki n
            KfNrMas(iii, it) = KfNrMasD(iii),
            if( KfNrMas(iii, it) <> 0 ) then
                ZbB(iii, it) = ZZb(purp, it);
                purp = purp+1;
            else ZbB(iii, it) = 0,
            end; // if KfNrMas pabaiga
        end; // for iii pabaiga
    end; // if RRRsq pabaiga
clc()
end; // for it pabaiga

```

```

////////////////////////////////////
////////////////////////////////////
end; // tt pabaiga
endfunction;

function [liekanE] = liekanos(Y, Ystg)
    sizeY = size(Y);
    for i = 1:sizeY(1)
        liekanE(i) = Y(i)-Ystg(i);
    end;
endfunction;

// tikrinama, ar matricos X, k-tojo stulpelio skaičiai ne didesni už a
// jei nedidesni - tuomet b = 1, jei didesni, tuomet 0

function b = nedidesni(X, k, a)
    b = 1;
    Xsize = size(X)
    for i = 1:Xsize(1),
        if X(i, k) > a then, b = 0, return;
        end;
    end;
endfunction

// X - nepriklausomu duomenų matrica (stulpeliais),
// k - priklausomos reikšmės stulpelis
function [rsqk, rsqAd, SSEk] = FindRsqrSqadj(X, k)

    Xsize = size(X)
    Xk = zeros(Xsize(1))
    Xnew = zeros(Xsize(1), Xsize(2)-1)

// kopijuojame visus stulpelius iki k-tojo
for t = 1:(k-1)
    for c = 1:Xsize(1)
        Xnew(c, t) = X(c, t)
    end; // for c pabaiga
end; // for t pabaiga

// kopijuojame priklausomo kintamojo stulpelį
for c = 1:Xsize(1)
    Xk(c) = X(c, k)
end;

```

```

// kopijuojuame visus stulpelius uz k-tojo
for t = (k+1):Xsize(2)
    for c = 1:Xsize(1)
        Xnew(c, t-1) = X(c, t)
    end; // for c pabaiga
end; // for t pabaiga

if YraVienet(x) == 0 then // jei matrica neturi konstantos stulpelio
    Xnew = [ones(Xsize(1), 1), Xnew]; // del modelio su konstanta
end;

//if abs(det(Xnew'*Xnew)) < 0.01 then
// Xnew = zeros(Xnew)
// rsqk = 1;
// rsqkAd = 1;
// SSEk = 0;
// return;
//end;

Bstog = inv(Xnew'*Xnew)*Xnew'*Xk
Xstog = Xnew*Bstog
//SSEk = zeros(Xk)
SSEk = sserr(Xk, Xstog);
SSTk = ssTR(Xk, ymean(Xk))

if abs(SSTk) < 0.000001 then
    SSTk = SSEk
end;

rsqk = 1 - SSEk/SSTk;
rsqkAd = 1 - (1 - rsqk)*(Xsize(1)-1)/(Xsize(1) - (Xsize(2) - 1) - 1)
endfunction;

function taip = YraVienet(X)
    taip = 0;
    ssx = size(X);
    for i = 1:ssx(2)
        for j = 2:ssx(1)
            if abs(X(j, i) - X(j-1, i)) > 0.00001 then
                break;
            end;
        end;
    if j == ssx(1) then

```

```

        taip = 1;
        return;
    end;
end;
end; // for i pabaiga
endfunction;

// jei VIF > 4 - galima itarti multikolinearuma
function [h, SEk] = Multikolinearus(x)

    Xsize = size(x);
    h = zeros(Xsize(2))
    rsq = 0.0;
    rsqadj = 0.0;
    for i = 1:Xsize(2)

        // skaičiuojame VIF - dispersijos mazejimo daugikli (variance inflation factor)
        [rsq, rsqadj, g] = FindRsqrSqadj(x, i)
        SEk(i) = g;
        h(i) = 1/(1-rsqadj);
    end; // for i pabaiga
endfunction;

filena = directory + "/issirink.txt"; // vartotojo pasirinkimui
failov = directory + "/matrica.txt"; // matricos nuskaitymui
fileBnm = directory + "/Bmatrix.txt" // b koeficientų matricos
fileSS = directory + "/SeSrR2adj.txt" // SSE SSR ir pataisyti determinacijos koef
failas
fileSe = directory + "/liekanos.txt" // liekanų masyvas

function [bTest, SEk] = vykdyti()
XXsize = size(X)
YYsize = size(Y)
    Zb = zeros(XXsize(2), YYsize(2))
// Knm - Koeficientų numerių masyvas
Knm = zeros(XXsize(2), XXsize(2))
    fd = mopen(filena, 'w');
    fdd = mopen(failov, 'w');
    fb = mopen(fileBnm, 'w');
    fssr = mopen(fileSS, 'w');
    bTest = zeros(X);
    fprintf(fd, 'Nr. Rsq | b1, b2, b3, b4, b5, b6, b7 \n RsqAdj \n');

```

```

liekan = [];
baigti = 0;
for KiekKoef = 1:(XXsize(2)), [Knm, RRssqq, Zb, RsqAdj, Se, Sr, bTest, SeE, SEk,
bb] = KfRink(KiekKoef, X, Y),
// rašome į failą
liekan = [liekan, SeE];

mfprintf(fd, '%25i', KiekKoef);
mfprintf(fd, '\n');

for jj = 1:YYsize(2)
mfprintf(fd, '%i', KiekKoef)
mfprintf(fd, 'rsq/VIF | ');
mfprintf(fd, '%8.5f', RRssqq(jj));
// rašome SSE SSR ir R2adj reikšmes
mfprintf(fssr, '%15.12f ', RsqAdj(jj))
mfprintf(fssr, '%15.12f ', Se(jj))
mfprintf(fssr, '%15.12f ', Sr(jj))
mfprintf(fssr, '\n')
mfprintf(fd, ' ');

thm = 0;
for i = 1:XXsize(2),
if Knm(i, jj) > 0.5 then
thm = thm + 1;
if bb <> 0 then, mfprintf(fd, '%5.3f ', bTest(thm, bb));
else mfprintf(fd, ' bb=0'); end; // if bb pabaiga
else mfprintf(fd, ' 0 ');
end; // if Knm pabaiga
end;
mfprintf(fd, '\n SEE(k) ');
a = size(SEk);

if bb <> 0 then
for i = 1:a(1); //KiekKoef, //(XXsize(2)-1),
mfprintf(fd, '%5.3f\t ', SEk(i, bb));
end; // for i pabaiga
end; // if bb pabaiga
mfprintf(fd, '\n rsqadj/ArParinktas');

mfprintf(fd, ' %8.5f', RsqAdj(jj));
// spausdiname spausdinti b masyvus
// end; // for ti pabaiga

```

```

// b koeficientų spausdinimo pabaiga
for i = 1:XXsize(2),

    mfprintf(fb, '%18.15f ', Zb(i, jj)),

    mfprintf(fd, '%5.2f ', Knm(i, jj));
    mfprintf(fdd, '%18.15f ', Knm(i, jj));
    mfprintf(fdd, ' ');
end; // for i pabaiga
mfprintf(fd, '\n');
mfprintf(fdd, '\n');
mfprintf(fb, '\n')

end; // for jj pabaiga
mfprintf(fd, '\n');

if abs(RRssqq) < 0.0001 then
    baigti = baigti +1;
end;

if baigti > 1 then
    break;
end;

end; // for KiekKoef pabaiga
fprintfMat(fileSe, liekan, '%5.2f');

    mclose(fd);
    mclose(fdd);
    mclose(fb);
    mclose(fssr);

endfunction;
tic()
[gagaa, sek] = vykdyti();
toc()
//M = fscanfMat(failov)
fscanfMat(filena)
function [a] = kuris()
    a = input("bu?");
endfunction;

//gdt = kuris()

```

```
//kuris = int(read(%io(1),1,1, '(a)'));

YYsize = size(Y)
bubu = string(1);
for i=1:(YYsize(2)-1),
    bubu = strcat([bubu; "; "; string(1)]),
end;
Matrixx = fscanfMat(fileBnm);
messagebox("Programos darbas baigtas", "Informacija apie darbo pabaiga", "info",
["Gerai"]);
```

### Programos tekstas „koreliuotiems.sci“

```
answ = 1;
if (answ == 1) then
    printf('\n Pasirinkite direktorija su: \n matrica X (stulp. sk. nurodo
parametru sk.) [n x m]; \n Vektoriumi Y [n x t];\n Bei statistikos reiksmiu
failais (1proc 5proc ir/ar 10proc) ')

    directory = uigetdir('/home/', "pasirink kataloga")
    filename = directory + "/x.txt"
    X = fscanfMat(filename);

    filename = directory + "/y"+ string(1) + ".txt"
    Y = fscanfMat(filename);

// šie taikomi, jei norima X ir Y pasirinkti kitus
else
    printf('pasirinkite matrica X (stulp. sk. nurodo parametru sk.) [n x m]')
    X = fscanfMat(uigetfile());
    printf('pasirinkite vektorių stulpelį Y (eil. sk. nurodo duomenų sk.) (n x t)')
    Y = fscanfMat(uigetfile());

    directory = uigetdir()
    end

// --- AA - modelio išmatuotos reikšmės,
// --- BB - turėtos reikšmės
// funkcijoms paduodamas vektorius-stulpelis
function [yse] = sserr(AA, BB)
    tt = size(AA);
    yse = zeros(tt(2))
```

```

for i = 1:tt(2),
    ss = 0;
    for j = 1:tt(1) ,
        ss = ss + (AA(j, i) - BB(j, i))^2 ,
    end;
yse(i)=ss;
end;
endfunction;

// --- AA - Y teorinių arba praktinių reikšmių vektorius
// --- pilnoji kvadratų arba regresijos modelio suma
function [yse] = ssTR(AA, k)
    tt = size(AA);
    for i = 1:tt(2),
        ss = 0;
        for j = 1:tt(1) ,
            ss = ss + (AA(j, i) - k(i))^2 ,
        end;
        yse(i) = ss;
    end;
endfunction;

// -- skaičiuojamas vektoriaus AA vidurkis

function [ym] = ymean(AA)
    tt = size(AA);
    for i = 1:tt(2),
        yysum = 0;
        for j = 1:tt(1), yysum = yysum + AA(j, i);
        end;
        ym(i) = yysum/tt(1);
    end;
endfunction;

function [nai] = lyginti(failoVardas, rsqr, XX)
    pada = fscanfMat(failoVardas);
    param = size(XX);
    n = param(1); // duomenų skaičius
    m = param(2); // parametru skaičius
    ff = (rsqr*(n-m) )/((1-rsqr)*(m-1));
    if pada(n, m) <= ff then nai = 1, else nai = 0,
        end;
endfunction;

```



```

// vektorius A nurodo iš n po k. t.y. iš viso ilgio, po tiek, kiek yra vienetų.
//A = [0 0 1 1]

// funkcija gražina 0, jei eilutės nelygios ir 1, jei lygios
function [ga] = arlygios(A, t)
    ga = 1;
    d = size(A);
    for j = 1:1:d(2) ,
        if ( A(t, j) <> A(t+1, j) ) then
            ga = 0
            break
        end;
    end;
endfunction;

// šaliname pasikartojančias eilutes
function [B] = mazinti(A)
    dyd=size(A)
    kk = 1;
    for i = 1:1:(dyd(1)-1),
        if ( arlygios(A, i) == 1 ) then
            continue
        end;
        for j = 1:1:dyd(2),
            B(kk, j) = A(i, j)
        end;
        kk = kk + 1 // pastumiame B masyvo eilutę
    end;
//if ( arlygios(A, dyd(1)-1) == 0 ) then
    for j = 1:dyd(2), B(kk, j) = A(dyd(1), j)
    end;
//end;
endfunction;

// gautoje B matricoje yra tiek gauti kėlinių vektoriai, eilutėmis
// kk - kiek faktorių yra tarpusavyje gerai koreliuoti
function A = combi(k, t, d, d1, kk)

    A = [];
    kz = factorial(d)/(factorial(d-d1)*factorial(d1))
    B = comb(kz, t, d, d1)
    for i = 1:kk,

```

```

C = []
    for j = 1:(i-1),
        C = [C, zeros(kz, 1)]
    end;
C = [C, ones(kz, 1)]
    for j = (i+1):kk
        C = [C, zeros(kz, 1)]
    end;
A = [A; C, B]
end;
//C = zeros(kz, kk)
// A = [A; C, B]
endfunction;

// k - prieš tai buvusio stulpelio ilgis
// t = { 0 ; 1 } prieš tai buvusio stulpelio skaičiai
// d - braizomo stulpelio vardiklis
// d1 - koeficiento skaitiklis braizomame stulpelyje

function A = comb( k, t, d, d1)
    if d1 < 0 | d < 1 then
        A = [];
        return
    end;
    if t == 1 then
        A = [ [ ones((k*d1)/d, 1), comb((k*d1)/d, 1, d-1, d1-1)]; [zeros((k*(d-d1))/d,
1), comb((k*(d-d1))/d, 0, d-1, d-d1-1) ] ]
        end; // if t 1 pabaiga
    if t == 0 then
        A = [ [ ones((k*(d-d1))/d, 1), comb( (k*(d-d1))/d , 1, d-1, d-d1-1)];
[ zeros((k*d1)/d, 1), comb((d1*k)/d, 0, d-1, d1-1) ] ]
        end; // if t 0 pabaiga
endfunction;

// gražina koeficientų, su kuriais modelio Rsq didžiausias, numerius
// KfNrMas - masyvas, nurodantis, kurie koeficientai buvo parinkti didžiausio Rsq
modeliui
// Rsqur - gražinamas gauto modelio maksimalus Rsq dydis
// KfSk - funkcijai pateikiamas dydis, nurodantis, kiek koeficientų įtraukti į
modelį
// Tai yra, gaunamame rezultate pateiktus KfSk koeficientus,
// su kuriais Rsq didžiausias KfSk koeficientų modelyje

```

```

// XXX - X nepriklausomų kintamųjų(faktorių) matrica (n x m)
// YYY - Y priklausomo kintamojo matrica (n x 1)
// BBB - B faktorių koeficientų matrica (m x 1)
// funkcija ymean(Y) gražina vektoriaus stulpelio "Y" vidurkį
// ssTr(Y, ymid) - pilnoji kvadratų arba regresijos modelio suma, ymid - vidurkis,
Y - vektorius
// gh - parodo, kiek pirmų stulpelių stipriai koreliuoti tarpusavyje
function [KfNrMas, Rsqur, ZbB, RsqrAdj, SE1, SR1, aaa, liekanE, SEk, a] =
KfRink(KfSk, XXX, YYY, gh)
Ysize = size(YYY); //[m x t]
Xsize = size(XXX) // [m x n]
Rsqur = zeros(Ysize(2), 1); //[t x 1]
RsqrAdj = zeros(Ysize(2), 1) // [t x 1]
SE1 = zeros(Ysize(2), 1)
SR1 = zeros(Ysize(2), 1)
ZbB = zeros(Xsize(2), Ysize(2)); // [n x t]

KfNrMas = zeros(Xsize(2), Ysize(2))

zz = factorial(Xsize(2))/(factorial(Xsize(2)-KfSk)*factorial(KfSk))
//TTT = comb( zz, 1, Xsize(2), KfSk)
TTT = combi( zz, 1, Xsize(2)-gh, KfSk, gh)

Tsize = size(TTT)
aaa = []
a = 1;
SEk = []
for tt = 1:1:Tsize(1), // ciklas per visus galimus TTT variantus
Zx = zeros(Xsize(1), KfSk)
jj = 0;
for kkk = 1:1:Xsize(2), // ciklas per X matricos stulpelius ir TTT matricos
eilutes
KfNrMasD(kkk) = TTT(tt, kkk)
if( TTT(tt, kkk) == 1 ) then // jei tt-ame vektoriuje yra kkk-tas vienetas
jj = jj + 1
for i = 1:1:Xsize(1), // ciklas per matricos X eilutes
Zx(i, jj) = XXX(i, kkk); // [m x p]; p = KfSk
end; // for i pabaiga
end;// if pabaiga
end; // for kkk pabaiga

ZZb = inv(Zx'*Zx)*Zx'*YYY; // [p x t] = [[p x m][m x p]] [p x m][m x t]

```



```

function [liekanE] = liekanos(Y, Ystg)
    sizeY = size(Y);
    for i = 1:sizeY(1)
        liekanE(i) = Y(i)-Ystg(i);
    end;

endfunction;

// tikrinama, ar matricos X, k-tojo stulpelio skaičiai ne didesni už a
// jei nedidesni - tuomet b = 1, jei didesni, tuomet 0

function b = nedidesni(X, k, a)
    b = 1;
    Xsize = size(X)
    for i = 1:Xsize(1),
        if X(i, k) > a then, b = 0, return;
        end;
    end;
endfunction

// X - nepriklausomu duomenų matrica (stulpeliais),
// k - priklausomos reikšmės stulpelis
function [rsqk, rsqkAd, SSEk] = FindRsqrSqadj(X, k)

    Xsize = size(X)
    Xk = zeros(Xsize(1))
    Xnew = zeros(Xsize(1), Xsize(2)-1)

// kopijuojame visus stulpelius iki k-tojo
for t = 1:(k-1)
    for c = 1:Xsize(1)
        Xnew(c, t) = X(c, t)
    end; // for c pabaiga
end; // for t pabaiga

// kopijuojame priklausomo kintamojo stulpelį
for c = 1:Xsize(1)
    Xk(c) = X(c, k)
end;

// kopijuojame visus stulpelius už k-tojo

```

```

for t = (k+1):Xsize(2)
    for c = 1:Xsize(1)
        Xnew(c, t-1) = X(c, t)
    end; // for c pabaiga
end; // for t pabaiga

if YraVienet(x) == 0 then // jei matrica neturi konstantos stulpelio
    Xnew = [ones(Xsize(1), 1), Xnew]; // kodas: peleda (: jei rimtai, tai del
modelio su konstanta
end;

Bstog = inv(Xnew'*Xnew)*Xnew'*Xk
Xstog = Xnew*Bstog
//SSEk = zeros(Xk)
SSEk = sserr(Xk, Xstog);
SSTk = ssTR(Xk, ymean(Xk))

if abs(SSTk) < 0.000001 then
    SSTk = SSEk
end;

rsqk = 1 - SSEk/SSTk;
rsqkAd = 1 - ( 1 - rsqk )*(Xsize(1)-1)/(Xsize(1) - (Xsize(2) - 1) - 1)
endfunction;

function taip = YraVienet(X)
    taip = 0;
    ssx = size(X);
    for i = 1:ssx(2)
        for j = 2:ssx(1)
            if abs(X(j, i) - X(j-1, i)) > 0.00001 then
                break;
            end;
            if j == ssx(1) then
                taip = 1;
                return;
            end;
        end;
    end;
end; // for i pabaiga
endfunction;

// jei VIF > 4- galima itarti multikolinearuma
function [h, SEk] = Multikolinearus(x)

```

```

Xsize = size(x);
h = zeros(Xsize(2))
    rsq = 0.0;
    rsqadj = 0.0;
for i = 1:Xsize(2)
    // skaičiuojame VIF - dispersijos mazejimo daugikli (variance inflation factor)
    [rsq, rsqadj, g] = FindRsqrSqadj(x, i)
    SEk(i) = g;
    h(i) = 1/(1-rsqadj);
end; // for i pabaiga
endfunction;

filena = directory + "/issirink.txt"; // vartotojo pasirinkimui
failov = directory + "/matrica.txt"; // matricos nuskaitymui
fileBnm = directory + "/Bmatrix.txt" // b koeficientų matricos
fileSS = directory + "/SeSrR2adj.txt" // SSE SSR ir pataisyti determinacijos koef
failas
fileSe = directory + "/liekanos.txt" // liekanų masyvas

bubu = string(1)
[ok, ghh]=getvalue("Faktoriu skaičiaus pasirinkimas",["kiek pirmų faktorių yra
stipriai koreliuoti tarpusavyje?"],list("vec",1),[bubu])

function [bTest, SEk] = vykdyti()
XXsize = size(X)
YYsize = size(Y)
    Zb = zeros(XXsize(2), YYsize(2))
// Knm - Koeficientų numerių masyvas
Knm = zeros(XXsize(2), XXsize(2))
    fd = mopen(filena, 'w');
    fdd = mopen(failov, 'w');
    fb = mopen(fileBnm, 'w');
    fssr = mopen(fileSS, 'w');
// fse = mopen(fileSe, 'w')
    bTest = zeros(X);
baigti = 0;
    fprintf(fd, 'Nr. Rsq | b1, b2, b3, b4, b5, b6, b7 \n RsqAdj \
n');
for KiekKoeff = 1:(XXsize(2)-ghh), [Knm, RRssqq, Zb, RsqAdj, Se, Sr, bTest, SeE,
SEk, bb] = KfRink(KiekKoeff, X, Y, ghh),
// rašome į faila

```

```

clc();
fprintfMat(fileSe, SeE, '%5.2f');

mfprintf(fd, '%25i', KiekKoef);
mfprintf(fd, '\n');

for jj = 1:YYsize(2)
mfprintf(fd, '%i', KiekKoef)
    mfprintf(fd, 'rsq/VIF | ');
mfprintf(fd, '%8.5f', RRssqq(jj));
    // rašome SSE SSR ir R2adj reikšmes
mfprintf(fssr, '%15.12f ', RsqAdj(jj))
mfprintf(fssr, '%15.12f ', Se(jj))
mfprintf(fssr, '%15.12f ', Sr(jj))
mfprintf(fssr, '\n')
mfprintf(fd, ' ');

thm = 0;
for i = 1:XXsize(2),
    if Knm(i, jj) > 0.5 then
        thm = thm + 1;
        if bb <> 0 then, mfprintf(fd, '%5.3f ', bTest(thm, bb));
            else mfprintf(fd, ' bb=0'); end; // if bb pabaiga
        else mfprintf(fd, ' 0 ');
end; // if Knm pabaiga
end;

mfprintf(fd, '\n SEE(k) ');
a = size(SEk);

if bb <> 0 then
    for i = 1:a(1); //KiekKoef, // (XXsize(2)-1),
        mfprintf(fd, '%5.3f\t', SEk(i, bb));
    end; // for i pabaiga
end; // if bb pabaiga
mfprintf(fd, '\n rsqadj/ArParinktas');

mfprintf(fd, ' %8.5f', RsqAdj(jj));

for i = 1:XXsize(2),

mfprintf(fb, '%18.15f ', Zb(i, jj)),

```



```

    mfprintf(fd, '%5.2f ', Knm(i, jj));
    mfprintf(fdd, '%18.15f', Knm(i, jj));
    mfprintf(fdd, ' ');
end; // for i pabaiga
mfprintf(fd, '\n');
mfprintf(fdd, '\n');
mfprintf(fb, '\n')

end; // for jj pabaiga
mfprintf(fd, '\n');

if abs(RRssqq) < 0.0001 then
    baigti = baigti +1;
end;

if baigti > 1 then
    break;
end;

end; // for KiekKoef pabaiga
mclose(fd);
mclose(fdd);
mclose(fb);
mclose(fssr);
// čia yra baigti skaičiuoti geriausi koeficientai.
endfunction;
tic()
[gagaa, sek] = vykdyti();
toc()
fscanfMat(filena)
function [a] = kuris()
    a = input("bu?");
endfunction;
YYsize = size(Y)
bubu = string(1);
for i=1:(YYsize(2)-1),
    bubu = strcat([bubu; "; "; string(1)]),
end;
Matrixx = fscanfMat(fileBnm);
messagebox("Programos darbas baigas.", "Informacija", "question", ["Taip"],
"modal");

```

## 5 PRIEDAS. ALGORITMŲ ILIUSTRACIJOS

35 pav. Algoritmo dalis

