



**KAUNO TECHNOLOGIJOS UNIVERSITETAS
FUNDAMENTALIŲJŲ MOKSLŲ FAKULTETAS
TAIKOMOSIOS MATEMATIKOS KATEDRA**

Janina Jablonskytė

**MIKROSKOPINIS EISMO SRAUTO
MODELIAVIMAS**

Magistro darbas

Vadovai
prof. habil. dr. P. Ilgakojis,
prof.dr. A. Aksomaitis

KAUNAS, 2006



**KAUNO TECHNOLOGIJOS UNIVERSITETAS
FUNDAMENTALIŲJŲ MOKSLŲ FAKULTETAS
TAIKOMOSIOS MATEMATIKOS KATEDRA**

**TVIRTINU
Katedros vedėjas
prof. dr. J.Rimas**

2006-06-06

Mikroskopinis eismo srauto modeliavimas

Taikomosios matematikos magistro baigiamasis darbas

Kalbos konsultantas

dr. J. Džežulskienė

2006-05-30

Vadovai

prof. habil. dr. P. Ilgakojis,

prof. dr. A. Aksomaitis

2006-06-03

Recenzentas Atliko

doc. dr. D. Markšaitis

2006-06-01

FMMM-4 gr. stud.

J. Jablonskytė

2006-05-25

KAUNAS, 2006

KVALIFIKINĖ KOMISIJA

Pirmininkas: Leonas Saulis, profesorius (VGTU)

Sekretorius: Eimutis Valakevičius, docentas (KTU)

Nariai: Algimantas Jonas Aksomaitis, profesorius (KTU)

Vytautas Janilionis, docentas (KTU)

Vidmantas Povilas Pekarskas, profesorius (KTU)

Rimantas Rudzkis, profesorius (MII)

Zenonas Navickas, profesorius (KTU)

Arūnas Barauskas, UAB „Elsis“ generalinio direkторiaus pavaduotojas

Jablonskyte J. Microscopic traffic flow modelling: Master's work in applied mathematics / supervisors: dr. prof. P. Ilgakojis and dr. prof. A. Aksomaitis; Department of Applied mathematics, Faculty of Fundamental Sciences, Kaunas University of Technology. –Kaunas, 2006. –83p.

SUMMARY

Everyone has had the experience of sitting in a traffic jam, or of seeing cars bunch up on a road for no apparent good reason. Nowadays the quantity of vehicles in the Lithuanian cities are growing very fast. The necessity of circumstantial territory analysis emerged for increasing Transportation Systems Control demand. Microscopic traffic flow models are important for analyzing individual crossroads and assessing interaction between some vehicles.

In this paper there are analyzed microscopic traffic flow model. In this paper there answered what effect is produced by small differences in the velocities of the cars. And we have that microscopic traffic flow is in stability when $kT < 0.5$ and not in stability when $kT > 0.5$. Its very important for modeling microscopic traffic flow model.

In this paper there are shown that microscopic traffic flow in K. Mindaugo – Birštono streets has Puasson distribution. There are made microscopic traffic flow simulation model of K. Mindaugo – Birštono streets crossroad by Arena 3.0 program and performed regression analysis for prognosticating microscopic traffic flow queues.

TURINYS

PAVEIKSLŲ SĀRAŠAS	6
LENTELIŲ SĀRAŠAS	7
IVADAS	8
1. BENDROJI DALIS	9
 1.1. MIKROSKOPINIS EISMAS	9
1.1.1. GM MODELIS	9
1.1.2. NETSIM MODELIS	12
1.1.3. FRESIM IR INTRAS MODELIAI.....	13
1.1.4. INTELSIM MODELIS	14
 1.2. EISMO SRAUTO STABILUMAS	15
1.2.1. LOKALINIS STABILUMAS	15
1.2.2. ASIMTOTINIS STABILUMAS	16
 1.3. MASINIO APTARNAVIMO SISTEMOS SĄVOKA	17
 1.4. PAPRASČIAUSIAS SRAUTAS IR JO SKIRSTINYS	19
 1.5. APTARNAVIMO LAIKAS	21
 1.6. REGRESINĖ ANALIZĖ	22
1.6.1. TIESINĖS REGRESIJOS MODELIS	23
 1.7. PROGRAMINĖS ĮRANGOS PASIRINKIMO PAGRINDIMAS	28
2. TIRIAMOJI DALIS IR REZULTATAI	29
 2.1. MIKROSKOPINIO EISMO SRAUTO STABILUMO ANALIZĖ	30
 2.2. MIKROSKOPINIO EISMO SRAUTO SKIRSTINIO NUSTATYMAS	35
 2.3. MIKROSKOPINIO EISMO SRAUTO IMITACINIS MODELIAVIMAS	39
 2.4. REGRESIJOS MODELIO SUDARYMAS	41
3. PROGRAMINĖ RELIZACIJA IR INSTRUKCIJA VARTOTOJUI	49
IŠVADOS	54
REKOMENDACIJOS	55
LITERATŪRA	56
1 PRIEDAS. DUOMENYS	58
2 PRIEDAS. GAUTI DUOMENYS IR REZULTATAI	59
3 PRIEDAS. MIKROSKOPINIO EISMO SRAUTO K. MINDAUGO PR. – BIRŠTONO G- VĖS SANKRYŽOS MODELIO REALIZACIJA ARENA 3.0 PROGRAMINIU PAKETU	76
4 PRIEDAS. PROGRAMŲ TEKSTAI	77
5 PRIEDAS. KONFERENCIJOS PRANEŠIMO MEDŽIAGA	81

PAVEIKSLŲ SĄRAŠAS

1.	NETSIM tolimesnio automobilio iliustracija (1.1.2.1).....	12
2.	Eismo srautų pasiskirstymas Kauno miesto centre (2.1).....	29
3.	Tyrimo schema (2.2).....	29
4.	Sistemos stabilumas ir nestabilumas (2.1.1).....	32
5.	Modelio struktūra Simulink aplinkoje (2.1.2).....	32
6.	Automobilių greičiai laiko momentu t, eismo srautas stabilus (2.1.3).....	33
7.	Automobilių pozicijos laiko momentu t, eismo srautas stabilus(2.1.4).....	33
8.	Automobilių greičiai laiko momentu t, eismo srautas nestabilus (2.1.5).....	34
9.	Stabilus eismo srautas ratu (2.1.6).....	34
10.	Nestabilus eismo srautas ratu (2.1.7).....	35
11.	Puasono skirstinys, D03 eismo juosta, $\lambda t = 5.3333$; $\lambda = 1.06671$ (2.2.1).....	37
12.	Puasono skirstinys, D09 eismo juosta, $\lambda t = 7.9167$; $\lambda = 1.5833$ (2.2.2).....	38
13.	Trišalė K. Mindaugo pr. – Birštono g-vės sankryža (2.3.1).....	39
14.	Galimos transporto priemonių važiavimo kryptys (2.3.2).....	40
15.	Paklaidų e_i Normalusis skirstinys (2.4.1).....	43
16.	D_01 ir \hat{D}_01 įverčio grafikas (2.4.2).....	44
17.	Standartinės paklaidos ir \hat{D}_01 grafikas (2.4.3).....	44
18.	Standartinės paklaidos ir liamda grafikas (2.4.4).....	45
19.	Standartinės paklaidos ir miu grafikas (2.4.5).....	45
20.	Standartinės paklaidos ir šviesoforo laiko grafikas (2.4.6).....	46
21.	Eilių ilgiai D01 eismo juostoje (2.4.7).....	48
22.	Eilių ilgiai D06 eismo juostoje (2.4.8).....	48
23.	Eilių ilgiai D09 eismo juostoje (2.4.9).....	48
24.	Trišalės K. Mindaugo pr. –Birštono g-vės sankryžos zonas (3.1).....	50
25.	Mašinos važiavimo iš eilės įsijungus/degant žaliui šviesoforo signalui algoritmas (3.2)	51
26.	Mašinos važiavimo iki galinės maršruto stotelės algoritmas (3.3).....	51
27.	Mašinos važiavimo algoritmas atlaisvinus pravažiuojamas zonas (3.4).....	52

LENTELIŲ SĄRAŠAS

1.	Atsitiktinio dydžio X reikšmės ir jų dažniai, D03 eismo juosta (2.2.1).....	36
2.	Sugrupuoti duomenys, D03 eismo juosta (2.2.2).....	36
3.	Sugrupuoti duomenys, D09 eismo juosta (2.2.3).....	38
4.	Reikšmingi kintamieji, D01 eilė (2.4.1).....	41
5.	Patikimumo analizė (2.4.2).....	42
6.	Paklaidų tikrinimas (2.4.3).....	43
7.	Tiesinės regresijos modeliai (2.4.4).....	46

IVADAS

Transporto poreikis nuolat auga. Keleivinio transporto srityje tai lemia neįtikėtinai didelė automobilių paklausa. Per praėjusius 30 metų automobilių skaičius išaugo trigubai ES valstybėse. Kiekvienais metais automobilių padidėdavo 3 mln. Daugelyje ES valstybių automobilių skaičius pradeda stabilizuotis [16]. Didėja ir transporto priemonių grūstys gatvėse, sankryžų apkrovimas, daugėja automobilių spūsčių, be reikalo deginami degalai, o kartu didėja oro užterštumas. Šios problemos sprendžiamos įvairiais būdais: platinami keliai, didinamas eilių skaičius, branginami degalai, tobulinamos visuomeninio transporto sistemos bei kuriamos intelektualios transporto valdymo sistemos.

Darbo tikslas: sudaryti matematinį mikroskopinį eismo srauto modelį; nustatyti mikroskopinio eismo srauto stabilumo ribas; išnagrinėti mikroskopinio eismo srauto charakteristikas, pasiskirstymo dėsnį, parametrų įtaką sąveikai; sukurti imitacinių mikroskopinio eismo srauto modelių sankryžos darbui modeliui.

Šiame darbe nagrinėjamas mikroskopinio eismo srauto stabilumo aktualumas mikroskopinio eismo srauto modeliavimui. Nagrinėjame, kas atsitinka esant mažiems greičių skirtumams, nustatome eismo srauto stabilumo ribas, kurioms esant mikroskopinio eismo srauto modeliai būtų teisingi. Nustatomas mikroskopinio eismo srauto pasiskirstymo dėsnis. Sukuriamas imitacinis trišalės sankryžos modelis. Nustatome, ar yra tiesinė priklausomybė tarp eilės ilgio, aptarnavimo laiko, srauto intensyvumo, vidutinio aptarnavimo dažnio, transporto priemonės greičio, jei yra sudarome tiesinės priklausomybės lygtis.

Tema „Mikroskopinio eismo srauto stabilumo analizė” parašytas straipsnis ir skaitytas pranešimas VI –ojoje studentų konferencijoje „TAIKOMOJI MATEMATIKA” 2006 m. gegužės 6 d.

Matematiniai tyrimai ir modeliavimas atlikti naudojant Matlab 7.0, Arena 3.0 ir SAS programinius paketus.

1. BENDROJI DALIS

1.1. MIKROSKOPINIS EISMAS

Mikroskopinis eismas – tai transporto priemonių judėjimas kelio segmentuose, santykio transporto priemonė – vairuotojas, transporto priemonė – transporto priemonė, transporto priemonė – aplinka prasme. Transporto priemonės vairuotojas turi polinkį sumažinti greitį, jei jis važiuoja greičiau už priekyje judančią automobilį, arba didinti greitį, jei jis važiuoja lėčiau negu priekyje važiuojanti mašina.

Tolimesnio automobilio elgsena kelyje yra pagrindinis mikroskopinis eismo srauto modelis. Modeliu aprašomas vienas paskui kitą važiuojančių automobilių procesas. Teigama, kad atstumai tarp automobilių yra koreliuoti, ir tai duoda pagrindą nagrinėti transporto priemonių judėjimo charakteristiką. Kiekvienas iš paskos važiuojantiesių vairuotojas turi sekti situaciją kelyje priklausomai nuo kelio geometrinės padėties, kelio ženklinimo ir priekyje važiuojančios transporto priemonės judėjimo (J. Gartner, 1992). Tolesnio automobilio modeliai: GM, NETSIM, FRESIM, INTRAS, CARSIM ir INTELSIM, aprašo mikroskopinius eismo srautus.

1.1.1. GM MODELIS

Tolesnio automobilio teorija pagrįsta tam tikro skaičiaus eismo reguliavimo taisyklių. GM modelis apibrėžtas 1.1.1.1 lygtimi pažymi, kad vairuotojo reakcija į pasikeitusias eismo sąlygas yra funkcija, priklausanti nuo transporto priemonės vairuotojo jautrumo į supančius veiksnius ir jo įžvalgumas į situacijos pakitimus.

$$\text{Reakcija} = F(\text{jautumas}, \text{stimulas}) . \quad (1.1.1.1)$$

Vairuotojas reaguoja į priekyje važiuojančios transporto priemonės greičio padidėjimą ar sumažėjimą. Tuo atveju, greičio stimulus sukelia iš paskos važiuojančio vairuotojo reakciją, antra vertus, t.y. reakcija į atitinkamai pasikeitusį greitį, atstumą tarp dviejų vieną paskui kitą važiuojančių mašinų. Jautumas yra laikomas daline vairuotojo reakciją į pakitusią aplinką bei kitus veiksnius, kaip reakcijos laikas ir mechaninis uždelsimas dėl įvairių mašinos komponenčių reagavimo.

Eismo srauto modelis buvo sukurtas ir išaiškintas Pipes. Sukurtame modelyje susiejo automobilio greitį su mažiausiu atstumu tarp automobilių (mažiausiu laiko tarpu tarp vienas po kito važiuojančių automobilių), motyvuojant, kad vairuotojai paprastai laikosi saugaus atstumo. Mažiausias saugus atstumas tarp vienas po kito važiuojančių automobilių yra funkcija, priklausanti nuo paskui važiuojančio automobilio greičio ir priekyje važiuojančio automobilio ilgio, kaip nurodyta lygtje 1.1.1.2. Skaičius 0.44835 yra pasikeitimo faktorius keičiant km/h į m/s. 1.1.1.2 lygtis apibrėžia, kad mažiausias saugiausias atstumas tarp dviejų važiuojančių mašinų atitinka vienos mažiausios mašinos ilgį ir tai padidėja per vieną mašinos ilgį kas 16.09 kilometrų didinant iš paskos važiuojančio automobilio greitį [8].

$$d_m = l_n \left(\frac{x_{n+1}'}{0.44835 \cdot 16.09} \right) + l_n , \quad (1.1.1.2)$$

čia: l_n – priekinio automobilio ilgis, x_{n+1}' – tolimesnio automobilio greitis.

Vėliau Forbes pagerino Pipes saugaus atstumo modelį, įtraukdamas vairuotojo reakcijos laiką, kad suvoktų greičio sumažinimo reikalingumą ir panaudotų stabdžius, 1.1.1.3 lygtis.

$$h_m = \frac{l_n}{x_{n+1}'} + \Delta t , \quad (1.1.1.3)$$

čia: Δt – vairuotojo reakcijos laikas.

GM modelis plačiai taikomas nagrinėjant mikroskopinius tolimesniojo automobilio modelius [10] Atliekant mokslinius bandymus buvo suformuotas pirmasis modelis:

$$x_{n+1}''(t + \Delta t) = k \left[x_n'(t) - x_{n+1}'(t) \right] , \quad (1.1.1.4)$$

čia: k – jautrumo konstanta (1/s), $x_n'(t)$ – n -osios mašinos greitis laiko momentu t (m/s), $x_{n+1}'(t)$ – $n+1$ -osios mašinos greitis laiko momentu t (m/s), $x_{n+1}''(t)$ – $n+1$ -osios mašinos pagreitis laiko momentu t (m/s^2).

Transporto priemonės važiuoja viena paskui kitą besilaikydamos mažiausio saugaus atstumo. Tuo tikslu, 1.1.1.4 lygtis buvo modifikuota [11], motyvuojant, kad tolimesnio automobilio pagreitis priklauso ir nuo transporto priemonės masės:

$$M \cdot \ddot{x}_{n+1}(t + \Delta t) = k \left[\dot{x}_n(t) - \dot{x}_{n+1}(t) \right].$$

Vėliau pirminis modelis, aprašytas 1.1.1.4 lygtimi, buvo patobulintas. Naujame modelyje jautrumo konstanta yra padalinta iš atstumo tarp n -osios ir $n+1$ -osios mašinų, darant prielaidą, kad tolimesnio automobilio vairuotojo reakcija yra atvirkščiai proporcinga atstumui tarp jo vairuojamo automobilio ir automobilio važiuojančio priekyje. Toks pokytis sudarė sąlygas jautrumo konstantą labiau taikyti praktinio pobūdžio uždaviniuose [2]. 1.1.1.4 lygtje jautrumo konstanta yra išreikšta (1/s), tuo tarpu 1.1.1.5 lygtje - greičio matavimo vienetu, kuri yra labiau susieta su modelio kintamaisiais.

$$\ddot{x}_{n+1}(t + \Delta t) = \frac{k}{x_n(t) - x_{n+1}(t)} \left[\dot{x}_n(t) - \dot{x}_{n+1}(t) \right], \quad (1.1.1.5)$$

čia: k – jautrumo konstanta, $x_n(t)$ – n -osios mašinos pozicija laiko momentu t .

Modelis buvo pagerintas. 1.1.1.6 lygtimi apibrėžtame modelyje, tariama, kad tolimesnio automobilio vairuotojas santykinių jautresnių priekyje važiuojančio automobilio greičiui, dėl jo vairuojamo automobilio greičio, kai jis padidina ar sumažina judėjimo pagreitį. Atlikus tokius pokyčius, jautrumo parametras tapo nedimensiniu dydžiu [6,10].

$$\ddot{x}_{n+1}(t + \Delta t) = \frac{k \left[\dot{x}_{n+1}(t + \Delta t) \right]}{x_n(t) - x_{n+1}(t)} \left[\dot{x}_n(t) - \dot{x}_{n+1}(t) \right] \quad (1.1.1.6)$$

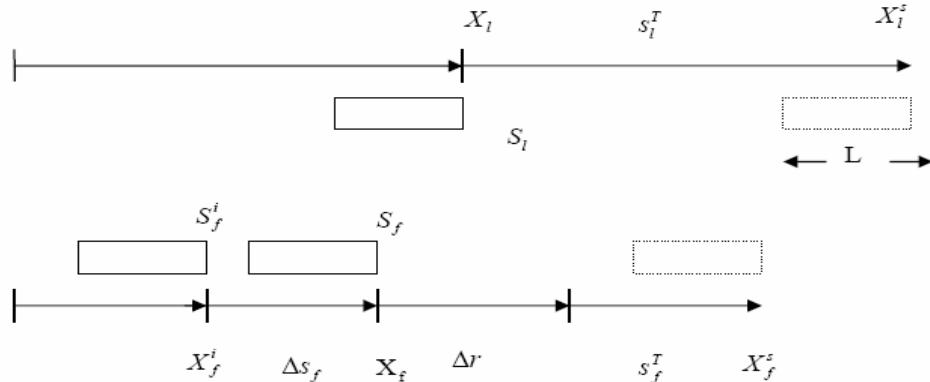
Galiausiai buvo suformuota galutinė modelio išraiška:

$$\ddot{x}_{n+1}(t + \Delta t) = \frac{k_{l,m} \left[\dot{x}_{n+1}(t + \Delta t) \right]^m}{\left[x_n(t) - x_{n+1}(t) \right]^l} \left[\dot{x}_n(t) - \dot{x}_{n+1}(t) \right] \quad (1.1.1.7)$$

čia: $x_{n+1}^v(t + \Delta t)$ – $n+1$ -ojo automobilio pagreitis laiko momentu $t + \Delta t$, $k_{l,m}$ – jautrumo parametras, Δt – $n+1$ -ojo automobilio vairuotojo reakcijos laikas, $x_n^v(t)$ – n -jo automobilio greitis laiko momentu t , $x_{n+1}^v(t)$ – $n+1$ -ojo automobilio greitis laiko momentu t , $x_n^v(t) - x_{n+1}^v(t)$ – reliatyvus greitis tarp priekyje važiuojančio ir iš paskos važiuojančio automobilių laiko momentu t , $x_n^v(t) - x_{n+1}^v(t)$ – atstumas tarp priekyje važiuojančio ir iš paskos važiuojančio automobilių laiko momentu t , l, m – atstumo ir greičio laipsnio rodikliai [8,15]

1.1.2. NETSIM MODELIS

NETSIM yra miesto gatvių tinklo modelis ir pagrindinis dėmesys yra skiriamas vairuotojo reakcijos laiko algoritmui. Modelis apibūdinamas kaip staigios reakcijos ir saugaus atstumo laikymosi išvengiant autoavarijų, susidūrimų, kai priekyje važiuojanties vairuotojas staigiai stabdo [4, 5]. 1.1.2.1 pav. pavaizduotas tolimesnio automobilio modelio iliustracija.



1.1.2.1 pav. NETSIM tolimesniojo automobilio modelio iliustracija

Čia: S_f^i – tolimesniojo automobilio greitis prasidėjus laiko intervalui T , S_l, S_f – atitinkamai priekyje važiuojančio ir paskui važiuojančio automobilių greičiai pasibaigus laiko intervalui T , X_l – priekyje važiuojančio automobilio pozicija pasibaigus laiko intervalui T , X_l^s, X_f^s – sustojimo vieta priekyje ir iš paskos važiuojančių automobilių, pasibaigus laiko intervalui T , X_f^i, X_f – atitinkamai tolimesniojo automobilio pozicijos prasidėjus ir pasibaigus laiko intervalui T , s_l^T, s_f^T – atitinkamai priekyje ir iš paskos važiuojančių automobilių stabdymo kelias, Δs_f – tolimesniojo automobilio nuvažiuotas atstumas per laiko intervalą T , Δr – tolimesniojo

automobilio nuvažiuotas atstumas per reakcijos laiką c , L – priekyje važiuojančio automobilio ilgis, T – laiko intervalas, 1s.

Matematinė lygtis:

$$a_f = \frac{F_1}{F_2} \quad (1.1.2.1)$$

$$F_1 = 2 \cdot [s - S_f^i \cdot (1 + c)] \cdot df + \frac{S_l^2 \cdot df}{dl} - (S_f^i)^2, \quad (1.1.2.2)$$

$$F_2 = df \cdot (2c + 1) + 2 \cdot S_f^i, \quad (1.1.2.3)$$

$$s = X_l - X_f^i - L, \quad (1.1.2.4)$$

čia: a_f – tolimesniojo automobilio pagreitis, dl, df – lėtėjimo koeficientas priekyje ir iš paskos važiuojančių automobilių atitinkamai, c – reakcijos laikas ,1s.

1.1.3. FRESIM IR INTRAS MODELIAI

FRESIM yra mikroskopinis eismo srauto modelis, INTRAS – praplėstas FRESIM modelis. Tariame, kad tolimesnis automobilio vairuotojas stengiasi išlaikyti atstumą iki priešakyje važiuojančios transporto priemonės:

$$h(t) = L + k \cdot S_f + 10 + b \cdot k \cdot (S_l - S_f)^2, \quad (1.1.3.1)$$

čia: L – priekyje važiuojančio automobilio ilgis, k – vairuotojo jautrumo faktorius, S_l, S_f – atitinkamai priekyje iš paskos važiuojančių transporto priemonių greičiai laiko intervalo gale, T [3].

Sutrikimų konstanta, b, apibrėžiama:

$$b = \begin{cases} 0.1, & S_l - S_f \leq 10, \\ 0, & S_l - S_f > 10. \end{cases} \quad (1.1.3.2)$$

Atlikus pertvarkymus, tolimesniojo automobilio lygtis užrašoma taip:

$$a_f = \frac{2 \cdot (X_l - X_f^i - L - 10 - S_f^i \cdot (k + T) - b \cdot k \cdot (S_l - S_f^i)^2)}{T^2 + 2 \cdot k \cdot T}, \quad (1.1.3.3)$$

čia: X_l – priekyje važiuojančio automobilio pozicija laiko intervalo gale, T , X_f^i – tolimesniojo automobilio pozicija laiko intervalo, T , pradžioje, S_f^i – tolimesniojo automobilio greitis laiko intervalo, T , pradžioje, S_l – priekyje važiuojančio automobilio greitis laiko intervalo gale, T , T – laiko intervalas.

Priekyje važiuojančio automobilio greitis ir pozicija pasikeičia po vairuotojo reakcijos laiko, c :

$$S_l = S_f^i + a_f \cdot (T - c), \quad (1.1.3.4)$$

$$X_l = X_f^i + S_f^i \cdot T + \frac{a_f \cdot (T - c)^2}{2}. \quad (1.1.3.5)$$

1.1.4. INTELSIM MODELIS

INTELSIM modeliu apibrėžiamas tolimesniojo automobilio pagreičio tiesinis kintamumas[7]:

$$a_f = \frac{S_f(t + \Delta T) - S_f(t) - 0.5 \cdot S_f'(t)(\Delta T)^2}{\Delta T}, \quad (1.1.4.1)$$

čia: $a_f(t)$ – tolimesnio automobilio pagreitis laiko momentu t , $S_f(t + \Delta T)$, $S_f(t)$ – tolimesnio automobilio greitis laiko momentais $t + \Delta T$ ir t , atitinkamai, $S_f'(t)$ – tolimesnio automobilio tiesinio pagreičio nuožulnumas.

1.2. EISMO SRAUTO STABILUMAS

Susidarius eismo srautui, visos transporto priemonės važiuoja tuo pačiu greičiu. Laikinas greičio sutrikdymas gali išsaukti įvairiausius eismo srauto sutrikimus kelyje.

Svarbu išnagrinėti eismo srauto stabilumą, kad būtų galima sudaryti teisingus matematinius modelius. Sistemos stabilumas priklauso nuo dviejų parametru: k - jautrumo parametras ir T - vairuotojo reakcijos laikas į priekyje važiuojančios transporto priemonės greičio pokyčius. Galima išskirti dvi stabilumo grupes: lokalinius stabilumus ir asimptotinius stabilumus [5, 6, 15].

1.2.1. LOKALINIS STABILUMAS

Lokalinis stabilumas – tai stabilumas tarp dviejų vienas paskui kitą važiuojančių transporto priemonių. Priekyje važiuojančios transporto priemonės pastovaus greičio svyravimas atitinkamai įtakoja paskui važiuojančios transporto priemonės judėjimo greitį ir saugaus atstumo laikymąsi.

Nagrinėjant tiesinę tolimesniojo automobilio lygtį:

$$\ddot{x}_{n+1}(t+T) = k[x_n^{\cdot}(t) - x_{n+1}^{\cdot}(t)]. \quad (1.2.1.1)$$

Dviejų vienas paskui kitą važiuojančių mašinų pozicijas laiko momentu t pažymėkime atitinkamai: $x_{n-1}(t)$ – $n-1$ -osios mašinos pozicija, $x_n(t)$ – n -osios mašinos pozicija.

Pažymėję $t = \tau T$ ir įstatę į (1.2.1.1) lygtį gausime

$$\ddot{x}_{n+1}(\tau + 1) = C[x_n^{\cdot}(\tau) - x_{n+1}^{\cdot}(\tau)], \quad (1.2.1.2)$$

čia : $C = kT$.

Lokalinio stabilumo sąlygas išvedamos iš (1.2.1.2) lyties naudojant Laplaso transformaciją (Herman 1959).

Nustatyta, kai:

- $kT < \pi/2$ – atstumas tarp transporto priemonių mažėja laike,
- $kT < 1/e$ – greičio sutrikimas mažėja ir išlaikomas saugus atstumas,
- $kT > \pi/2$ – atstumas mažėja, svyravimas didėja, galiausiai transporto priemonės susiduria, eismas lokalai nestabilus [6, 15].

1.2.2. ASIMTOTINIS STABILUMAS

Nagrinėjant lokalinių stabilumų buvo aprašomas n -osios mašinos elgsena. Toliau nagrinėsime grupę mašinų važiuojančias viena paskui kitą pagal tiesinę tolimesniojo automobilio lygtį 1.2.2.1.

Lygtis aprašanti eilėje važiuojančių N identiškų automobilių yra:

$$\frac{d^2 x_{n+1}(t+T)}{dt^2} = k \left(\frac{dx_n(t)}{dt} - \frac{dx_{n+1}(t)}{dt} \right), n = 0, 1, 2, 3, \dots, N. \quad (1.2.2.1)$$

Apskritai (1.2.2.1) lygties išsprendimas priklauso nuo eilėje važiuojančios priekinės mašinos greičio, $u_0(t)$ bei nuo dviejų parametru k ir T . Jei važiuojant eilėje tarpai tarp mašinų sumažėja, o susigrūdimai amplitudiškai didėja, tai galiausiai gali įvykti avarijų maždaug mašinų eilės gale. (1.2.2.1) lygtimi galime apibrėžti vietą, kur tokie susigrudimai padidėja ar sumažėja [5, 15]. Eilėje važiuojančios pirmosios mašinos greitis, $u_0(t)$ apibrėžiamas monochromatiniu svyravimų dažniu, w ir amplitude, f_0 , t.y.:

$$u_0(t) = a_0 + f_0 e^{iwt}, \quad (1.2.2.2)$$

o n -osios mašinos greitis apibrėžiamas lygtimi

$$u_n(t) = a_0 + f_n e^{iwt}. \quad (1.2.2.3)$$

Irašant (1.2.2.2) ir (1.2.2.3) keitinius į (1.2.2.1) lygtį gauname:

$$u_n(t) = a_0 + F(w, \lambda, T, n) e^{i\Omega(w, \lambda, T, n)}, \quad (1.2.2.4)$$

čia amplitudė

$$F(w, \lambda, T, n) = \left[1 + \left(\frac{w}{\lambda} \right)^2 + 2 \left(\frac{w}{\lambda} \right) \sin(wT) \right]^{\frac{-n}{2}}, \quad (1.2.2.5)$$

kuri mažėja didėjant n , jeigu

$$1 + \left(\frac{w}{\lambda} \right)^2 + 2 \left(\frac{w}{\lambda} \right) \sin(wT) > 1, \quad (1.2.2.6)$$

t.y., jeigu

$$\frac{w}{\lambda} > 2 \sin(wT). \quad (1.2.2.7)$$

Parametro λ apribojimą gauname, kai svyravimų dažnis $w \rightarrow 0$. λ apribojimą atitinka nelygybė

$$\lambda T < \frac{1}{2} \left[\lim_{w \rightarrow 0} \frac{wT}{\sin(wT)} \right]. \quad (1.2.2.8)$$

Dėl to asimptotinis stabilumas yra garantuotas visiems svyravimų dažniams, kai (1.2.2.8) nelygybė yra teisinga.

1.3. MASINIO APTARNAVIMO SISTEMOS SĄVOKA

Masinio aptarnavimo sistemomis (toliau MAS) – vadinamos sistemos, i kurias pakliūva paraiškos, reikalaujančios kokių nors paslaugų įvykdymo ir kuriose tos paslaugos yra vykdomos. Mūsų nagrinėjamu atveju aptarnavimo reikalaujantis srautas yra mašinų, atvažiuojančių į sankryžą srautas[9, 17]. Paraiškos į sistemą pakliūva atsitiktiniai laiko momentais, viena paskui kitą. Bet kokie paraiškas aptarnaujantys įrenginiai (mūsų atveju šviesoforai) vadinami aptarnavimo kanalais. Tuo būdu MAS galime išskirti šias pagrindines dalis:

- paraiškų šaltinis;
- įėjimo srautas;
- aptarnavimo laukianti eilė;
- aptarnavimo įrenginys (aptarnavimo kanalas);
- išėjimo srautas.

Visuma aptarnavimo aparatu ir taisyklės, pagal kurias yra aptarnaujamos paraiškos, sudaro aptarnavimo sistemą. Paraiškų srautas, kuris patenka į aptarnavimo sistemą, vadinamas įėjimo srautu. Paraiškų srautas, išeinantis iš aptarnavimo sistemos, vadinamas išėjimo srautu. Nagrinėsime MAS su eile. Atėjusi paraiška ir radusi visus aptarnavimo įrenginius užimtus stoja į eilę ir laukia aptarnavimo pradžios. Šiuo atveju apribojimų eilės ilgii ir paraiškos laukimo laikui nėra. Paraiškos sistemoje su eile gali būti aptarnaujamos skirtingai. Jos gali būti aptarnaujamos arba tokia tvarka, kokia jos patenka į sistemą, arba atsitiktinai imant paraiškas iš eilės pagal paraiškų prioritetus. Gali būti taip, kad atėjusi prioritetinė paraiška nutraukia jau aptarnaujamos

paraiškos aptarnavimą ir pradedama aptarnauti ne eilės tvarka. Pagal aptarnavimo įrenginių skaičių, MAS yra skirtomos į vienakanales, kai aptarnavimo įrenginys yra vienas ir daugiakanales, kai aptarnavimo įrenginių yra daugiau nei vienas. Priklausomai nuo būvimo vietas, MAS skirtomos į atviras, kada paraiškų šaltinis yra išorėje ir uždaras, kada paraiškų šaltinis yra sistemos viduje [9].

Pagrindiniai principai yra: eilės turi įėjimo dažnį, aptarnavimo dažnį bei savo discipliną (tipą). Žemiau pateikti priimti eilių teorijos žymėjimai. Vienkanalės eilės modelis su Puasono įėjimo dažniu bei eksponentiniu aptarnavimo dažniu.

λ = Laukiamas įėjimų skaičius per laiko vienetą (vidutinis įėjimo dažnis),

μ = Laukiamas aptarnavimų skaičius per laiko vienetą (vidutinis aptarnavimo dažnis).

Modelyje naudojamos prielaidos:

- eilė turi vieną kanalą;
- įėjimo srautas pasiskirstęs pagal Puasono skirstinį;
- aptarnavimo laikas pasiskirstęs pagal eksponentinį skirstinį;
- eilės disciplina (tipas) yra: pirmas ateina, pirma aptarnaujama.

$$P_0 = \left(1 - \frac{\lambda}{\mu}\right) - \text{tikimybė, kad nieko nėra eilėje} \quad (1.3.1)$$

$$P_n = \left(\frac{\lambda}{\mu}\right)^n P_0 - \text{tikimybė, kad sistemoje yra } N \text{ mašinų} \quad (1.3.2)$$

$$L_q = \frac{\lambda^2}{\mu(\mu - \lambda)} - \text{vidutinis mašinų skaičius eilėje} \quad (1.3.3)$$

$$L = L_q + \frac{\lambda}{\mu} - \text{vidutinis mašinų skaičius sistemoje} \quad (1.3.4)$$

$$W_q = \frac{L_q}{\lambda} - \text{vidutinis mašinų laukimo eilėje laikas} \quad (1.3.5)$$

$$W = W_q + \frac{1}{\mu} - \text{vidutinis mašinų laukimo sistemoje laikas} \quad (1.3.6)$$

$$P_w = \frac{\lambda}{\mu} - \text{tikimybė, kad mašina turėjo laukti eilėje} \quad (1.3.7)$$

1.4. PAPRASČIAUSIAS SRAUTAS IR JO SKIRSTINYS

Atsitiktinio dydžio X skirstinį vadiname Puasono skirstiniu, jei

$$P(X = k) = \frac{\lambda^k e^{-\lambda}}{k!}, k = 0, 1, 2, \dots, \lambda > 0. \quad (1.4.1)$$

Sakykime, tam tikri įvykiai įvyksta atsitiktiniai laiko momentais. Tokių įvykių seką vadiname įvykių srautu.

Laikoma, kad įvykių srautas tenkina sąlygas [12]:

1. jei Δ_1 ir Δ_2 - bet kurie nesusikertantys laiko intervalai, tai įvykių pasirodymo dažniai šiuose intervaluose yra nepriklausomi atsitiktiniai dydžiai;
2. bet kurio įvykių skaičiaus patekimo į intervalą tikimybė priklauso tik nuo intervalo ilgio;
3. tikimybė $P_k(\Delta t)$, kad k įvykių įvyks nykstamojo ilgio Δt intervale $[t, t + \Delta t]$, tenkina sąlygas:

- $P_0(\Delta t) = 1 - \lambda \Delta t + o(\Delta t),$
- $P_1(\Delta t) = \lambda \Delta t + o(\Delta t), \text{ kai } \Delta t \rightarrow 0.$

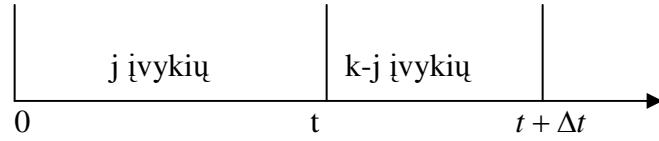
Teorema. Jei srautas yra paprasčiausias, tai tikimybė, kad laikotarpiu $[0, t]$ įvyks k srauto įvykių,

$$P_k(t) = \frac{(\lambda t)^k e^{-\lambda t}}{k!}, k = 0, 1, 2, \dots \quad (1.4.2)$$

čia: λt - vidutinis srauto įvykių skaičius laikotarpiu $[0, t]$, λ - vidutinis srauto intensyvumas.

Irodymas. Iš pilnosios tikimybės formulės ir 1 sąlygos išplaukia:

$$P_k(t + \Delta t) = \sum_{j=0}^k P_j(t) P_{k-j}(\Delta t), k = 0, 1, 2, K \quad (1.4.3)$$



Kai $k = 0$, gauname:

$$P_0(t + \Delta t) = P_0(t) P_0(\Delta t) = P_0(t)(1 - \lambda \Delta t + o(\Delta t)), \quad (1.4.4)$$

arba

$$\frac{P_0(t + \Delta t) - P_0(t)}{\Delta t} = -\lambda P_0(t) + \frac{o(\Delta t)}{\Delta t} \quad (1.4.5)$$

ir

$$\dot{P}_0(t) = -\lambda P_0(t). \quad (1.4.6)$$

Kai $k \geq 1$, išskyrę paskutiniuosius du narius, gauname:

$$P_k(t + \Delta t) = P_k(t) P_0(\Delta t) + P_{k-1}(t) P_1(\Delta t) + \sum_{j=0}^{k-2} P_j(t) P_{k-j}(\Delta t) = P_k(t)(1 - \lambda \Delta t + o(\Delta t)) + \\ + P_{k-1}(t)(\lambda \Delta t + o(\Delta t)) + o(\Delta t), \quad (1.4.7)$$

nes

$$\sum_{j=0}^{k-2} P_j(t) P_{k-j}(\Delta t) \leq \sum_{j=0}^{k-2} P_{k-j}(\Delta t) = o(\Delta t). \quad (1.4.8)$$

Dabar

$$\frac{P_k(t + \Delta t) - P_k(t)}{\Delta t} = \lambda P_{k-1}(t) - \lambda P_k(t) + \frac{o(\Delta t)}{\Delta t}, \quad (1.4.9)$$

ir apskaičiavę riba, kai $\Delta t \rightarrow 0$, gauname diferencialinę lygčių sistemą

$$P_k'(t) = \lambda P_{k-1}(t) - \lambda P_k(t), \text{ kai } k = 1, 2, K \quad (1.4.10)$$

Kadangi $P_0(0) = 1$ ir $P_k(0) = 0$ su visais $k \geq 1$, tai iš pirmos diferencialinės lygties

$$P_0(t) = e^{-\lambda t}. \quad (1.4.11)$$

Kai $k \geq 1$, pritaikę keitinį $P_k(t) = e^{-\lambda t} U_k(t)$, gauname sistemą

$$U_k'(t) = \lambda U_{k-1}(t). \quad (1.4.12)$$

Ją išsprendę rekurentiškai, turime:

$$U_k(t) = \frac{(\lambda t)^k}{k!}. \quad (1.4.13)$$

Pagaliau

$$P_k(t) = \frac{(\lambda t)^k e^{-\lambda t}}{k!}, \text{ kai } k = 0, 1, 2, K \quad (1.4.14)$$

Iš šios teoremos išplaukia, jog paprasčiausią srautą natūralu vadinti Puasono srautu [12].

1.5. APTARNAVIMO LAIKAS

Aptarnavimo sistemos efektyvumas priklauso ne tik nuo įėjimo srauto charakteristikų, bet ir nuo aptarnavimo sistemos našumo, t.y. nuo kanalų skaičiaus ir jų greitaeigžumo [9, 17]. Todėl vienos paraiškos aptarnavimo laikas yra svarbi sistemos charakteristika. Kadangi realiose sistemose kiekvienos Paraiškos aptarnavimo laikas yra skirtinas, todėl ji laikysime atsitiktiniu dydžiu.

Aptarnavimo laiko tikimybių pasiskirstymo funkcija

$$F(t) = P(T_{apt} < t), t > 0. \quad (1.5.1)$$

Praktikoje aptarnavimo laikas dažniausiai yra pasiskirstęs pagal eksponentinį pasiskirstymo dėsnį, t. y.

$$F(t) = 1 - e^{-\mu t}. \quad (1.5.2)$$

Aptarnavimo laiko tankio funkcija

$$f(t) = \frac{dF(t)}{dt}, f(t) = \mu e^{-\mu t} \quad (1.5.3)$$

Rasime aptarnavimo laiko vidurkį

$$M[T_{apt}] = \int_0^{\infty} tf(t) dt = \int_0^{\infty} \mu te^{-\mu t} dt = \mu \int_0^{\infty} te^{-\mu t} dt. \quad (1.5.4)$$

Panaudoję integravimo dalimis metodą ir apskaičiavę šį netiesioginį integralą, gauname

$$M[T_{ap}] = \frac{1}{\mu} \quad (1.5.5)$$

1.6. REGRESINĖ ANALIZĖ

Regresijos modelis - statistinis modelis, leidžiantis vieno kintamojo reikšmes prognozuoti pagal kito kintamojo reikšmes [13,14]. Statistiniai metodai, skirti regresijos modeliui sudaryti, patikrinti, ar jis tinkamas, ir taikyti prognozēms, turi bendrą pavadinimą - *regresinė analizė*.

Pirmiausia pasirenkamas regresijos modelio tipas - nuspindžiama, kokia priklausomybė kintamuosius sieja. Pasirinkus modelį reikia:

- įvertinti nežinomus modelio parametrus;
- patikrinti, ar parinktasis modelis suderinamas su duomenimis;
- išmokti regresijos modelį taikyti prognozēms.

Regresinėje analizėje visos prognozės yra kiekybinės - visada sprendžiama problema, kaip vieno kintamojo *skaitinės* reikšmės priklauso nuo kito kintamojo skaitinių reikšmių. Tiesinėje regresijoje susiduriame su atsitiktiniais dydžiais, todėl jokia prognozė nėra šimtaprocentinė - prognozuojamos reikšmės téra gana tikėtinės.

Svarbiausias tiesinės regresinės analizės privalumas prieš koreliacijos koeficientus yra tai, kad parenkama kintamuosius siejanti funkcija. Aptykslė kintamojo Y priklausomybė nuo X aprašoma lygtimi $y = bx + c$. Šia lygtimi galima naudotis prognozuojant Y reikšmes. Be to, parametras b parodo, keliais vienetais pasikeičia prognozuojama y reikšmė vienetu padidėjus x reikšmei. Žinoma, tokia lygtis tik apytiksliai atitinka tikrą, kintamuosius X ir Y siejančią priklausomybę.

Kintamasis, kurio reikšmes norima prognozuoti, vadinas *priklausomuoju kintamuoju*.

Kintamasis, pagal kurio reikšmes norima prognozuoti priklausomojo kintamojo reikšmes, vadinas *nepriklausomuoju kintamuoju*.

Regresijos modelio kintamuosius gali sieti *vienpusė* arba *dvipusė* priklausomybė. Dvipusės priklausomybės atveju, kurį laikyti priklausomu kintamuoju, lemia tiriama problema.

Nei vienpusė, nei dvipusė regresijos modelio kintamujų priklausomybė dar nereiškia *ją priežastinio* ryšio. Kokie ryšiai sieja kintamuosius, nustatoma remiantis papildoma informacija, pavyzdžiui, specialiai suplanuoto eksperimento rezultatais.

1.6.1. TIESINĖS REGRESIJOS MODELIS

Bendriausias tiesinis tikimybinis modelis, siejantis intervalinius kintamuosius Y ir X , atrodo taip:

$$Y = a + bX + e. \quad (1.6.1.1)$$

Šioje lygyje a, b yra nežinomas konstantos, o e - atsitiktinė paklaida.

Regresijos modelyje pabrėžiama Y priklausomybė nuo X . Bet Y gali priklausyti ir nuo kitų neįvardytų kintamujų [13,14]. Jų įtaka matyti iš atsitiktinės paklaidos.

Dažnai mus domina, kokias reikšmes gali įgyti Y , esant fiksutoms (neatsitiktinėms) X reikšmėms. Užrašysime (1.6.1.1) modelio analogą tuo atveju, kai X įgyja reikšmę x_i

$$Y_i = a + bx_i + e_i. \quad (1.6.1.2)$$

Šiame modelyje x_i yra neatsitiktinė fiksuta reikšmė, o e_i - atsitiktinė paklaida (atsitiktinis dydis).

Norime dar kartą pabrėžti, kad rinkdamiesi regresijos modelį, tik pasirenkame priklausomybės *tipą* su nežinomais koeficientais a ir b . Tirkindami, ar modelis tinkta, kartu randame ir šių koeficientų įverčius. Modelio lygtis parodo, kodėl esant tai pačiai reikšmei x_i galima gauti skirtinges y, realizacijas y_i . Galimos realizacijos priklauso nuo atsitiktinės paklaidos

elgesio. Regresijos modelio prielaidos - tai reikalavimai, kuriuos turi tenkinti paklaidos e_i , [13,14]. Suformuluosime jas.

Tiesinės regresijos prielaidos:

- 1) e_i normaliai pasiskirstę atsitiktiniai dydžiai,
- 2) visų e_i vidurkiai lygūs nuliui, t.y. $E e_i = 0$;
- 3) visų e_i dispersijos lygios, t.y. $D e_i = \sigma^2$;
- 4) visi e_i nepriklausomi.

Trumpai visas keturias prielaidas galima užrašyti taip: $e_i \sim N(0, \sigma^2)$; čia e_i yra nepriklausomi atsitiktiniai dydžiai. Beje, dispersija σ^2 nežinoma.

Mūsų tikslas - parametru a ir b įverčius \hat{a} ir \hat{b} parinkti taip, kad funkcijos $\hat{y}(x) = \hat{a} + \hat{b}x$ reikšmės taškuose x_i kiek galima mažiau skirtūsi nuo y_i . Gautoji funkcija bus naudojama priklausomojo kintamojo reikšmėms prognozuoti.

Kiekvieną x_i atitinka jo porinis stebėjimas y_i ir funkcijos $\hat{y}(x) = \hat{a} + \hat{b}x$ reikšmė. Geriausiai tinkanti funkcija yra tokia, kurios skirtumai (liekamoji paklaida) $\hat{e}_i = y_i - \hat{y}(x_i)$, $i = 1, 2, \dots, n$, mažiausiai.

Įverčiai \hat{a} ir \hat{b} randami minimizuojant

$$SSE = \sum_{i=1}^n (y_i - a - bx_i)^2. \quad (1.6.1.3)$$

Sumą SSE minimizuoja

$$\hat{b} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\sum_{i=1}^n x_i y_i - (\sum_{i=1}^n x_i \sum_{i=1}^n y_i) / n}{\sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2 / n}; \quad (1.6.1.4)$$

$$\hat{a} = \bar{y} - \hat{b}\bar{x}; \quad (1.6.1.5)$$

čia $\bar{y} = \sum_1^n y_i / n$, $\bar{x} = \sum_1^n x_i / n$. Aprašytasis funkcijos $\hat{y}(x)$ parametru parinkimo metodas vadinamas *mažiausiųjų kvadratų metodu*. Šiuo metodu gauti įverčiai yra nepaslinktieji ir turi mažiausias dispersijas.

Determinacijos koeficientas. Duomenis sudaro intervalinių kintamųjų poriniai stebėjimai: $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$.

Žinant tik x prognozuojama Y reikšmė būtų \bar{y} . Kiekvieną y_i ir \bar{y} skirtumą galima išskaidyti į dvi sudėties dalis:

$$y_i - \bar{y} = (y_i - \hat{y}(x_i)) + (\hat{y}(x_i) - \bar{y}) = \hat{e}_i + (\hat{y}(x_i) - \bar{y}). \quad (1.6.1.6)$$

Pakelę abi (1.6.1.6) lygybės puses kvadratu, susumavę ir sutraukę panašiuosius narius, gauname tokią lygybę:

$$SST = SSR + SSE \quad (1.6.1.7)$$

čia

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2, \quad SSR = \sum_{i=1}^n (\hat{y}(x_i) - \bar{y})^2, \quad SSE = \sum_{i=1}^n \hat{e}_i^2 \quad (1.6.1.8)$$

Suma SST vadinama visa kvadratų suma, SSR - regresijos kvadratų suma, o SSE - liekamujų paklaidų kvadratų suma.

Santykis SSR/SST vadinamas determinacijos koeficientu:

$$r^2 = \frac{SSR}{SST}. \quad (1.6.1.9)$$

Determinacijos koeficientą galima interpretuoti taip: r^2 = Variacijos dalis, kurią paaiškina regresijos modelis /Visa variacija.

Tarkime, kad duomenys idealiai atitinka regresijos tiesės lygtį $\hat{y}(x) = \hat{a} + \hat{b}x$, t. y. grafiko visos y_i reikšmės patenka ant regresijos tieses. Tuo atveju $SSE = 0$, $SSR = SST$ ir $SSR/SST = 1$. Dabar tarkime, kad regresijos tiesės lygtis visiškai netinkama prognozei, t. y. $SSR = 0$. Tuomet $SSR/SST = 0$.

Determinacijos koeficientas plačiai naudojamas kaip regresijos modelio tinkamumo indikatorius.

Norime atkreipti dėmesį, kad: didesnis determinacijos koeficientas reiškia, kad stebėjimai yra labiau koncentruoti apie mažiausiuju kvadratų metodu gautą tiesę. Remiantis vien tik determinacijos koeficientu, dar negalima pasakyti, ar tiesinės regresijos modelis turimiems duomenims tinkta.

Praktiškai taikant regresinę analizę, dažniausiai reikalaujama, kad $r^2 > 0,25$. Jeigu $r^2 < 0,25$, labai abejotina, ar tiesinės regresijos modelis tinkta.

Regresinės analizės statistinės išvados. Ankstesniuose skyreliuose apsiribojome aprašomajai statistikai būdingais vertinimais iš akies. Kai kurie iš jų skirti regresijos modelio

prielaids patikrinti. Užrašydami regresijos modelį jokių reikalavimų koeficientams a , b nekéléme. Be to, nereikalavome, kad paklaidų dispersija σ^2 būtų maža. Gali atsitikti taip, kad paklaidos yra normaliai pasiskirsčiusios ir nepriklausomos, ir homoskedastiškos, o nepriklausomas kintamasis priklausomam kintamajam jokios įtakos neturi, nes jo koeficientas modelyje lygus nuliui, t. y. turėsime modelį $Y_i = a + 0 \cdot x_i + e_i$. Todėl dar reikia ivertinti regresijos modelio koeficientų elgesį.

Parametru pasikliautinieji intervalai. Tarkime, kad visos (1.6.1.2) modelio prielaidos galioja. Modelyje yra du nežinomi koeficientai a , b ir nežinoma dispersija σ^2 . Visų jų išverčiai jau rasti anksčiau: a , b ir MSE . Primename, kad $MSE = SSE/(n - 2)$.

Galima apskaičiuoti parametrų a ir b pasikliautinuosius intervalus. Irodyta, kad \hat{a} ir \hat{b} dispersijų išverčiai yra

$$s_a^2 = MSE \left(\frac{1}{n} + \frac{(x)^2}{(n-1)s_x^2} \right), \quad s_b^2 = \frac{MSE}{(n-1)s_x^2} \quad (1.6.1.10)$$

$$\text{čia } (n-1)s_x^2 = \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2 / n.$$

Statistikos $(\hat{a} - a)/s_a$, $(\hat{b} - b)/s_b$ turi Stjudento skirstinius su $(n - 2)$ laisvės laipsniu. Be to, SSE/σ^2 turi χ^2 skirstinį su $(n - 2)$ laisvės laipsniu. Koeficientų a , b ir dispersijos σ^2 pasikliautinieji intervalai skaičiuojami pagal formules:

$$\hat{a} \pm s_a t_{(1-Q)/2}(n-2) \quad \hat{b} \pm s_b t_{(1-Q)/2}(n-2) \quad (1.6.1.11)$$

čia Q yra pasikliovimo lygmuo, $t_{(1-Q)/2}(n-2)$ - Stjudento skirstinio su $(n - 2)$ laisvės laipsniu $(1 - Q)/2$ lygmens kritinė reikšmė, $\chi^2_{(1-Q)/2}(n-2)$ yra χ^2 skirstinio su $(n - 2)$ laisvės laipsniu $(1 + Q)/2$ lygmens kritinė reikšmė. Visas kritis reikšmes galima rasti iš knygos pabaigoje pateikiamu lenteliu.

Hipotezė apie koeficiente b lygybę nuliui

Žinodami koeficientų išverčių skirstinius, galime tikrinti statistines hipotezes apie pačių koeficientų reikšmes. Statistinė hipoteze $H_0: a = 0$ aktuali tik tuo atveju, kai svarbu įsitikinti, ar regresijos tiesė kerta koordinačių susikirtimo tašką $(0, 0)$. Taip būna retai. Todėl šiuos hipotezės plačiau neaptarsime, tik pažymėsime, kad ji tikrinama visiškai analogiškai hipotezei apie b reikšmę ir naudojama statistika $(\hat{a} - a)/s_a$.

Mus labiausiai domina, ar koeficientas b nelygus nuliui, nes tuo atveju regresijos modelis virsta $Y_i = a + e_i$ t. y. Y_i nepriklauso nuo x_i . Užrašysime, kaip patikrinti hipotezę apie koeficiente b lygybę nuliui.

Duomenys. Turime porinius stebėjimus : $(x_1 \ y_1), (x_2 \ y_2), \dots, (x_n \ y_n)$. Visos tiesinės regresijos prielaidos galioja.

Statistinė hipotezė:

$$\begin{cases} H_0 : b = 0 \\ H_1 : b \neq 0 \end{cases} \quad (1.6.1.12)$$

Kriterijaus statistika. Apskaičiuojame statistiką $T = \hat{b} / s_b$.

Sprendinio priėmimo taisyklė. Tegul reikšmingumo lygmuo lygus α . Hipotezė H_0 neatmetama, jeigu $|T| > t_{\alpha/2}(n - 2)$; čia $t_{\alpha/2}(n - 2)$ yra Stjudento skirstinio su $(n - 2)$ laisvės laipsniu $\alpha/2$ lygmens kritinė reikšmė. Hipotezė H_0 neatmetama, jeigu $|T| \leq t_{\alpha/2}(n - 2)$.

Statistinio kriterijaus naudojama statistika T su determinacijos koeficientu r^2 yra susijusi tokia priklausomybe:

$$r^2 = \frac{T^2}{T^2 + (n - 2)}. \quad (1.6.1.13)$$

Prognozavimas regresinėje analizėje. Paminėsime, kokie reikalavimai keliami prognozēms ir kaip jas galima patikslinti.

Aptarsime, ką reiškia prognozuoti pagal regresijos tiesės lygtį. Prisiminkime (1.6.1.2) modelį. Tarkime, kad prognozę norime padaryti konkrečiai *fiksotai* nepriklausomo kintamojo x reikšmei. Iš (1.6.1.2) modelio išplaukia, kad tada priklausomas kintamasis $Y = a + bx + e$; čia $e \sim N(0, \sigma^2)$ yra atsitiktinė paklaida. Vadinas, su fiksotomis x reikšmėmis Y gali įgyti įvairias reikšmes, nes joms įtakos turi ir atsitiktinė paklaida. Todėl nelabai tikėtina, kad pasiseks *tiksliai* atspėti tikrają busimąją Y reikšmę. Ką tuomet prognozuojame?

Kadangi e skirstinys yra normalusis, tai normaliai pasiskirstęs ir kintamasis Y . Normaliojo kintamojo tankis didžiausią reikšmę įgyja vidurkio taške. Todėl geriausia, ką galima padaryti, tai prognozuoti Y reikšmę, kiek galima artimesnę visų galimų (fiksotam x) kintamojo Y reikšmių vidurkiui. Taip ir darome: \hat{a} yra a , o \hat{b} yra b įverčiai, todėl akivaizdu, kad regresijos tiesė $\hat{y}(x) = \hat{a} + \hat{b}x$ yra lygties $EY = a + bx$ (kurioje jau nėra atsitiktinių dydžių, tik nežinomi daugikliai) analogas.

Taigi taikydami $\hat{y}(x)$ prognozei, siekiame, kad prognozuojamoji reikšmė būtų kiek galima artimesnė, esant tam tikram fiksotam x , galimų y , reikšmių vidurkiui.

Atkreipiame dėmesį, kad norėdami prognozuoti *vidutinę* Y reikšmę, esant fiksotam x , naudotumėmės ta pačia regresijos tiesės lygtimi ir gautume tų pačią prognozę.

Viena iš būdingiausių bet kokio prognozavimo klaidų yra bandymas pernelyg tolimą ateitį spėti remiantis dabarties prielaidomis. Norėdami jų išvengti, griežčiau apibrėšime, kokioms x reikšmėms galima prognozuoti Y reikšmes.

Regresinėje analizėje prognozės daromos tik toms x reikšmėms, kurios patenka į duomenų intervalą, t.y. tik tada, kai $\min(x_1, \dots, x_n) \leq x \leq \max(x_1, \dots, x_n)$ [14].

1.7. PROGRAMINĖS ĮRANGOS PASIRINKIMO PAGRINDIMAS

Darbe reikia atlikti mikroskopinio eismo srauto stabilumo analizę, statistinius veiksmus, skaičiuoti ir įvertinti parametrus, sudaryti mikroskopinį eismo srauto imitacinių sankryžos modelį ir nustatyti kintamųjų įtaką eilių susidarymui.

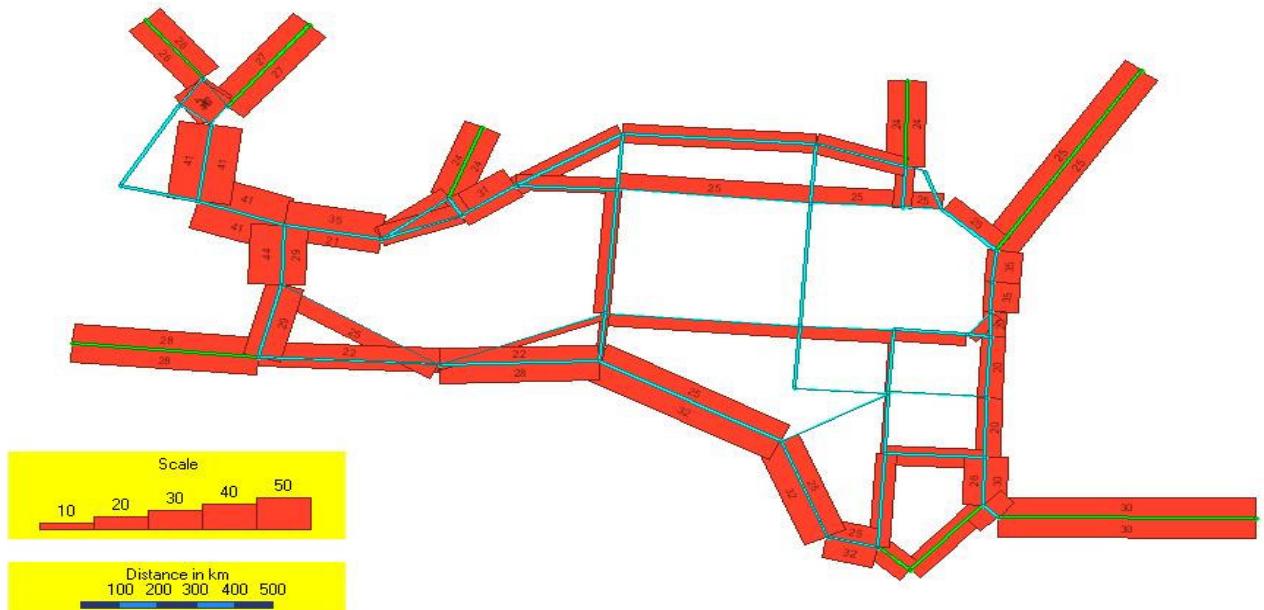
Sudaromas mikroskopinio eismo srauto matematinis modelis ir atliekama stabilumo analizė programiniu paketu Matlab 7.0. Matlab paprogramėje Simulink sukuriamas realaus laiko, eismas ratu modelis. Programa pritaikyta atlikti ne tik modeliavimus, bet ir gautus duomenis apdoroti statistiškai.

Imitacinis trišalės sankryžos veikimas modeliuojamas programiniu paketu Arena 3.0 (akademinė versija). Pasirinkta todėl, kad yra platus įrankių asortimentas leidžiantis projektuoti sankryžos veikimą.

Regresinio modelio sudarymui naudojame SAS statistinį paketą.

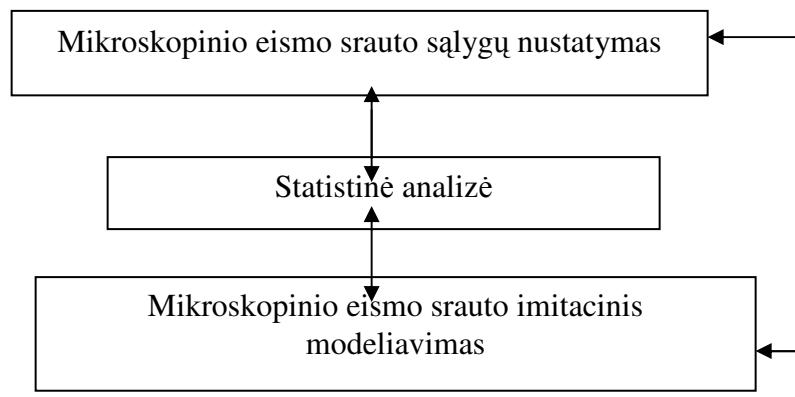
2. TIRIAMOJI DALIS IR REZULTATAI

Detaliam tyrimui buvo pasirinkta K. Mindaugo pr. – Birštono g-vės sankryža, nes didžiausiai transporto eismo srautai susidaro ties įvažiavimais – išvažiavimais į Kauno miesto centrą, čia susieina didelio pralaidumo ir intensyvumo gatvės – Savanorių pr., Jonavos g. ir K. Mindaugo pr. (dar galima priskirti Veiverių g.). Jomis judantys automobilių srautai pasiskirsto keliose mažesnio pralaidumo senamiesčio gatvėse (Šv. Gertrūdos, Gimnazijos, Birštono, Šauklių g.), jas užkimšdami (ypatingai rytinio ir vakarinio piko metu). Salyginai mažiausiai eismo srautai yra Donelaičio ir Kęstučio gatvėse. 2.1 pav. pateikiti eismo srautų intensyvumai [18].



2.1 pav. Eismo srautų pasiskirstymas Kauno miesto centre

Mikroskopinio eismo srauto modeliavimas ir analizė buvo atliekama keliais etapais. Etapai ir jų eiliukumas pavaizduotas 2.2 pav.



Pagrindinę darbo esmę sudaro mikroskopinis eismo srauto K. Mindaugo pr. – Birštono g-vės sankryžos modeliavimas. Prieš atliekant šį modeliavimą, visų pirma, įvertiname sistemos stabilumo ribas, tam, kad sukurtas modelis būtų teisingas. Visų antra, nustatome mikroskopinio eismo srauto pasiskirstymo skirstinį, tam, kad sankryžos modeliavimui galėtume taikyti Markovo masinio aptarnavimo sistemų teoriją. Po šio etapo įgyvendinimo toliau lygiagrečiai sekė K. Mindaugo pr. – Birštono g-vės sankryžos modeliavimas ir parametru įvertinimas. Galiausiai sudarome regresijos modelį eismo srautams prognozuoti.

2.1. MIKROSKOPINIO EISMO SRAUTO STABILUMO ANALIZĖ

Šiame darbe išnagrinėtas mikroskopinio eismo srauto stabilumo aktualumas mikroskopinio eismo srauto modeliavimui. Esant neribotam greičiui, sistema tampa nestabili. Išanalizuota, kas atsitinka esant mažiems greičių skirtumams ir nustatyta eismo srauto stabilumo ribos, kurioms esant mikroskopinio eismo srauto modeliai būtų teisingi.

Analizujant nesudėtingą eismo modelį, atskleidžiamas pakankamai komplikuota srauto elgsena. Nagrinėtas vienos juostos eismas ratu, kurioje važiuoja fiksotas skaičius mašinų. Kiekvienas vairuotojas tai sumažina, tai padidina mašinos greitį, priklausomai nuo priekyje judančios mašinos greičio bei atstumo tarp dviejų, vienas po kito važiuojančių transporto priemonių. Vairuotojui yra reikalingas baigtinis reakcijos laikas, vertinant eismo padėtį kas akimirką. Kitaip tariant, reikalingas laiko tarpas (paprastai apie sekundę) suvokti, kas vyksta kelyje, priklausomai nuo to padidinti, sumažinti, ar išlaikyti tokį pat greitį.

Analizė atlikta pagal 1.1 ir 1.2 skyrių matematinius modelius. Remiantis klasikiniu tolimesniojo automobilio modeliu turime, kad

$$x_{n+1}''(t + \Delta t) = k[x_n'(t) - x_{n+1}'(t)]. \quad (2.1.1)$$

Pagrindinė esmė yra, kad vairuotojas turi polinkį sumažinti greitį, jei jis važiuoja greičiau už priekyje judančią automobilį, arba kai jis yra arti priekyje važiuojančio automobilio, ir turi polinkį padidinti greitį, jei jis važiuoja lėčiau negu priekyje važiuojanti mašina. Be to, vairuotojas (ypač neapkrautame eisme) gali bandyti padidinti, sumažinti greitį priklausomai ar jis važiuoja greičiau ar lėčiau (atitinkamai) negu leistinas greitis tame kelyje.

Kadangi, eismas vyksta ratu, (2.1.1) lygtje x_0 yra interpretuojamas kaip x_N , čia N -automobilių skaičius. Apsiribojame, tuo atveju, kai jautrumo konstanta k yra teigama. Tuomet gaunama homogeninė diferencialinė lygtis su pastoviais greičio $\dot{x}_n(t)$ koeficientais. Akivaizdu, kad sprendinys yra pastovus („steady-state“), kai visi greičiai yra lygūs ir konstantos lygios, t.y. eismas vyksta pastoviu greičiu. Žinome, kad

$$\dot{x}_n(t) = \exp(\alpha t)v_n, \quad (2.1.2)$$

čia: v_n, α - (kompleksinės) konstantos.

Sistema nestabili, jei greitis neribojamas, t.y. α teigama. Naudojant vektorių žymėjimą turime, kad

$$\dot{x}(t) = \exp(\alpha t)v, x''(t+T) = \alpha \cdot \exp(\alpha T) \exp(\alpha t)v. \quad (2.1.3)$$

(2.1.3) lygtį įstatome į (2.1.1) ir gauname:

$$\alpha \cdot \exp(\alpha T) \exp(\alpha t)v = k(S - I) \exp(\alpha t)v, \quad (2.1.4)$$

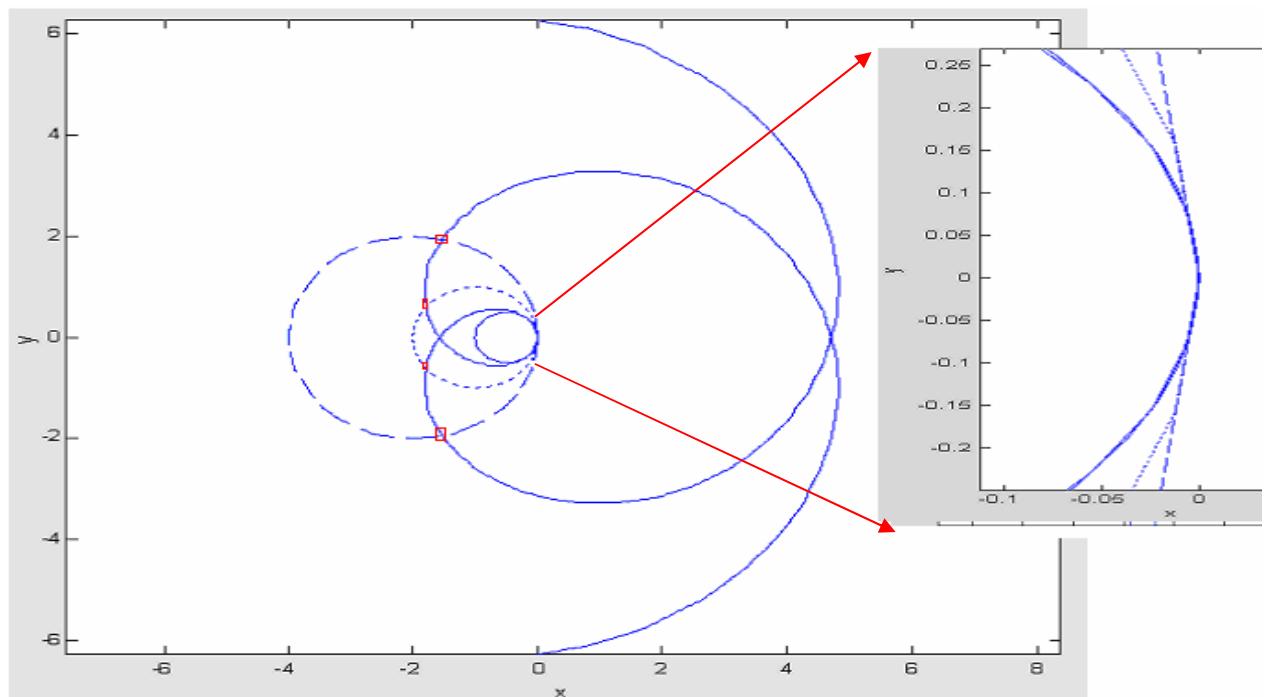
čia: I – vienetinė matrica, S – paslinktoji matrica, T – vairuotojo reakcijos laikas, kaip ir Δt .

$$S = \begin{pmatrix} 0 & K & K & K & K & 1 \\ 1 & 0 & K & K & K & K \\ 0 & 1 & K & K & K & K \\ K & K & K & K & K & K \\ K & K & K & 1 & 0 & K \\ K & K & K & 0 & 1 & 0 \end{pmatrix}. \quad (2.1.5)$$

Sprendžiant (2.1.4) lygtį gauname:

$$\begin{aligned} \alpha \cdot \exp(\alpha T)v &= k(S - I)v, \text{ arba} \\ (S - (1 + ((\frac{\alpha}{k}) \exp(\alpha T))I)v &= 0, \end{aligned} \quad (2.1.6)$$

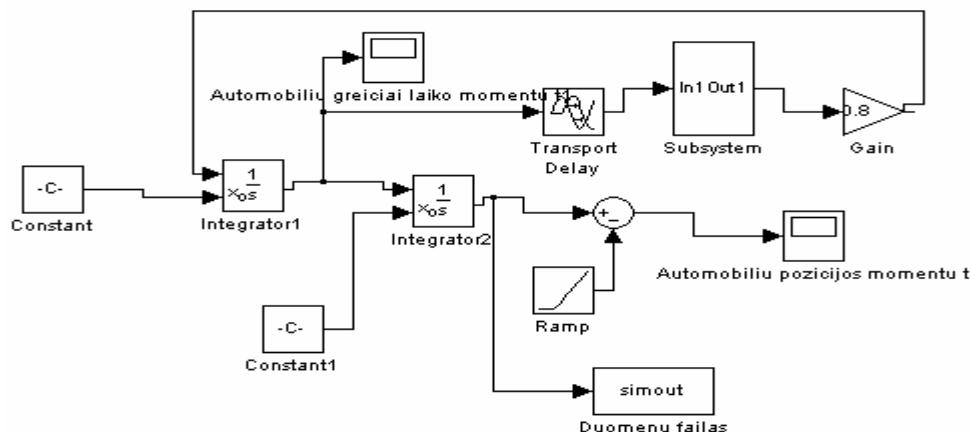
Nestabilumas priklauso nuo kT . Visa tai galime pamatyti koordinačių plokštumoje atidedant z reikšmes $z = \exp(z)$, lygindami su kreive $kT(e^{i\theta} - 1)$, kai kT įvairios reikšmės.



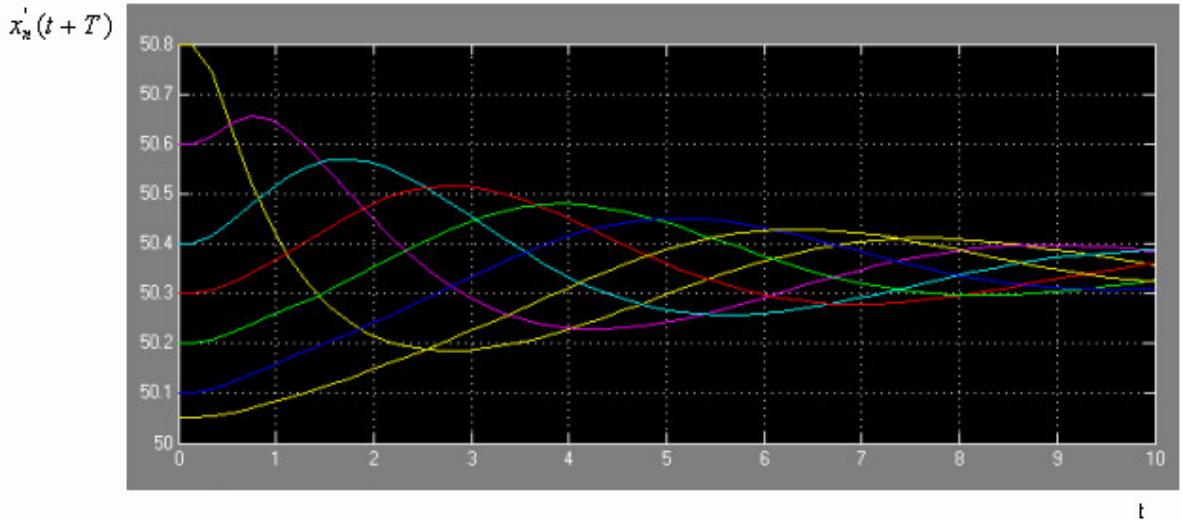
2.1.1 pav. Sistemos stabilumas ir nestabilumas

2.1.1 paveiksle pavaizduotas sistemos stabilumas ir nestabilumas. Kai $kT = 0.5$, turime sistemos stabilumo ribą, kol apskritimas $0.5(e^{i\theta} - 1)$ nekerta spiralės $z = \exp(z)$, kai z yra kompleksinis skaičius stabilumo taške $\text{Re } z = 0$. Taškuota ir punktyrinė kreivės, kai $kT = 1$ ir $kT = 2$, kertančiuose spiralės taškuose, pažymėti raudonais kvadratais, rodo eismo srauto nestabilumą.

Patikriname gautus teorinius rezultatus modeliuojant MATLAB/Simulink :

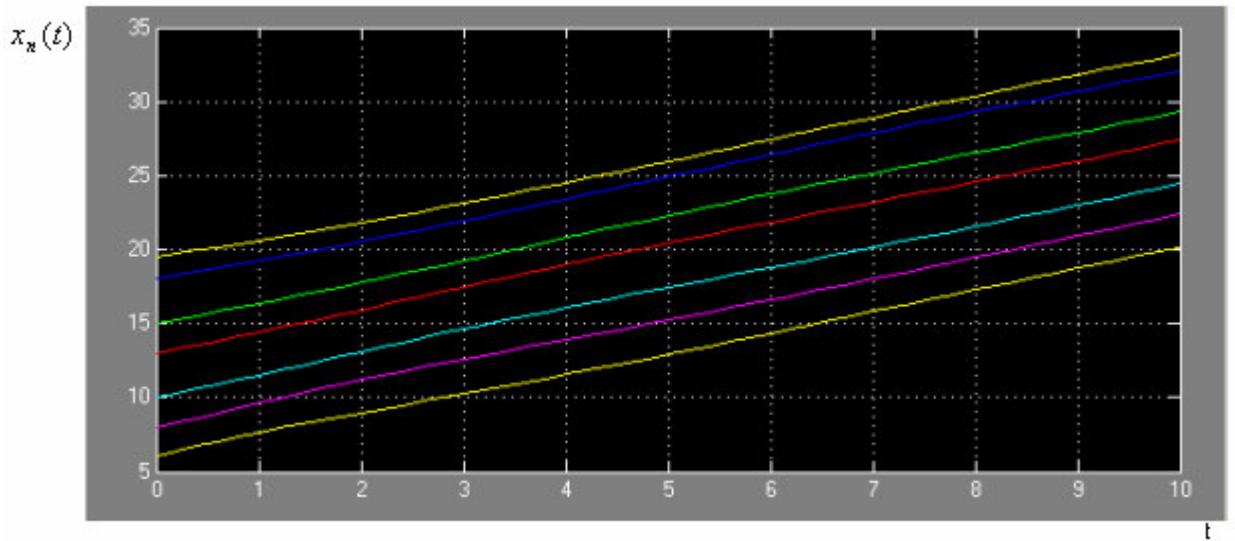


2.1.2 pav. Modelio struktūra Simulink aplinkoje



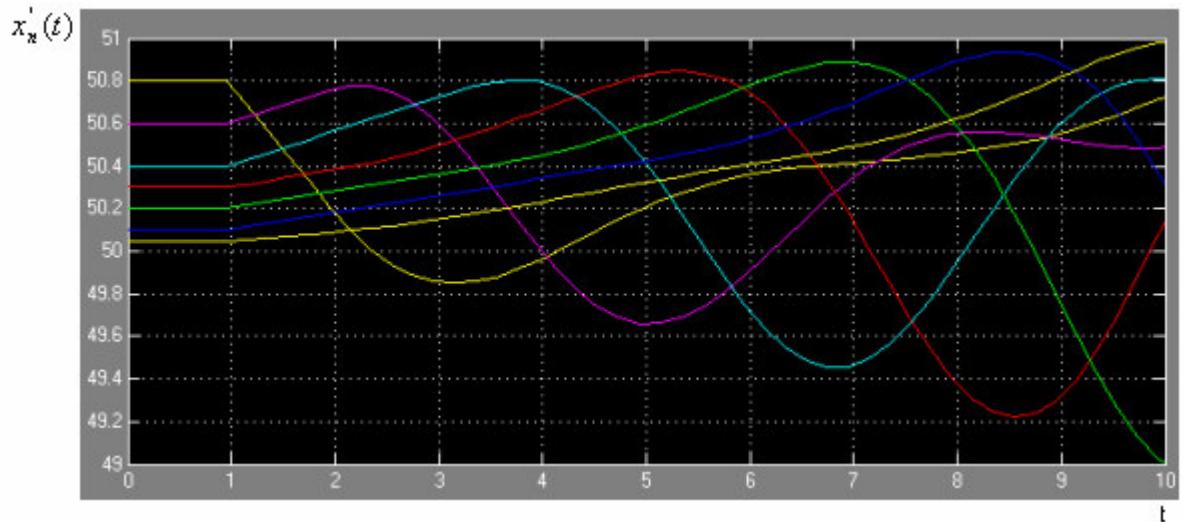
2.1.3 pav. Automobilių greičiai laiko momentu t , eismo srautas stabilus

2.1.3 paveiksle pavaizduotas septynių transporto priemonių judėjimo greičių kitimas laiko momentu t , kai automobilių greičių skirtumas yra pakankamai mažas. Matome, kad automobilių greičių svyravimų dažnis mažėja ir galiausiai konverguoja į pastovų greitį 50.3 km/h. Eismo srautas stabilus, $kT = 0.192$.



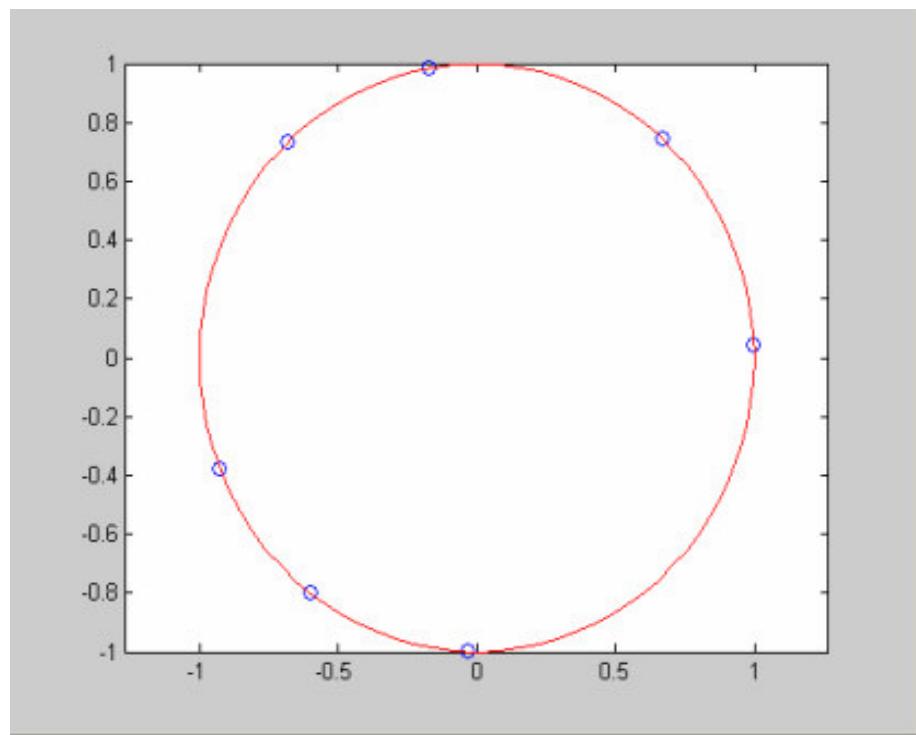
2.1.4 pav. Automobilių pozicijos laiko momentu t , eismo srautas stabilus

Gauti rezultatai (2.1.4 pav.) parodo, kad atstumai, tarp vienas po kito važiuojančių transporto priemonių, yra išlaikomi pastovūs. Nusistovėjus greičiui, nusistovi ir atstumai tarp transporto priemonių, gautos mikroskopinės eismo srautės yra stabilus, $kT = 0.192$.

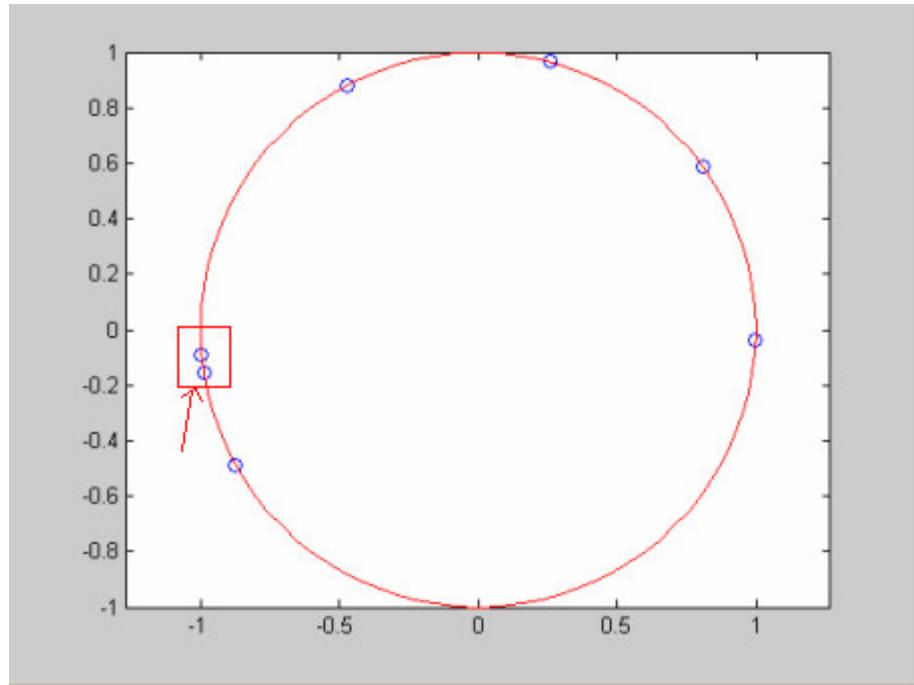


2.1.5 pav. Automobilių greičiai laiko momentu t , eismo srautas nestabilus

2.1.5 paveiksle pavaizduotas eismo srauto nestabilumas, esant mažiems automobilių greičių skirtumams. Jautrumo parametras buvo padidintas, $kT = 0.642$. Matome, kad greičių svyravimų dažnis didėja ir galiausiai prarandama pusiausvyra ir mikroskopinio eismo srauto sistema tampa nestabili.



2.1.6 pav. Stabilus eismo srautas ratu



2.1.7 pav. Nestabilus eismo srautas ratu

Remiantis gautais modeliavimo rezultatais analizuojame eismą ratu (2.1.6 pav. ir 2.1.7 pav.), kur raudonas vienetinis apskritimas žymi transporto priemonių judėjimo trajektoriją ratu, o maži mėlyni apskritimai - transporto priemones. Įvykdžius programinę realizaciją, gauname, kad 2.1.6 pav. mikroskopinio eismo srauto sistema stabili, o 2.1.7 pav. nėra išlaikomas saugus atstumas tarp septynių vienas po kito važiuojančių transporto priemonių. Greičių svyravimų dažnis padidėja ir transporto priemonės galiausiai susiduria. Sistema tampa nestabili, $kT = 0.642$.

Atlikus eilę bandymų nustatyta, kad mikroskopinio eismo srauto stabilumas priklauso nuo vairuotojo reakcijos laiko T ir jautrumo parametru k . Mikroskopinis eismo srauto sistema yra stabili, kai $kT < 0.5$ ir nestabili, kai $kT > 0.5$. Gautas rezultatas yra naudojamas modeliuojant mikroskopinį eismo srautą Mindaugo pr. – Birštono g-vės sankryžos veikimą.

2.2. MIKROSKOPINIO EISMO SRAUTO SKIRSTINIO NUSTATYMAS

Analizuojame pravažiuojančių transporto priemonių srautą K. Mindaugo pr. – Birštono gatvėje nuo 6:45 val. iki 8:45 val. (žr.1 Priedas , 1 lentelė).

Pateikiame apskaičiuotus atsitiktinio dydžio X reikšmes ir jų dažnus $D03$ eismo juosteje per 5 min. (2.2.1 lentelė).

2.2.1 Lentelė

Atsitiktinio dydžio X reikšmės ir jų dažniai D03 eismo juosteje

x_i	0	1	2	3	4	5	6	7	8	9
n_i	0	1	0	1	7	5	3	4	2	1

Parodysime, kad mikroskopinis eismo srautas yra paprasčiausias. Tam panaudosime Pirsono χ^2 kriterijų. Apskaičiuojame vidutinį transporto priemonių, pravažiuojančių per 5 min., skaičių: $Q = \lambda t = 5.33333$.

Remdamiesi duomenimis (2.2.1 lentelė) :

- nubraižysime santykinių dažnių histogramą;
- su reikšmingumo lygmeniu $\alpha = 0.05$ patikrinsime nulinę hipotezę $H_0: X \sim P(\lambda)$.

Δ Tikimybė, kad per laiką $[0, t]$ įvyks i įvykių lygi

$$P_i(t) = \frac{(\lambda t)^i}{i!} e^{-\lambda t},$$

čia λt - vidutinis srauto įvykių skaičius laikotarpiu $[0, t]$, λ - vidutinis srauto intensyvumas, t.y. vidutinis transporto priemonių, pravažiuojančių per laiko vienetą, skaičius.

Rasime Puasono skirstinio $P(\lambda)$ nežinomo parametru įvertį $\lambda = 1.066667$.

Apskaičiuojame tikimybes:

$$p_i = \frac{5.33333^i \cdot e^{-5.33333}}{i!}, \text{ kai } i = 0, 1, 2, 3, 4, 5, 6, 7, 8, 9.$$

Toliau skaičiuojame teorinius dažnius np_i ir statistikos χ^2 narius:

$$\overline{\chi^2}_i = \frac{(np_i - n_i)^2}{np_i}, \quad i = 0, 1, 2, K, 9.$$

Gautus rezultatus pateikiame lentelėje

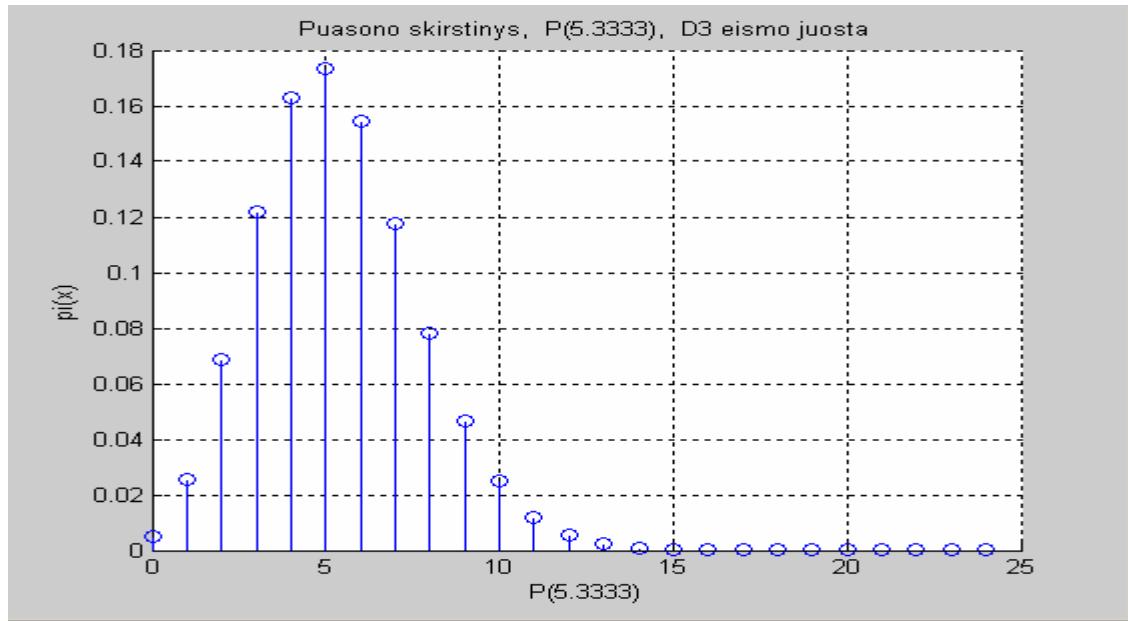
2.2.2 lentelė

Sugrupuoti duomenys, D03 eismo juosta

$i = x_i$	n_i	p_i	np_i	$\overline{\chi^2}_i$
0	0	0,004828	0,115871	0,115871
1	1	0,025749	0,617978	0,236159
2	0	0,068664	1,64794	1,64794
3	1	0,12207	2,929672	1,271007

4	7	0,16276	3,906229	2,450297
5	5	0,17361	4,166644	0,166677
6	3	0,15432	3,703684	0,133697
7	4	0,117577	2,821854	0,491885
8	2	0,078385	1,881236	0,007498
9	1	0,092037	2,208893	0,661609
\sum	24	1	24	7,182639

Pateikiame santykinių dažnių D03 eismo juostoje histogramą (2.2.1 pav.).



2.2.1 pav. Puasono skirstinys, D03 eismo juosta, $\lambda_t = 5.3333; \lambda = 1.0667$.

Iš histogramos darome prielaidą, kad eismo srautas yra puasoninis, taigi keliame hipotezę $H_0: X \sim P(\lambda)$, ją tikriname Pirsono χ^2 kriterijumi. Apskaičiuoti χ^2 nariai pateikti 2.2.1 lentelėje.

Kai $\alpha = 0.05$ ir χ^2 skirstinio su $v = k - r - 1 = 8$ laisvės laipsniais p-asis kvantilis $X_p^2 = X_{0.95}^2(8) = 15,50731$. Gauname:

$$\overline{X}_{0.95}^2(8) = 7,182639 < 15,50731 = X_{0.95}^2(8),$$

taigi hipotezę H_0 , kad eismo srautas Birštono gatvės D03 eismo juostoje yra pasiskirstęs pagal Puasono skirstinį priimame, t.y.:

$$P_i(t) = \frac{(1.066667t)^i \cdot e^{-1.066667t}}{i!}.$$

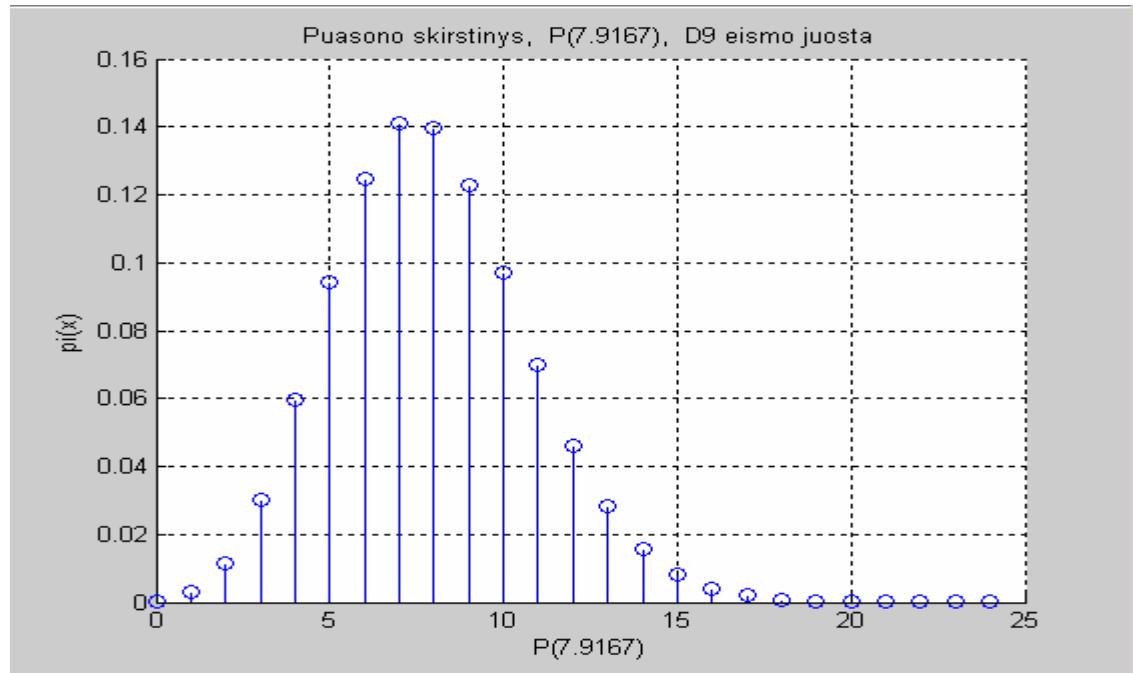
Pateikiame apskaičiuotus atsitiktinio dydžio X reikšmes ir jų dažnius $D09$ eismo juosteje per 5 min. Sugrupuotų duomenų lentelėje (2.2.3 lentelė).

2.2.3 lentelė

Sugrupuoti duomenys, D09 eismo juosta

$i = x_i$	n_i	p_i	np_i	\bar{X}_i^2
0	0	0,000365	0,008751	0,008751
1	0	0,002887	0,069277	0,069277
2	0	0,011426	0,274221	0,274221
3	0	0,030152	0,72364	0,72364
4	3	0,059675	1,432204	1,716226
5	2	0,094486	2,267656	0,031592
6	7	0,124669	2,992046	5,3688
7	2	0,140994	3,383861	0,565943
8	1	0,139526	3,348613	1,647244
9	0	0,122731	2,945539	2,945539
10	3	0,097162	2,331885	0,191423
11	2	0,069927	1,678251	0,061685
12	2	0,046132	1,107179	0,719964
13	1	0,028093	0,674244	0,157387
14	0	0,015886	0,381269	0,381269
15	1	0,01589	0,381365	1,003527
Σ	24	1	24	15,86649

Pateikiame santykinių dažnių $D09$ eismo juosteje histogramą (2.2.2 pav.)



2.2.2 pav. Puasono skirstinys, D09 eismo juosta, $\lambda_t = 7.9167; \lambda = 1.5833$.

Iš histogramos darome prielaidą, kad eismo srautas yra puasoninis, taigi keliame hipotezę $H_0: X \sim P(\lambda)$, ją tikriname Pirsono χ^2 kriterijumi. Apskaičiuoti χ^2 nariai pateiki 1.3 lentelėje.

Kai $\alpha = 0.05$ ir χ^2 skirstinio su $v = k - r - 1 = 14$ laisvės laipsniais p-asis kvantilis $X_p^2 = X_{0.95}^2(14) = 23,68478$. Gauname:

$$\bar{X}_{0.95}^2(14) = 15,86649 < 23,68478 = X_{0.95}^2(14),$$

taigi hipotezę H_0 , kad eismo srautas Birštono gatvės D9 eismo juosteje yra pasiskirstęs pagal Puasono skirstinį priimame, t.y.:

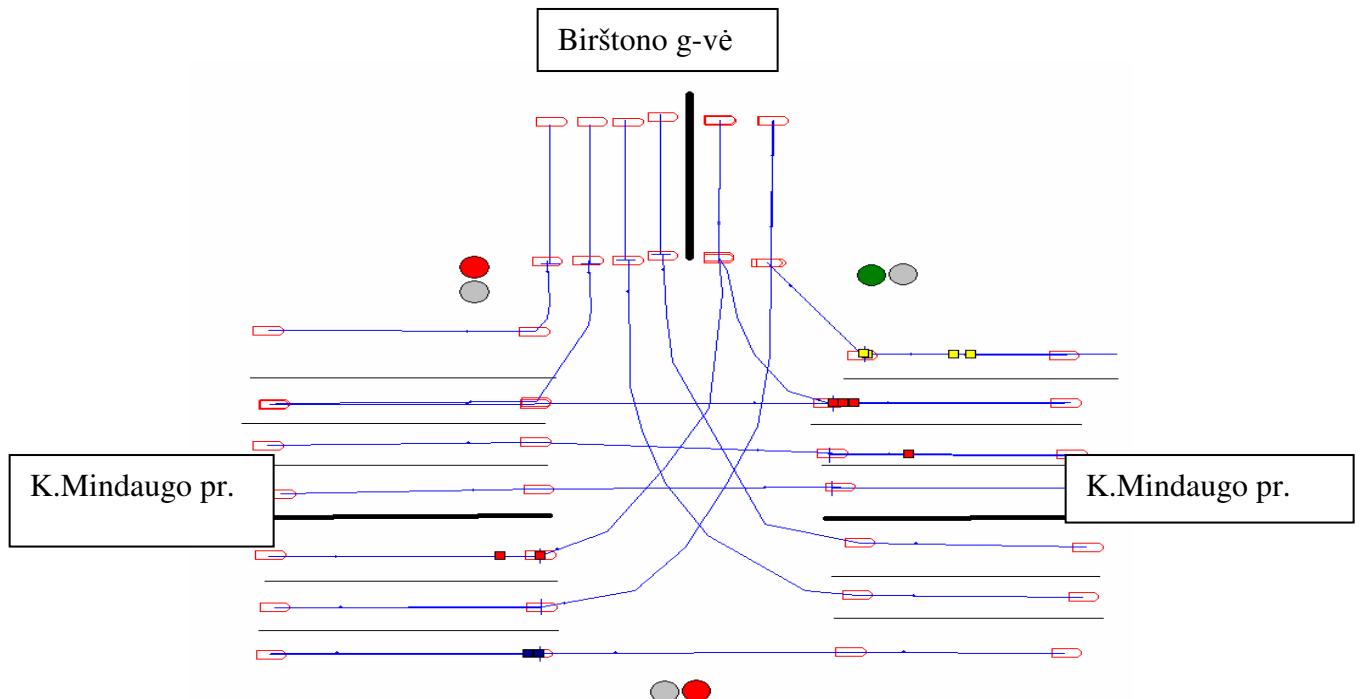
$$P_i(t) = \frac{(7.9167t)^i \cdot e^{-7.9167t}}{i!}.$$

Atitinkamai darome išvadą, kad mikroskopinis eismo srautas yra puasoninis ir paprasčiausias.

Gautas rezultatas toliau naudojamas modeliuojant K. Mindaugo pr. – Birštono g-vės sankryžos veikimą taikant Markovo masinio aptarnavimo sistemų teoriją.

2.3. MIKROSKOPINIO EISMO SRAUTO IMITACINIS MODELIAVIMAS

Mikroskopiniam eismo srautui modeliuoti ir tirti pasirinkta K. Mindaugo pr. – Birštono gatvių sankryžą. Eismo srautus modeliuojame pagal Markovo masinio aptarnavimo sistemų teoriją. Modeliavimui pasirenkame M/M/1 sistemą.



2.3.1 pav. Trišalė K. Mindaugo pr. – Birštono g-vės sankryža

Sukurtas modelis, kuris atspindi trišalės sankryžos veikimą (2.3.1 pav.). Sankryža reguliuojama šviesoforais. Laikome, kad šviesoforai papildomu rodykliu neturi.

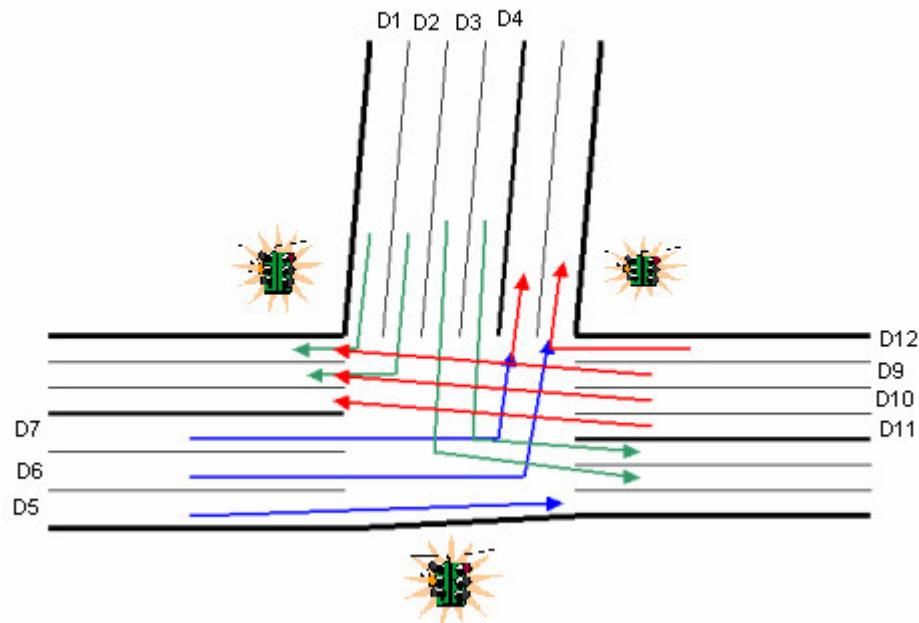
Sudarant modelį atsižvelgėme, kad:

- transporto priemonių vairuotojai vadovaujasi kelių eismo taisyklėmis;
- transporto priemonės kelyje negali apsisukti ir viena kitos lenkti.

Transporto priemonė važiuoja per sankryžą, jei iš dešinėje pusėje esančio kelio nėra automobilių ir sankryža laisva, t.y. sankryžoje nėra kitų automobilių, kurie kliudytu pravažiuoti. Jeigu tuo momentu, kai atvažiuoja transporto priemonė, sankryža yra užimta arba jai yra kliūtis iš dešinės, tada stoja į eilę ir laukia kada galės važiuoti. Automobiliai stoja į eilę ir degant draudžiamiems šviesoforo signalams bei tuo atveju, kai kelyje yra susidariusi mašinų eilė.

Pagal Markovo masinio aptarnavimo sistemų teoriją vidutinis sankryžos atidarymo laikas, t.y. aptarnavimo laikas, K. Mindaugo pr. yra $T_{aptM} = 35$ s, o Birštono gatve $T_{aptB} = 25$ s. Parametras μ yra atvirkščias dydis vidutinei paraiškos aptarnavimo trukmei:

$$\mu = \frac{1}{T_{apt}} = \frac{1}{30} \approx 0.033 \text{ 1/s.}$$



2.3.2 pav. Galimos transporto priemonių važiavimo kryptys

Transporto priemonių važiavimo per sankryžą algoritmas pavaizduotas 2.3.2 paveiksle. Važiavimo algoritmas nepriklauso nuo to iš kurio kelio atvažiavo ir į kurį nori važiuoti transporto priemonė.

Atlikus programinę realizaciją Arena 3.0 aplinkoje ir sudarius programinę schemą gaunamas duomenų failas (duom.xls), kuriame saugoma informacija: šviesoforo degimo trukmė (aptarnavimo laikas), susidariusių transporto priemonių eilių skaičius kiekvienoje eismo juosteje, transporto priemonių judėjimo greičiai, srauto intensyvumai, vidutiniai aptarnavimo dažniai

Remiantis gautais duomenimis sudaromas tiesinės regresijos modelis eilėms prognozuoti.

2.4. REGRESIJOS MODELIO SUDARYMAS

Turime tokius nepriklausomus kintamuosius: transporto priemonių judėjimo greičiai, aptarnavimo laikas (šviesoforo laikas), srauto intensyvumas, vidutiniai aptarnavimo dažniai. Ir priklausomi kintamieji: *D01, D02, D03, D04, D05, D06, D07, D09, D10, D11, D12* susidariusių eilių ilgiai.

Regresinio modelio sudarymui naudojame SAS statistinio paketo procedūrą REG ir jos opciją STEPWISE, kuri žingsnis po žingsnio atmeta kintamuosius, kurie yra nereikšmingi regresinio modelio sudarymui.

Visų pirma ieškome *D01* eismo juostos eilės ilgio regresijos modelį, kaip *D01* eilė priklauso nuo nepriklausomų kintamųjų aprašytų anksčiau.

Gauname tokius rezultatus(žr. 2.4.1 pav.):

Reikšmingi kintamieji, D01 eilė

2.4.1 lentelė

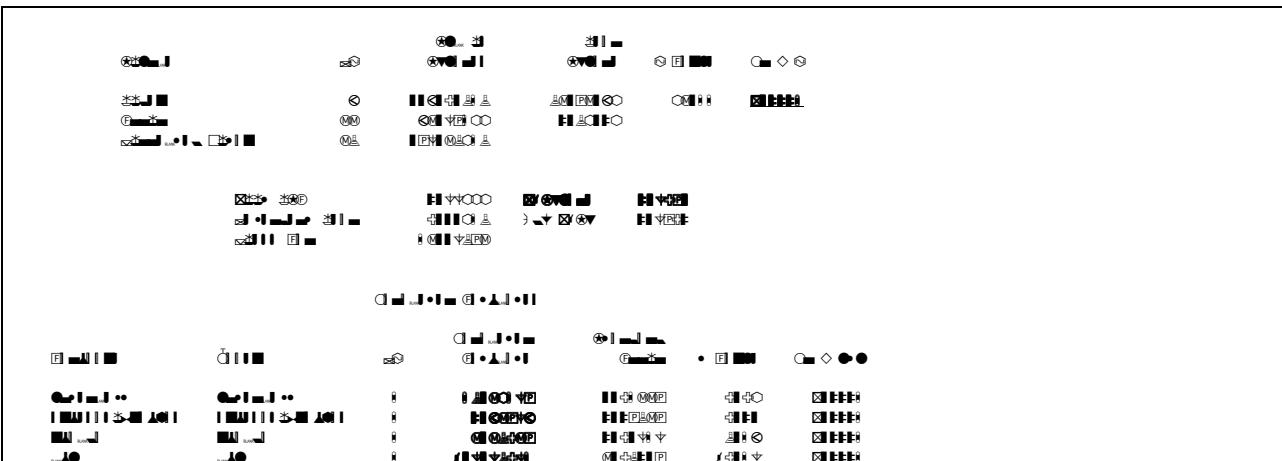
Reikšmingi kintamieji, D01 eilė
liamda, miu, sviesafo_laikas

Remiantis 2.4.1 lentelės gautais rezultatais matome, kad *D01* eilės ilgis priklauso nuo trijų kintamųjų: *liamda, miu, sviesafo_laikas*. Toliau sudarome modelį ir gauname (2.4.2 lentelė):

Patikimumo analizė

2.4.2 lentelė

Patikimumo analizė



Hipotezės apie regresijos lygties koeficientų lygybę 0 atmetamos. Apibrėžtumo koeficientas lygus 0.8652. Vadinas, 86.52% sklaidos apie vidurkį galime paaškinti tiesine regresija tarp kintamųjų, o likusi yra nepaaškinama sklaidos dalis. Gauname lygtį:

Skaičius skliaustose yra parametru t-reikšmė.(jeigu t- reikšmė yra moduliui mažiau už 2, tai nepriklausomos kintamasis yra nereikšmingas ir jį galime į lygtį neitraukti)

$R^2 = 0.8652$, F- reikšmė = 94.11.

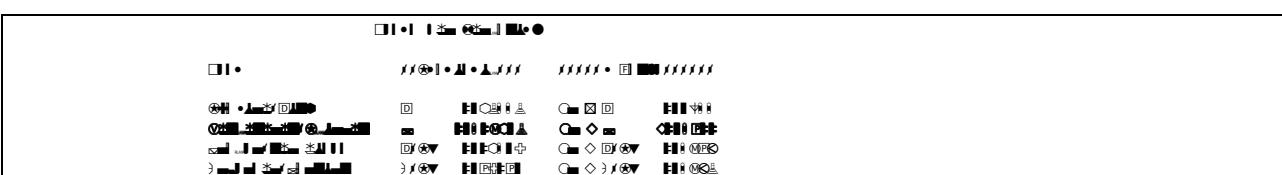
Toliau tiriame gauto tiesinės regresijos modelio adekvatumą. Tiesinės regresijos analizės rezultatai yra korekтиški tik tuo atveju, jei tenkinamos prielaidos:

- 1) y_i nuo \hat{y}_i grafikas turi būti tiesė, sudaranti 45laipsnių kampą su y_i ašimi;
 - 2) prognozės paklaidos(arba standartizuotos paklaidos) grafikas nuo y įverčio turi svyruoti apie nulį su pastovia amplitude.
 - 3) prognozės paklaidos(arba standartizuotos paklaidos) nuo x reikšmių turi svyruoti apie nulį su pastovia amplitude.
 - 4) paklaidos skirstinys normalusis;

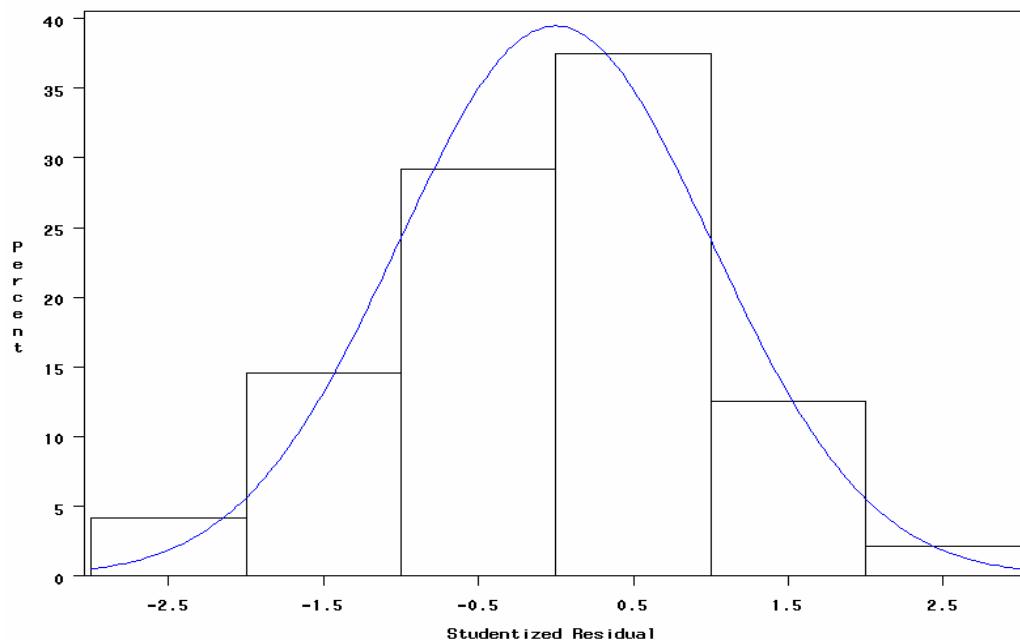
Tikriname ar e_i pasiskirstės pagal normalujį dėsnį. Gauti rezultatai pateikti 2.4.3 lentelėje:

2.4.3 lentelė

Paklaidų tikrinimas



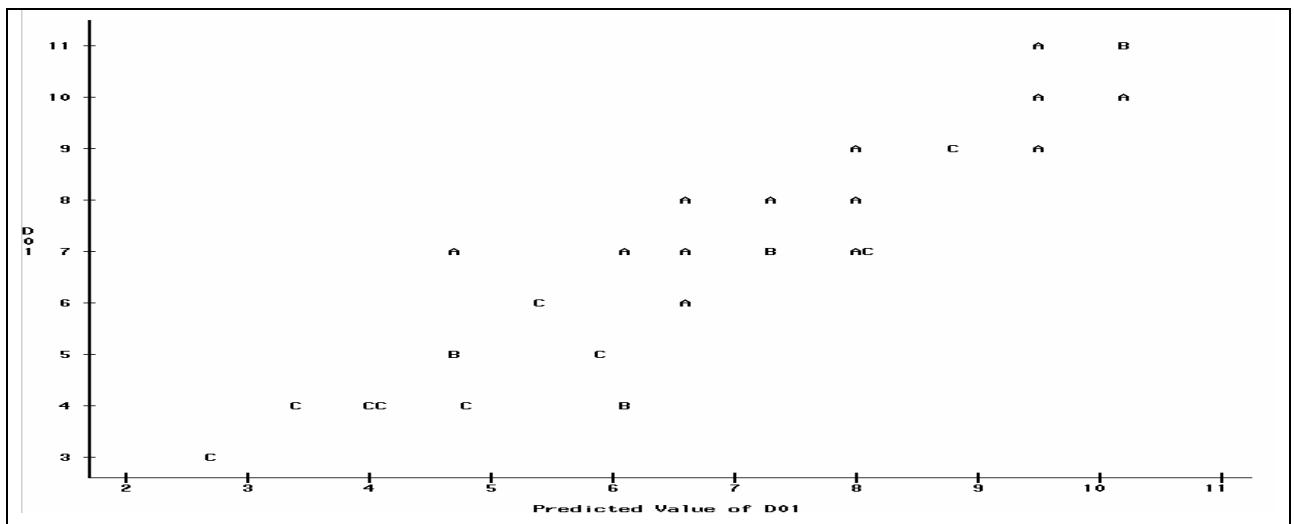
Paklaidų pasiskirstymas pagal Normalujį desni



2.4.1 pav. Paklaidų e_i Normalusis skirstinys

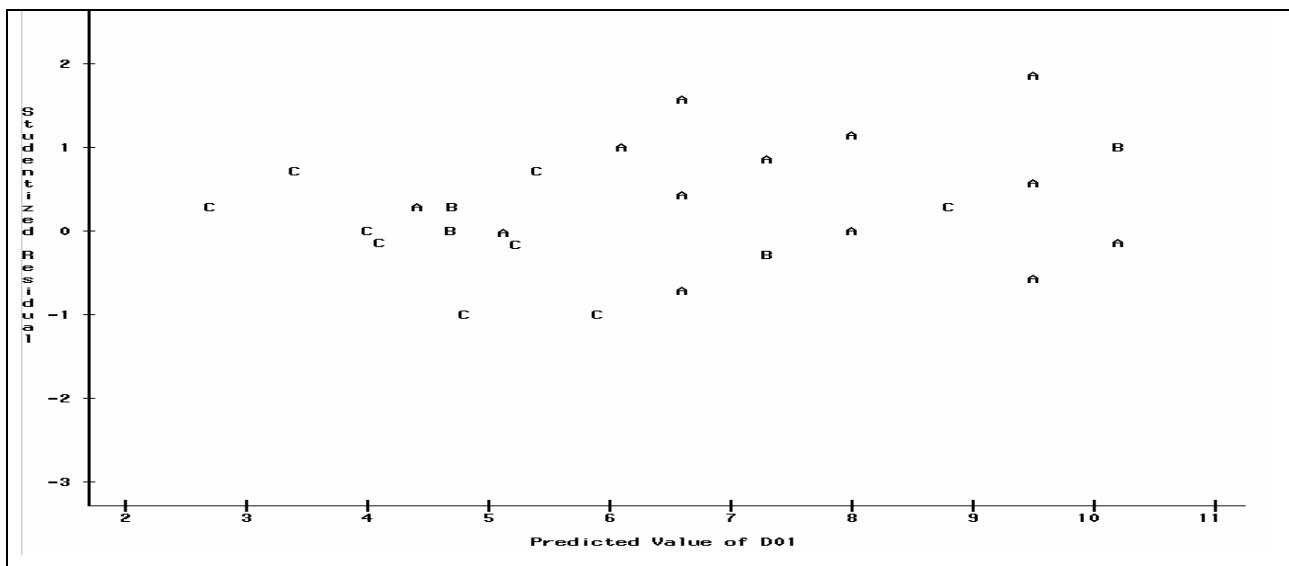
Iš 2.4.3 lentelės matome, kad Kolmogorovo – Smirnovo statistika, jog paklaidos e_i yra pasiskirsčiusios pagal normalujį skirstinį, neprieštarauja.

Likusias prielaidas patikriname grafiškai.



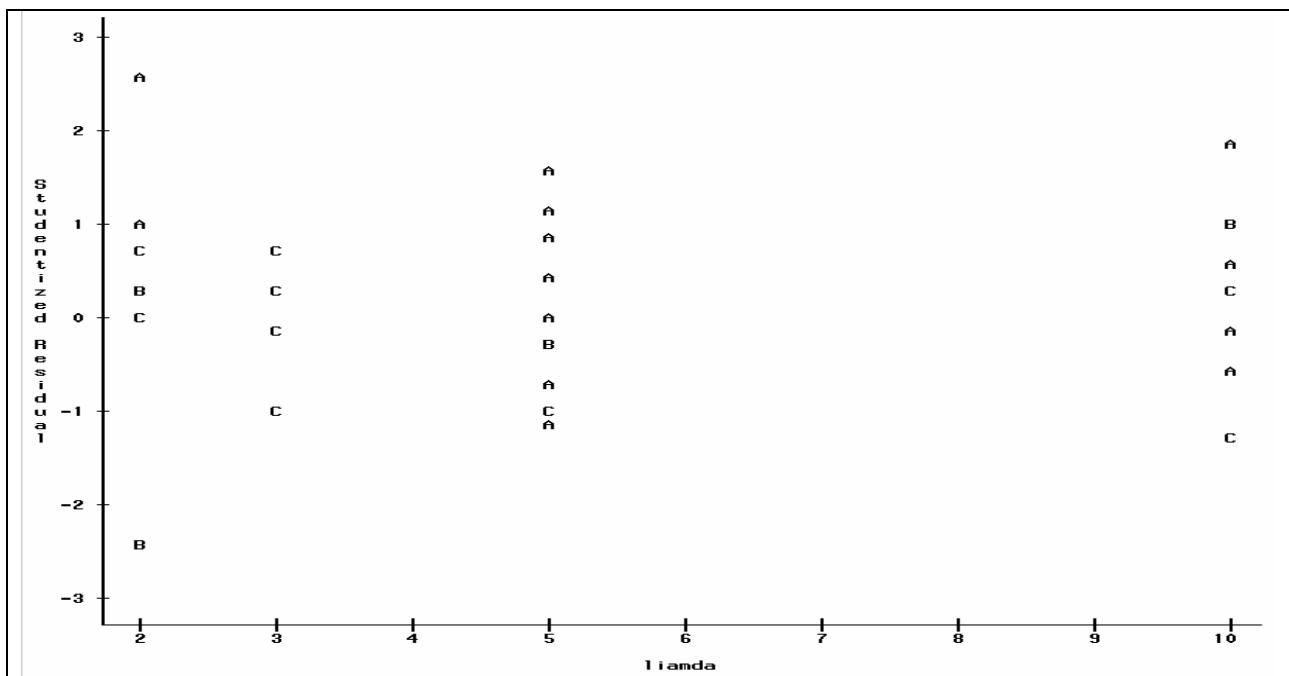
2.4.2 pav. $D01$ ir $\hat{D}01$ įverčio grafikas

2.4.2 pav. pavaizduotas priklausomas kintamasis ir jo įvertis. Matome, kad pirmas tiesinės regresijos adekvatumo reikalavimas yra išpildytas. Priklausomas kintamasis ir jo įvertis sudaro tiesę ir 45 laipsnių kampą su y ir x ašimis (D01 ir $\hat{D}01$).



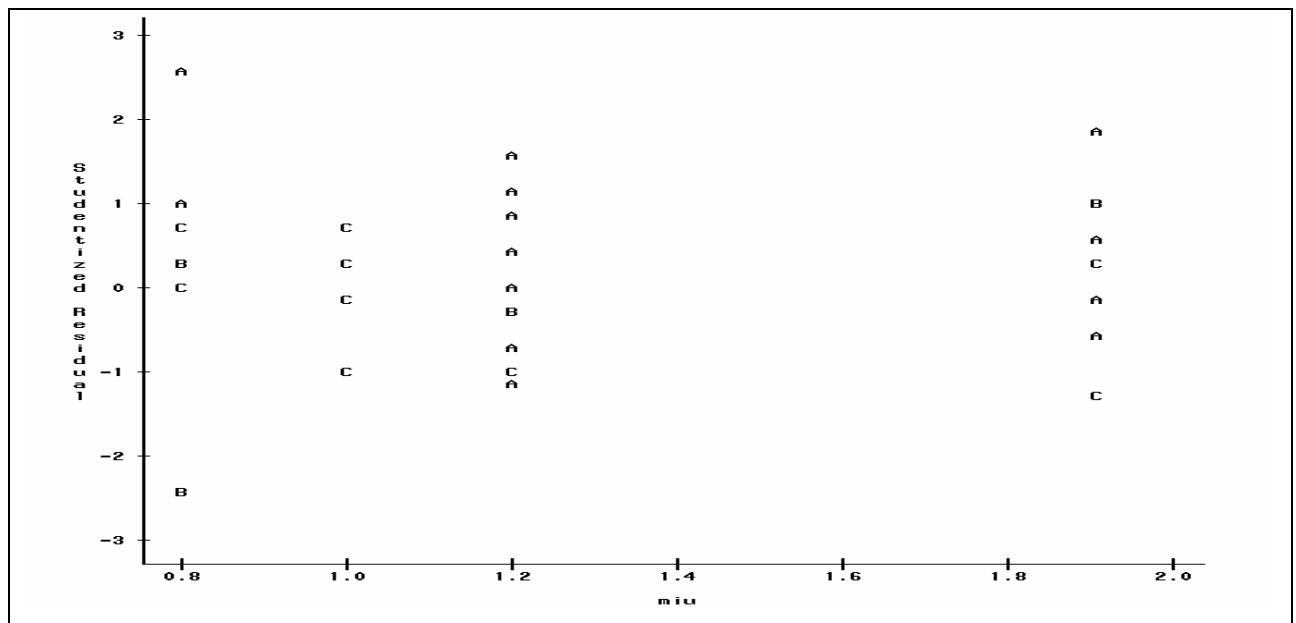
2.4.3 pav. Standartinės paklaidos ir $\hat{D}01$ įverčio grafikas

2.4.3 pav. pavaizduotas standartinės paklaidos priklausomybė nuo priklausomo kintamojo $\hat{D}01$ įverčio. Tenkinamas antras tiesinės regresijos adekvatumo reikalavimas.



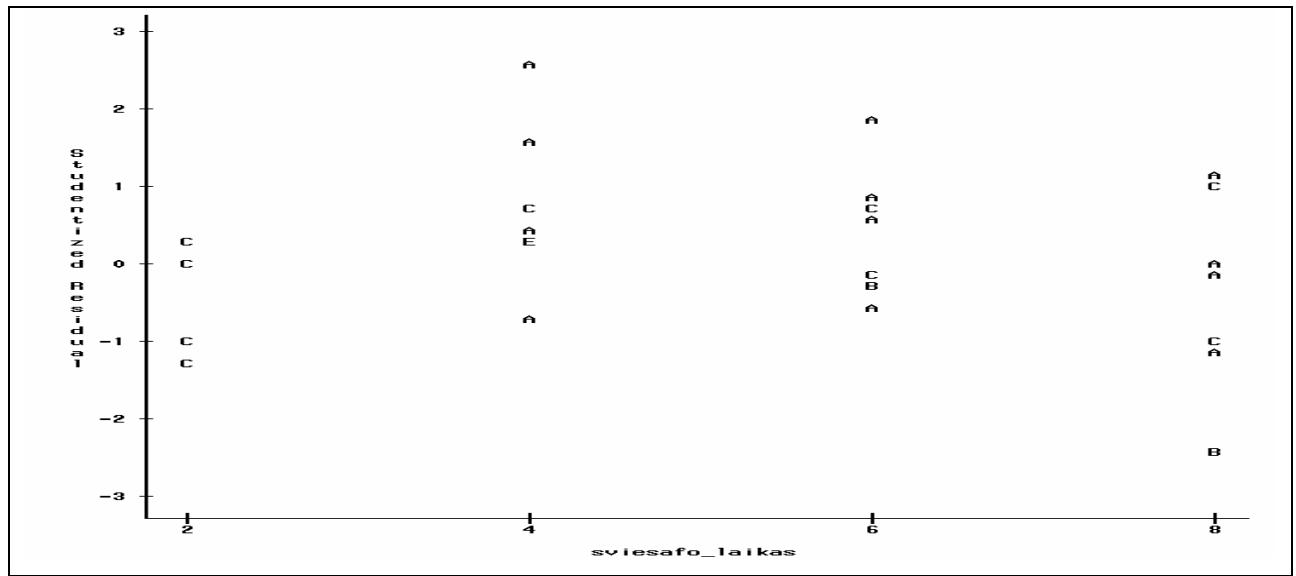
2.4.4 pav. Standartinės paklaidos ir liamda grafikas

2.4.4 pav. pavaizduotas standartinės paklaidos priklausomybė nuo liamda grafikas. Nėra tenkinamas trečiasis tiesinės regresijos adekvatumo reikalavimas.



2.4.5 pav. Standartinės paklaidos ir miu grafikas

2.4.5 pav. pavaizduotas standartinės paklaidos priklausomybė nuo *liamda* grafikas. Nėra tenkinamas trečiasis tiesinės regresijos adekvatumo reikalavimas.



2.4.6 pav. Standartinės paklaidos ir šviesoforo laikas grafikas

2.4.6 pav. pavaizduotas standartinės paklaidos priklausomybė nuo *liamda* grafikas. Nėra tenkinamas trečiasis tiesinės regresijos adekvatumo reikalavimas.

Analogiškai gaunamos ir kitos lygybės. Rezultatai pateikti prieduose. Čia pateikiame tik galutinius gautos tiesinės regresijos modelius (2.4.4 lentelė).

Atlikus tyrimą nustatome, kad $D02$ eilės ilgis nepriklauso nuo kintamųjų. $D02$ yra nereikšmingas (p reikšmė $0.064 > 0.05$), vadinas priimta hipotezė, kad koeficientai prie jo yra lygūs nuliui.

2.4.4 lentelė

Tiesinės regresijos modeliai

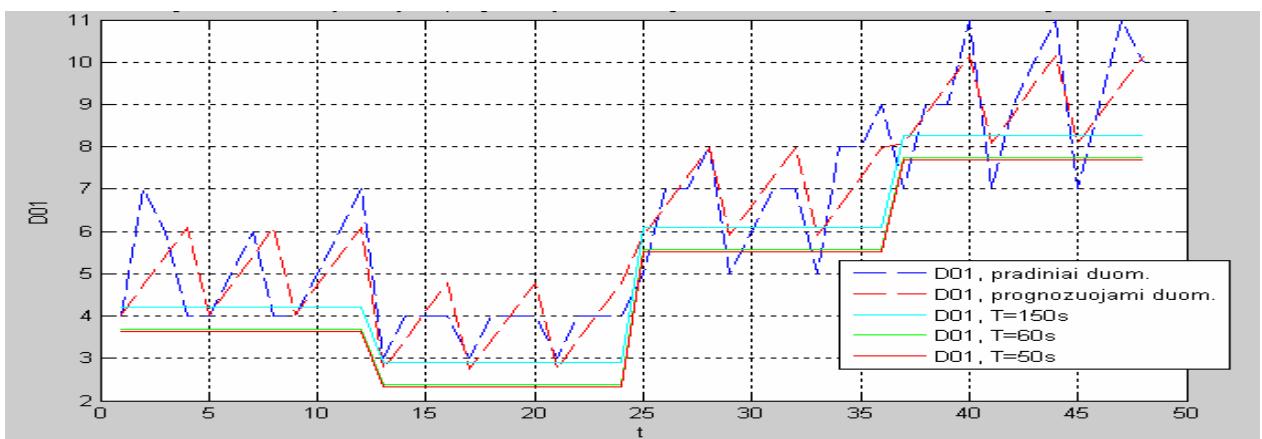
R^2	F-reikšmė	Eilė	Taikymas
0.8652	94.11	$D01_i = 17.49185 + 0.34583\text{sviesaf}_i \text{laikas}_i +$ (6.02) $+4.47645\text{liamda}_i - 28.87681\text{miu}_i .$ (7.13) (−6.18)	Adekvatumo prielaidos netenkinamos, modelį taikome nekorektiškai.
0.8652	94.11	$D03_i = 15.49185 + 4.47645\text{liamda}_i -$ (7.13) $-28.87681\text{miu}_i + 0.34583\text{sviesaf}_i \text{laikas}_i .$ (−6.18) (6.02)	Adekvatumo prielaidos tenkinamos, modelį taikome korektiškai
0.7892	84.25	$D04_i = -5.84182 + 7.38788\text{miu}_i + 0.3\text{sviesaf}_i \text{laikas}_i .$ (12.68) (2.78)	Adekvatumo prielaidos netenkinamos, modelį taikome nekorektiškai.
0.6131	72.58	$D05_i = 1.40899 + 0.6557\text{liamda}_i .$ (8.52)	Adekvatumo prielaidos netenkinamos, modelį taikome nekorektiškai.
0.8265	69.86	$D06_i = 11.34330 + 4.07971\text{liamda}_i +$ (3.89) $+0.29853\text{sviesaf}_i \text{laikas}_i - 23.22464\text{miu}_i .$ (3.08) (−2.98)	Adekvatumo prielaidos netenkinamos, taigi modelį taikome nekorektiškai.
0.7541	69.01	$D07_i = 17.22101 + 4.47646\text{liamda}_i - 28.87681\text{miu}_i .$ (5.34) (−4.63)	Adekvatumo prielaidos netenkinamos, taigi modelį taikome nekorektiškai.
0.8947	124,61	$D09_i = 19.88949 + 5.65761\text{liamda}_i - 36.81159\text{miu}_i +$ (8.89) (−7.78) $+ 0.29167\text{sviesaf}_i \text{laikas}_i .$ (5.01)	Adekvatumo prielaidos netenkinamos, taigi modelį taikome nekorektiškai.
0.7467	66.32	$D10_i = 16.48551 + 4.717391\text{liamda}_i - 29.02174\text{miu}_i .$ (4.18) (−3.46)	Adekvatumo prielaidos netenkinamos, taigi modelį taikome nekorektiškai.
0.7332	126.41	$D11_i = -1.18939 + 3.18182\text{miu}_i .$ (11.24)	Adekvatumo prielaidos netenkinamos, taigi modelį taikome nekorektiškai.

0.8873	115.52	$D12_i = 15.53351 + 4.476451 \text{liamda}_i - 28.87681 \text{miu}_i +$ (7.92) (-6.87) + 0.33750sviesafo_laikas _i . (6.53)	Adekvatumo prielaidos tenkinamos, modeli taikome korektiškai.
--------	--------	--	--

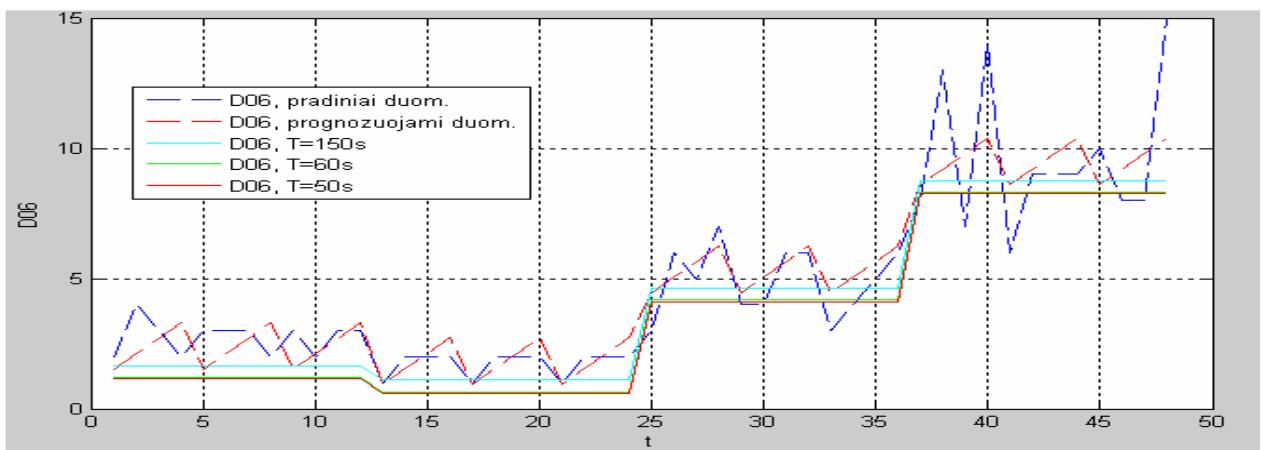
Gavome eilę lygybių pagal kurias galima prognozuoti eilių susidarymus K. Mindaugo pr. – Birštono g-vės kelio juostose. Iš gautų rezultatų matome (žr. 2 Priedas, 2 lentelė), kad prognozuojami eilių ilgiai nedaug skiriasi nuo tikrujų rezultatų (žr. 2 Priedas, 1 lentelė). Taigi, modeliai sudaryti teisingai.

Didinant srauto intensyvumą, eilės ilgis eismo juostoje didėja eksponentiškai. Esant dideliam automobilių srautui, mažiausiai ilgiai K. Mindaugo pr. - Birštono g-vėje susidaro, kai šviesoforo degimo laikas yra 50- 60 sekundžių piko metu (žr. Priedas 2, 3,4 lentelės).

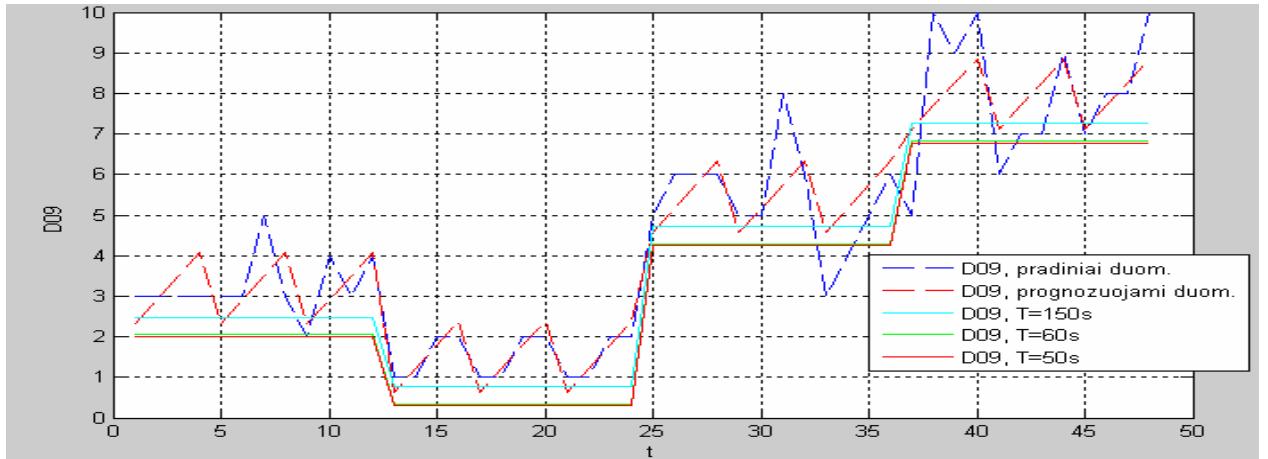
Gautus rezultatus pateikiame grafiškai, 2.4.7-2.4.9 pav.:



2.4.7 pav. Eilių ilgiai D01 eismo juostoje piko metu



2.4.8 pav. Eilių ilgiai D06 eismo juostoje piko metu



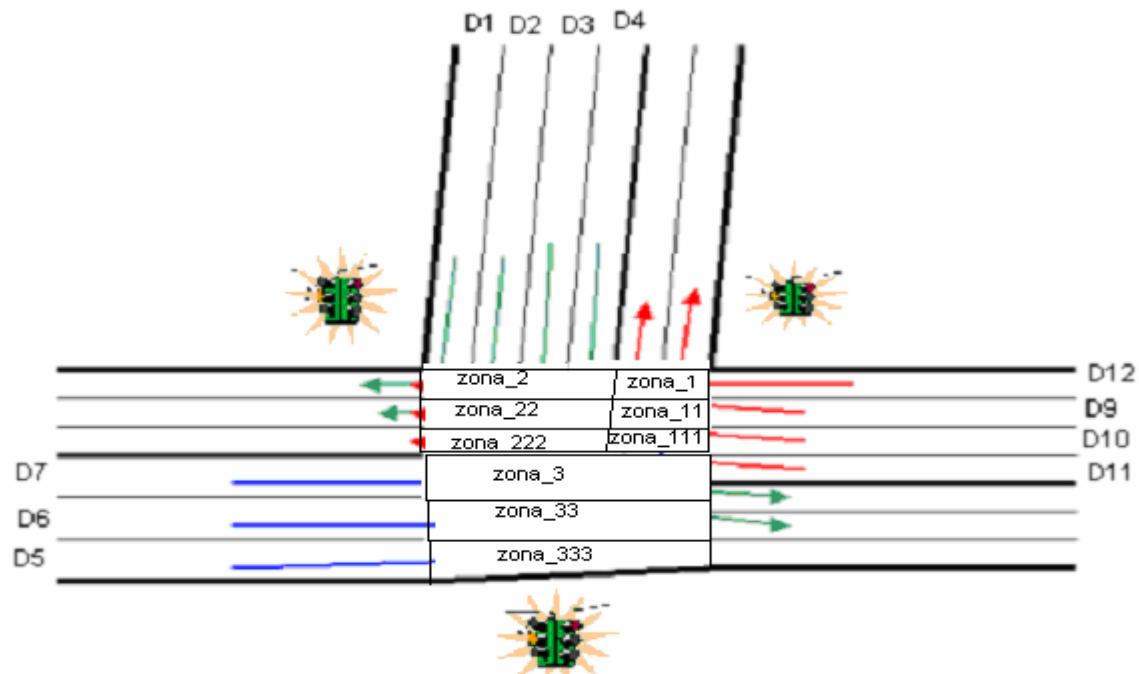
2.4.9 pav. Eilių ilgiai D09 eismo juostoje piko metu

Grafiškai pavaizduoti susidariusių eilių ilgiai (2.4.7-2.4.9 pav.), kai šviesoforo degimo laikas yra 50s – raudona kreivė; 60s – žalia kreivė; 150s – melsva kreivė. Mėlyna punktyrinė kreivė žymi susidariusių eilių ilgius, gautus programiniu paketu Arena 3.0 (akademinė versija), o raudona punktyrinė kreivė – prognozuojami eilės ilgiai taikant tiesinės regresijos modelį. Remiantis grafiniais prognozavimo rezultatais matome, kad mažiausiai eilių ilgiai susidaro, kai šviesoforo degimo laikas yra 50 – 60 sekundžių

3. PROGRAMINĖ RELIZACIJA IR INSTRUKCIJA VARTOTOJUI

Mikroskopiniam eismo srautui modeliuoti K. Mindaugo pr. – Birštono g-vės sankryžai taikome programą padarytą „Arena 3.0“ (akademinė versija) programiniu paketu. Mikroskopinio eismo srauto imitacijos modeliavimo principas pateiktas 2.3 skyrelyje.

Sistemos analizė. Susidaro vienuolika atvykstančių mašinų srautų. Sankryžos pravažiavimo schema nepriklauso nuo to, iš kurio kelio atvažiuoja transporto priemonė ir kur nori važiuoti. Šioje sistemoje resursas dėl kurio konkuruoja mašinos – vieta sankryžoje, todėl tikslinga ją padalinti į pravažiuojamas zonas.



3.1 pav. Trišalės K. Mindaugo pr. – Birštono g-vės sankryžos zonas

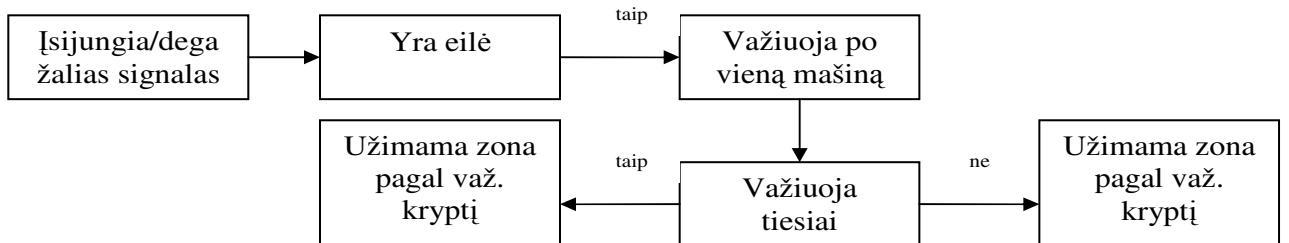
Zonoje vienu metu gali būti tik viena mašina, todėl jei pravažiuojamos zonas yra užimtos arba dega neleistinas šviesoforo signalas, mašinos stoja į eilę. Eilėje jos stovi iki to momento, kol yra patenkinamos sąlygos: prieš ją nėra mašinų (ji gali būti prie šviesoforo pirmoji), užsidega leistinas šviesoforo signalas, reikalingos pravažiuojamos zonas atlaisvinamos.

Mašinų važiavimo algoritmai. Mašinos važiavimo per sankryžą algoritmą iki galinės maršruto stotelės, įvertinant visas galimas kliūties, galime suskaidyti į tris etapus:

- mašinos važiavimo iki sankryžos;
- mašinos važiavimo iš eilės įsijungus/degant žaliam šviesoforo signalui;

- mašinos važiavimo iki galinės stotelės, atlaisvinus pravažiuojamas zonas.

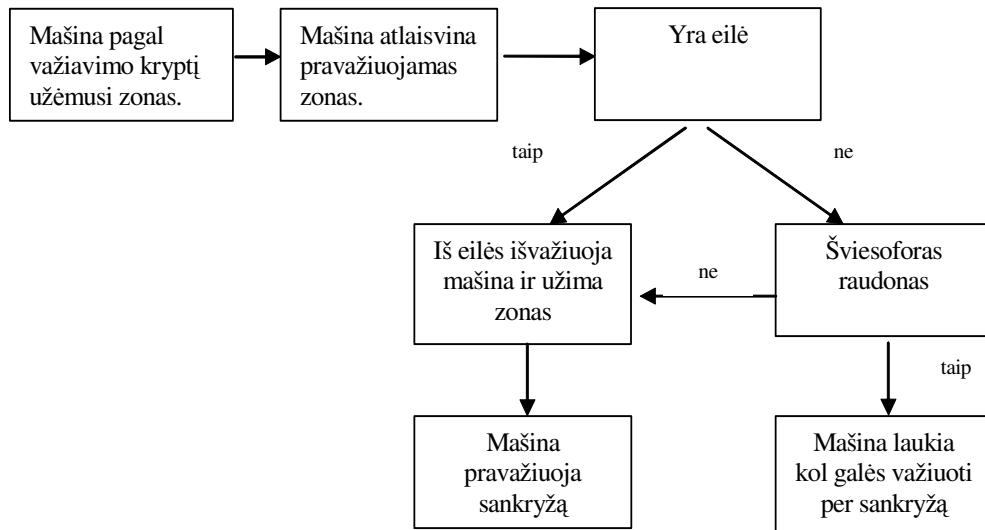
Kelyje dega šviesoforas, turintis du signalus: raudoną ir žalią. Mašina gali pravažiuoti sankryžą degant tik žaliam šviesoforo signalui. Vaizduokime algoritmu važiavimo per sankryžą įsijungus/degant šiam leistinam šviesoforo signalui:



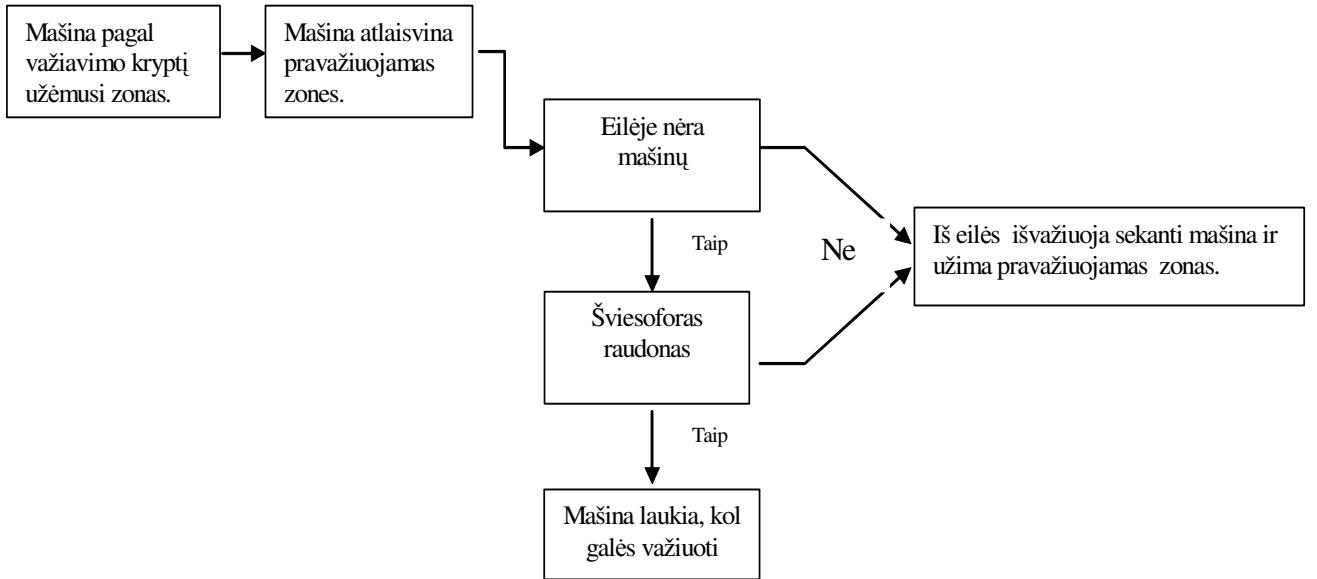
3.2 pav. Mašinos važiavimo iš eilės įsijungus/degant žaliam šviesoforo signalui algoritmo algoritmas

Mašinai pravažiavus sankryžą (atlaisvinus pravažiuojamas zonas) tikriname:

- ar kelyje yra mašinų eilė;
- ar dar dega žalias šviesoforo signalas.



3.3 pav. Mašinos važiavimo iki galinės maršruto stotelės algoritmas



3.4 pav. Mašinos važiavimo algoritmas atlaisvinus pravažiuojamas zonas

Modelyje generuojami vienuolika atvykstančių mašinų srautai. Jiems sukurti naudojami elementai **ARRIVE**, kurių parametrai yra šie:

Enter Data - >Station	x_pradzia, Indeksas rodo kelio numerį.
Batch Size	1
Time Between	Mašinų srautas generuojamas eksponentiniu dėsniu ($\text{Expo}(x)$).
Station	Nurodoma tolimesnė kelio stotelė prie sankryžos – sustoti_x.
Route Time	Nurodoma, kiek trunka nuvažiuoti iki atitinkamos tarpinės stotelės – pvz. 3 sekundes.

Sankryžoje zonom vaizduoti naudojami **RESOURCE** elementai. Juose nurodoma:

Resource	zona_x. Indeksas rodo kelio numerį.
Capacity Type	Capacity.
Capacity	Zonoje vienu metu gali būti tik viena mašina, todėl įrašome 1.

Mašina, įvažiuodama į sankryžą, užima pagal važiavimo kryptį atitinkamas zonas. Šiam momentui fiksuoti, naudojame elementus **SEIZE**. Juose nurodoma:

Priority	Pirmenybė suteikiama pirmai mašinai, todėl įrašome 1.
----------	---

Resource ID	zona_x
Number of Units	1

Mašina, pravažiuodama sankryžą, atlaisvina pagal važiavimo kryptį užimtas zonas. Šiam momentui fiksuoti, naudojame elementus **RELEASE**. Juose nurodoma:

Resource Name	Resource
Resource	zona_x
Release Quantity	1

Kiekviename kelyje esant kliūtimis (dega neleistinas šviesoforo signalas arba užimtos pravažiuojamos zonas), susidaro mašinų eilės. Joms vaizduoti naudojami elementai **QUEUE**. Elementuose nurodoma:

Queue Name	eile_x arba eile_x, arba eile_x. Indeksas rodo kelio numerį.
Queue Characteristics	# in Queue Statistics.
Ranking Rule	Nurodoma tvarka, kuria išvažiuoja mašinos iš eilės, (FIFO) principu.

Stotelėms vaizduoti sankryžoje naudojame elementus **ENTER**, kuriuose nurodoma:

Station	Stotelės pavadinimai prie sankryžos: sustoti_x . Stotelės pavadinimai už sankryžos: atlaisvinti_x. Indeksai rodo iš kurio ir i kurį kelią atvažiuoja mašina.
---------	---

Elementai **LEAVE** naudojami, kai norime vaizduoti mašinos važiavimo iš stotelės, esančios prie sankryžos (sustoti_x) i stotelę, esančią už sankryžos (atlaisvinti_x) ir iš stotelės, esančios už sankryžos, i galinę maršruto stotelę (x_pabaiga). Juose nurodoma:

Leave Data ->From Station	sustoti_x
To Station	atlaisvinti_x

Route Time	Važiavimo trukmė
Leave Data ->From Station	atlaisvinti_x
To Station	x_pabaiga
Route Time	Važiavimo trukmė

Galinėms kiekvieno maršruto stotelėms vaizduoti naudojame elementus **DEPART**. Juose nurodoma:

Station	x_pabaiga. Indeksas rodo kelio numerį.
---------	--

Elementas **SIMULATE** generuoja modelio veikimą.

Mikroskopinio eismo srauto modelio realizaciją programoje Arena 3.0 žiūrėkite prieduose (3 Priedas). Visi kiti skaičiavimai, kurie buvo reikalingi darant šį darbą, buvo atlikti Matlab 7.0 ir SAS programiniais paketais (2 Priedas).

IŠVADOS

1. Sudarytas mikroskopinio eismo srauto matematinis modelis ir nustatyta, kad mikroskopinis eismo srautas yra stabilus, kai $kT < 0.5$, esant mažiemis greičių svyrapimams. Teoriniai ir praktiniai rezultatai sutampa.
2. Nustatyta, kad pagrindinėse K. Mindaugo pr. – Birštono g-vės eismo juostose mikroskopinis eismo srautas yra paprasčiausias ir puasoninis.
3. Naudojantis programiniu paketu „Arena 3.0” sukurtas imitacinis K. Mindaugo pr. – Birštono g-vės sankryžos modelis. Programų paketu šiame modelyje galima keisti visus sankryžos modelio parametrus: ateinantį paraiškų srautą λ , šviesoforo darbo ciklus, transporto priemonių judėjimo greičius ir t.t.
4. Sudarytas tiesinės regresijos modelis. Nustatyti labiausiai priklausomi kintamieji, įtakojantys transporto priemonių eilių susidarymą K. Mindaugo pr. – Birštono g-vėje. Mažiausias transporto priemonių skaičius eismo juostose K.Mindaugo pr. – Birštono g-vėje susidaro, kai šviesoforo degimo laikas yra 50- 60 sekundžių.

REKOMENDACIJOS

1. Mikroskopinių eismo srautų modelio rezultatai naudotini optimizuojant Kauno miesto sankryžos šviesoforų Mindaugo pr.-Birštono g-vės darbo veikimą, minimizuojant transporto priemonių eilių susidarymą piko metu.
2. Modelis taikytinas, su nesudėtingomis korekcijomis, ir kitų sankryžų eismo srautų analizei ir optimizavimui, gautų rezultatų lyginimui, aukštesniojo lygio eismo srautų modelių sąlygų nustatymui bei analizuojant Kauno miesto tinklo pralaidumą.
3. Šio darbo tēstinumas reikalingas įvairių tipų sankryžoms Kauno mieste, eismo srautų intensyvumų bei jų charakteristikų analizei, įdiegiant koordinuotą eismo reguliavimo šviesoforais sistemą, mažinant eismo kamščių skaičių bei trukmę.

LITERATŪRA

1. Acha-Daza, J. A. and Hall F.L. Application of Catastrophe Theory to Traffic Flow Variables. *Transport Research – B*, 28B(3). Elsevier Science Ltd., 1994, p. 235-250.
2. Bender, J. G. An Overview of Systems Studies of Automated Highway Systems. *IEEE Transactions on Vehicular Technolofy* (40 (I) . IEEE Vehicular Technology Society, 1991, p 82 –99.
3. Chandler, F.E, R. Herman, and E. W. Montroll. *Traffic Dynamics: Studies in Car Following, Operations Research*, 1958, p. 165 – 184.
4. Shladover, S. E.,C. A. Desoer, J. D. Hedrick, Mtomizuka, J. Walrand, W. B. Zhang, D. H. McMahon, H. Peng, S. Shiekholeslam and N. McMKeown. Automated Vehicle Control Developments in the PATH Program. *IEEE Transactions on Vehicular Technology* (40(I)), 1991, p 114-130.
5. Zeeman, E. C. *Catastrophe Theory. Selected Papers 1972–1977.* Addison-Wesley, London,1977.
6. Pripogine, I., and Herman R. *Kinematic Theory of Vehicular Traffic.* American Elsevier Publishing Co., New York, 1971.
7. Helbing, D. (1997c) Fundamentals of traffic flow. *Physical Review E* 55, p 3735-3738.
8. R. W. Rothery, Car following Models, in : *Traffic Flow Theory*, N. Gartner, C. J. Messer and A. K. Rathi (eds.) (Transportation Research Board, Special Report, 1992, Chap 4.
9. Pranevičius H., Valakevičius E. *Markovo procesų teorijos taikymas sistemoms modeliuoti.* Kaunas: Technologija, 1991, 90p.
10. Wilhelm L., *Introduction to the Theory of Traffic flow.* Berlin, 1988.
11. Wang R., H. J. Ruskin. Modeling traffic flow at a single – lane urban roundabout. *Comp. Phys. Commun.*, 2003, 147:570 –576.
12. Aksomaitis A. *Tikimybių teorija ir statistika.* Kaunas: Technologija, 2000, p. 345.
13. SAS OnlineDoc®.-SAS Institute Inc., Cary, NC, 2002 m.
14. Elliott R.J. *Learning SAS on the computer lab.-Belmont: An International Thompson Publishing Company*, 1995, p.184.
15. Gazis D. C., R. Herman, R. W. Rothery. *Analytical Methods in Transportation: Mathematical Car – Following Theory of Traffic Flow.* Journal Engineering Mechanics division, ASCE Proc. Paper 3724 89 (Paper 372), 1963, p. 29-46.

16. EUROPOS KOMISIJA, Europos transporto politika 2010-iesiems metams – laikas priimti sprendimą, Baltoji knyga, 2001, p. 108.
17. Советов Б.Я., Яковлев С.А. Моделирование систем. Москва: Наука, 1999. - С.205-300.
18. Ilgakojytė-Bazarienė J., Markšaitis D. Application of equilibrium traffic flow model. Transport Means – 2005:proceedings of the 9th international conference, October 20-21, 2005, Kaunas University of Technology, Lithuania. – ISSN 1822-296X. Kaunas, p59-61.

1 PRIEDAS. DUOMENYS

Pradinių duomenų pavyzdys. K. Mindaugo pr. – Birštono g-vės eismo juostomis pravažiuojančių transporto priemonių skaičiai, fiksuoti kas 5 min. (D01, D02, D03, D04, D05, D06, D07, D09, D10, D11, D12 – eismo juostos)

1 lentelė

Pradinių duomenų pavyzdys

Davikliai	D01	D02	D03	D04	D05	D06	D07	D09	D10	D11	D12
04.18.06:45	11	1	5	2	2	10	7	3	3	0	5
04.18.06:50	25	0	4	2	1	12	7	6	2	0	2
04.18.06:55	8	0	6	3	0	8	3	4	3	1	7
04.18.07:00	15	0	4	2	0	20	7	6	1	0	7
04.18.07:05	19	0	3	7	1	8	3	7	6	0	12
04.18.07:10	14	0	5	6	11	19	10	5	4	2	7
04.18.07:15	17	0	5	4	4	9	4	8	3	0	8
04.18.07:20	13	0	6	5	6	13	6	6	5	0	5
04.18.07:25	21	0	7	4	6	18	10	4	2	1	5
04.18.07:30	19	1	8	5	6	22	14	4	4	0	9
04.18.07:35	11	1	5	5	6	16	5	6	3	0	12
04.18.07:40	17	0	4	6	11	13	9	6	8	1	14
04.18.07:45	19	0	5	5	8	22	11	7	2	0	10
04.18.07:50	31	0	4	6	7	19	13	6	3	2	10
04.18.07:55	20	0	6	6	7	15	11	13	8	2	17
04.18.08:00	21	0	8	5	13	23	12	12	5	1	17
04.18.08:05	19	1	4	3	17	24	15	10	9	2	20
04.18.08:10	26	0	5	3	15	15	10	5	8	0	12
04.18.08:15	24	0	4	2	14	12	5	6	5	1	21
04.18.08:20	36	0	1	2	8	25	10	10	4	1	12
04.18.08:25	24	0	4	5	9	32	18	10	7	0	11
04.18.08:30	31	0	7	11	10	31	17	11	10	2	11
04.18.08:35	25	0	9	7	10	27	21	15	16	4	24
04.18.08:40	22	0	7	6	11	34	21	12	3	2	17
04.18.08:45	35	0	7	8	15	30	16	11	6	3	25
04.18.08:50	27	0	4	5	16	29	14	12	5	4	21
04.18.08:55	35	0	11	7	22	31	16	9	5	5	13
04.18.09:00	36	0	3	3	11	38	21	16	9	4	22
04.18.09:05	25	0	6	5	7	37	23	18	7	2	29
04.18.09:10	30	0	6	5	13	35	19	8	5	2	14
04.18.09:15	27	0	5	5	14	52	31	10	9	1	13
04.18.09:20	40	0	7	7	9	35	20	16	8	2	19
04.18.09:25	41	0	11	7	17	33	13	8	5	3	9
04.18.09:30	30	0	5	4	25	31	15	8	8	7	19
04.18.09:35	54	0	3	8	21	40	19	7	7	4	17
04.18.09:40	35	0	8	11	16	41	26	14	6	4	22

2 PRIEDAS. GAUTI DUOMENYS IR REZULTATAI

Atlikus mikroskopinę eismo srauto modeliavimą K.Mindaugo pr. – Birštono g-vės programiniu paketu Arena 3.0 gauti tokie duomenys(D01, D02, D03, D04, D05, D06, D07, D09, D10, D11, D12 – transportų priemonių skaičius eismo juosteje):

1 lentelė

Gauti duomenys programiniu paketu Arena 3.0

D01	D02	D03	D04	D05	D06	D07	D09	D10	D11	D12	greitis	sviesaforo_laikas	liamda	miu
4	0	2	1	4	2	5	3	3	0	3	50		2	2 0,8
7	0	5	3	3	4	2	3	4	1	3	50		4	2 0,8
6	0	4	2	4	3	2	3	4	0	3	50		6	2 0,8
4	0	2	1	3	2	4	3	4	1	3	50		8	2 0,8
4	0	2	2	4	3	3	3	1	1	3	47		2	2 0,8
5	0	3	2	3	3	2	3	2	0	3	47		4	2 0,8
6	0	4	2	6	3	2	5	2	0	4	47		6	2 0,8
4	0	2	1	1	2	4	3	2	1	2	47		8	2 0,8
4	1	2	2	2	3	2	2	2	1	2	45		2	2 0,8
5	0	3	1	2	2	3	4	1	1	3	45		4	2 0,8
6	0	4	2	2	3	4	3	2	2	4	45		6	2 0,8
7	0	5	2	1	3	5	4	3	1	5	45		8	2 0,8
3	0	1	2	2	1	2	1	1	2	1	50		2	3 1
4	0	2	5	2	2	1	1	2	2	2	50		4	3 1
4	0	2	4	2	2	2	2	2	2	2	50		6	3 1
4	0	2	2	1	2	2	2	2	3	2	50		8	3 1
3	0	1	2	2	1	2	1	2	3	1	47		2	3 1
4	0	2	3	2	2	1	1	1	1	3	47		4	3 1
4	0	2	4	2	2	2	2	2	3	2	47		6	3 1
4	0	2	2	3	2	2	2	3	1	2	47		8	3 1
3	0	1	2	6	1	1	1	1	1	1	45		2	3 1
4	0	2	3	4	2	2	1	1	2	2	45		4	3 1
4	0	2	4	4	2	2	2	2	2	2	45		6	3 1
4	0	2	5	3	2	2	2	1	3	2	45		8	3 1
5	0	3	1	4	3	5	5	2	3	3	50		2	5 1,2
7	0	5	2	4	6	3	6	3	3	5	50		4	5 1,2
7	0	5	2	4	5	5	6	5	4	5	50		6	5 1,2
8	0	6	6	3	7	3	6	8	3	6	50		8	5 1,2
5	0	3	5	4	4	6	5	6	4	3	47		2	5 1,2
6	1	4	4	7	4	4	5	3	3	4	47		4	5 1,2
7	0	5	5	8	6	5	8	4	3	5	47		6	5 1,2
7	0	5	6	7	6	3	6	5	4	5	47		8	5 1,2
5	0	3	3	4	3	5	3	6	3	3	45		2	5 1,2
8	0	6	4	5	4	6	4	5	3	6	45		4	5 1,2
8	0	6	5	6	5	6	5	10	3	6	45		6	5 1,2
9	0	7	6	7	6	7	6	9	3	7	45		8	5 1,2
7	0	5	8	6	8	5	5	10	4	5	50		2	10 1,9
9	0	7	14	11	13	7	10	6	4	7	50		4	10 1,9
9	0	7	8	10	7	7	9	7	4	7	50		6	10 1,9
11	0	9	14	9	14	9	10	7	5	9	50		8	10 1,9

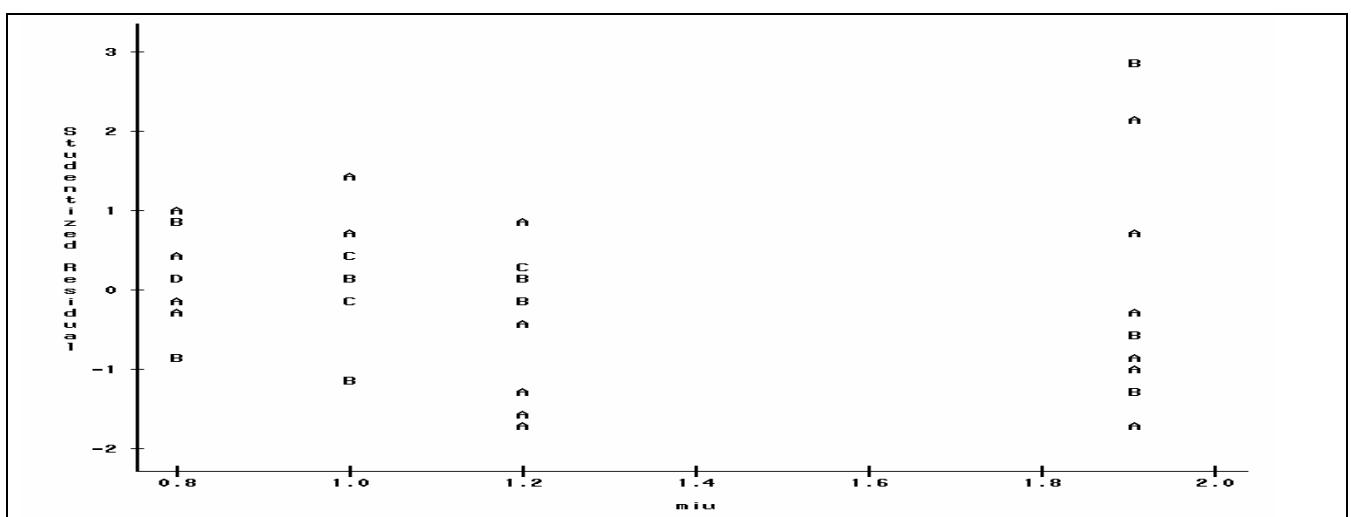
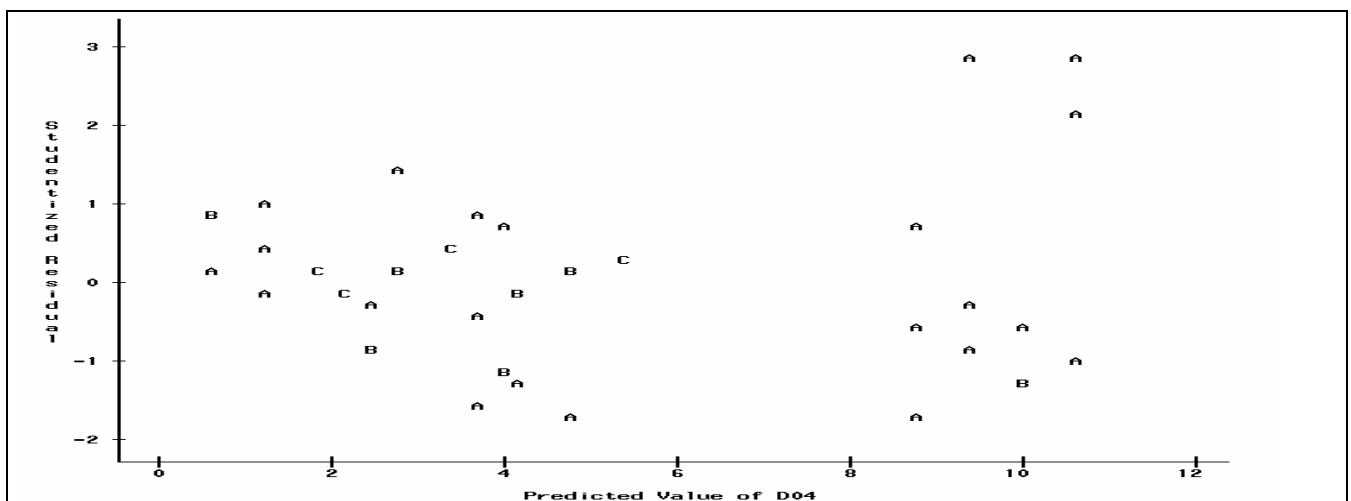
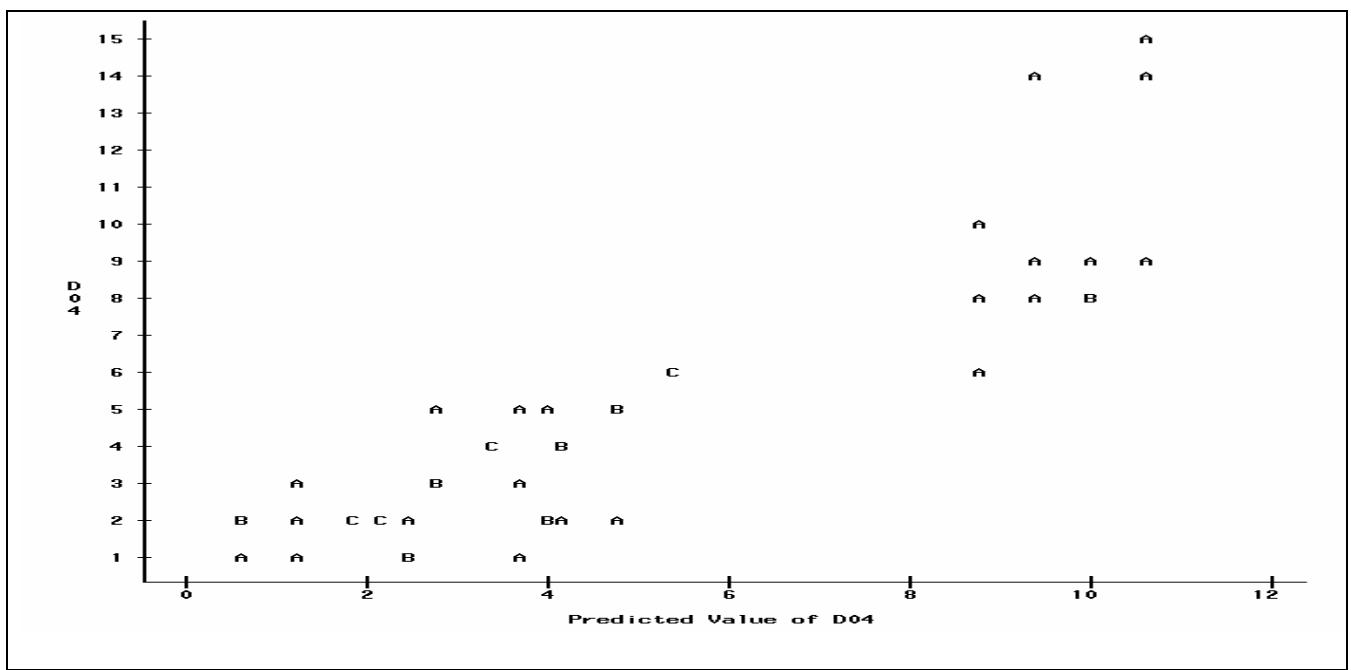
7	1	5	6	5	6	5	6	9	6	5	47	2	10	1,9
9	0	7	9	6	9	8	7	10	4	7	47	4	10	1,9
10	0	8	9	6	9	7	7	6	4	8	47	6	10	1,9
11	0	9	9	8	9	5	9	9	5	9	47	8	10	1,9
7	0	5	10	6	10	9	7	8	4	5	45	2	10	1,9
9	0	7	8	9	8	8	8	11	6	7	45	4	10	1,9
11	0	9	8	9	8	9	8	9	5	9	45	6	10	1,9
10	0	8	15	9	15	7	10	9	4	8	45	8	10	1,9

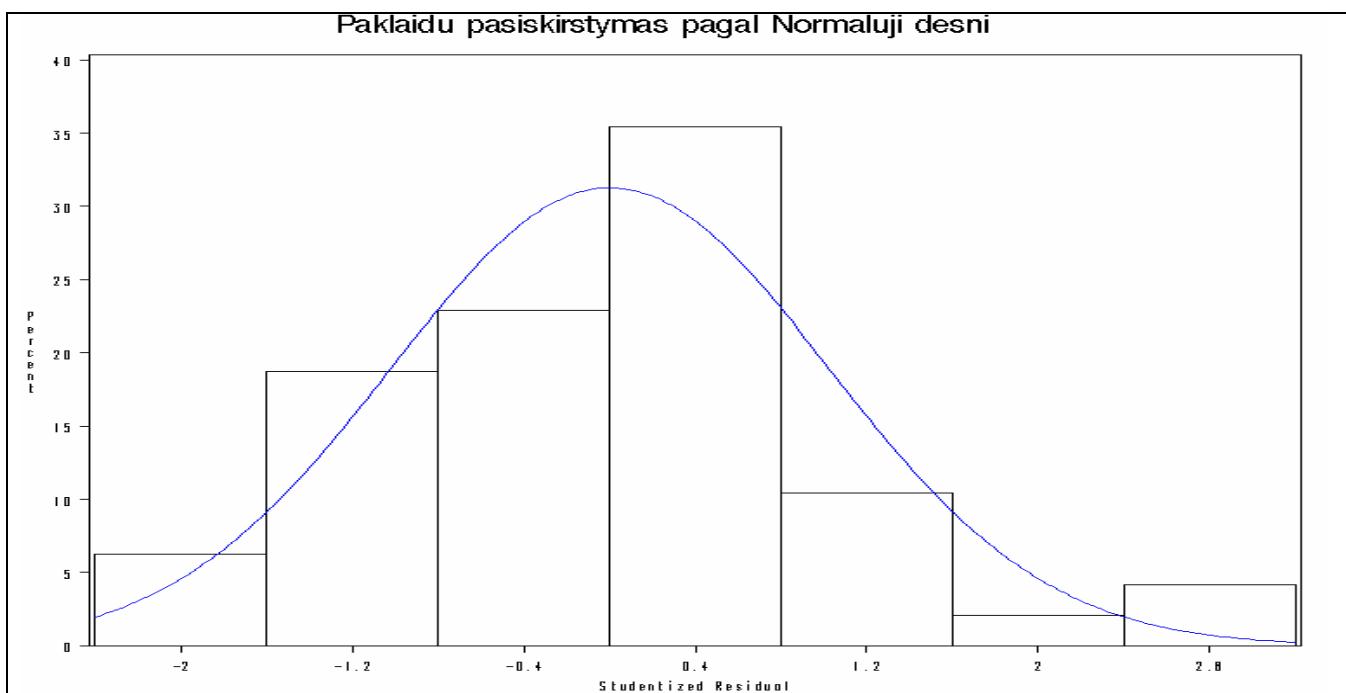
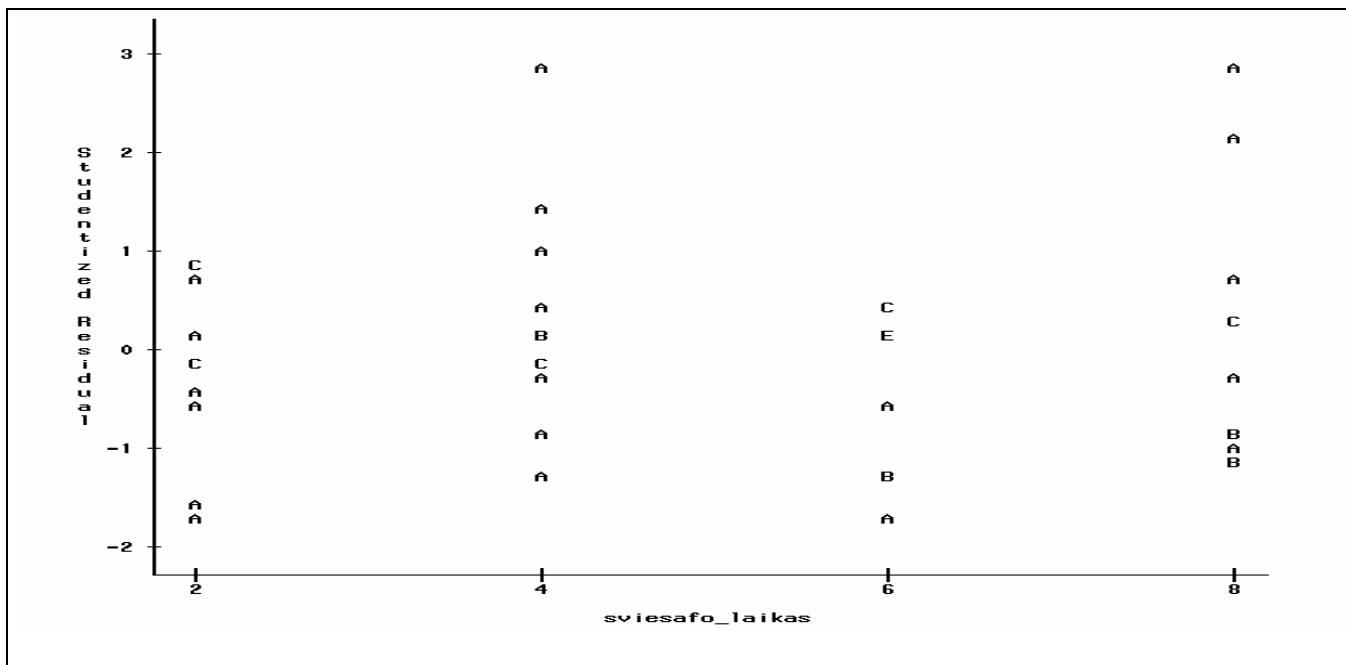
REZULTATAI

Pateikiame gautus rezultatus, apskaičiuotus programiniu paketu SAS.

D04 eilė

Summary of Stepwise Selection						
Step Entered	Variable Removed	Label	Number Vars In	Partial R-Square	Model R-Square	C(p)
1 miu		miu	1	0.7531	0.7531	6.7835
2 sviesafo_laikas		sviesafo_laikas	2	0.0361	0.7892	1.3531
The REG Procedure Model: MODEL1 Dependent Variable: D04 D04						
Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	2	471.89121	235.94561	84.25	<.0001	
Error	45	126.02545	2.80057			
Corrected Total	47	597.91667				
Root MSE Dependent Mean Coeff Var						
		1.67349	R-Square	0.7892		
		4.70833	Adj R-Sq	0.7799		
		35.54313				
Parameter Estimates						
Variable	Label	DF	Parameter Estimate	Standard Error	t Value	Pr >
Intercept	Intercept	1	-5.84182	0.92708	-6.30	<.0
miu	miu	1	7.38788	0.58263	12.68	<.0
sviesafo_laikas	sviesafo_laikas	1	0.30000	0.10802	2.78	0.0
Tests for Normality						
Test	--Statistic--	-----p Value-----				
Shapiro-Wilk	W 0.941659	Pr < W	0.0188			
Kolmogorov-Smirnov	D 0.122462	Pr > D	0.0716			
Cramer-von Mises	W-Sq 0.113824	Pr > W-Sq	0.0750			
Anderson-Darling	A-Sq 0.778308	Pr > A-Sq	0.0419			

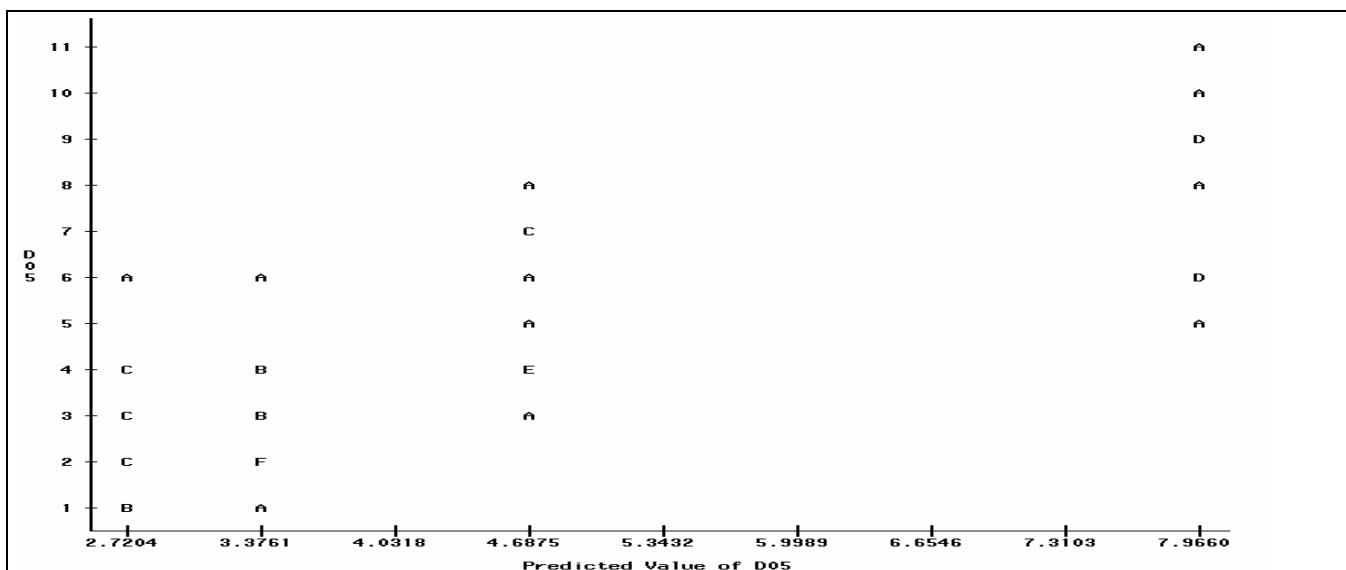


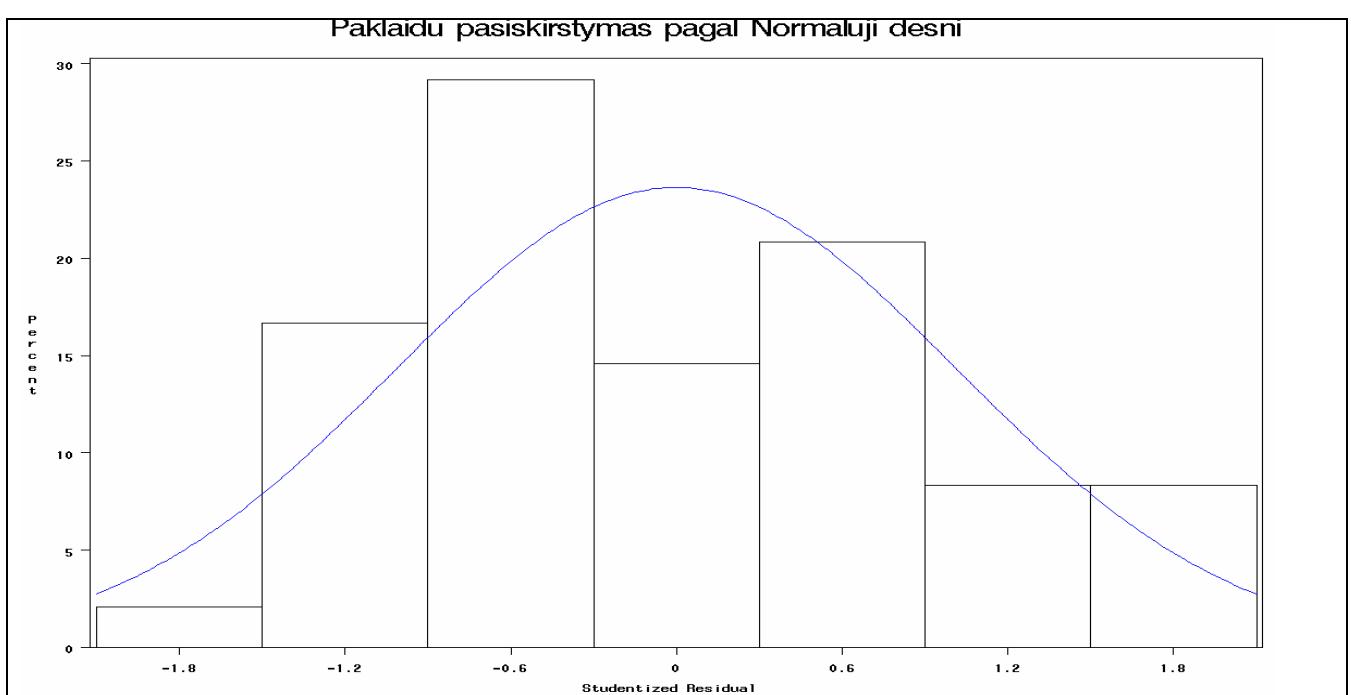
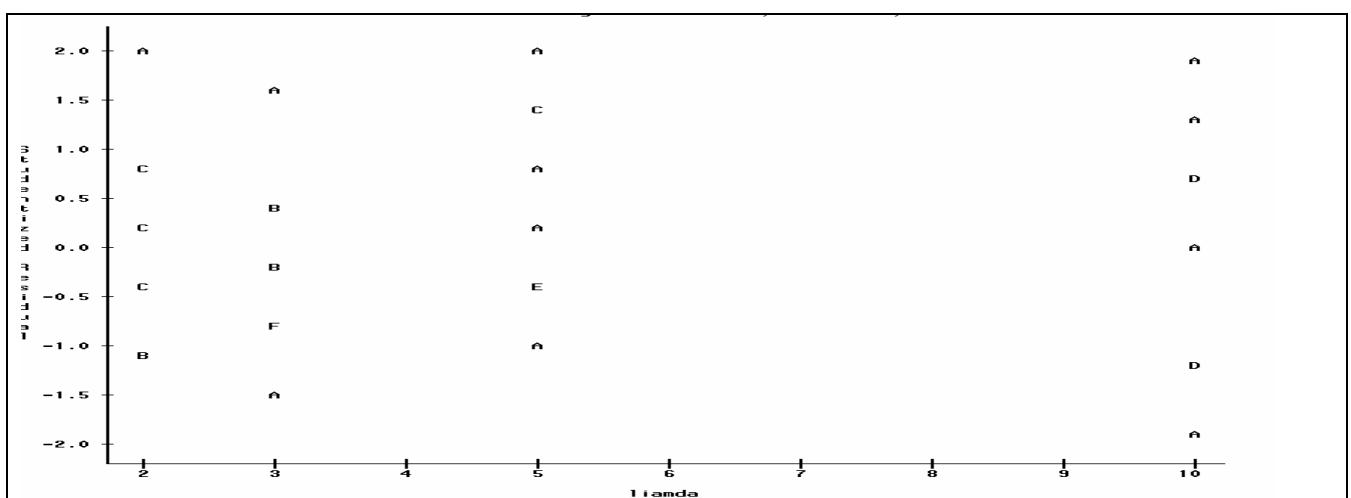
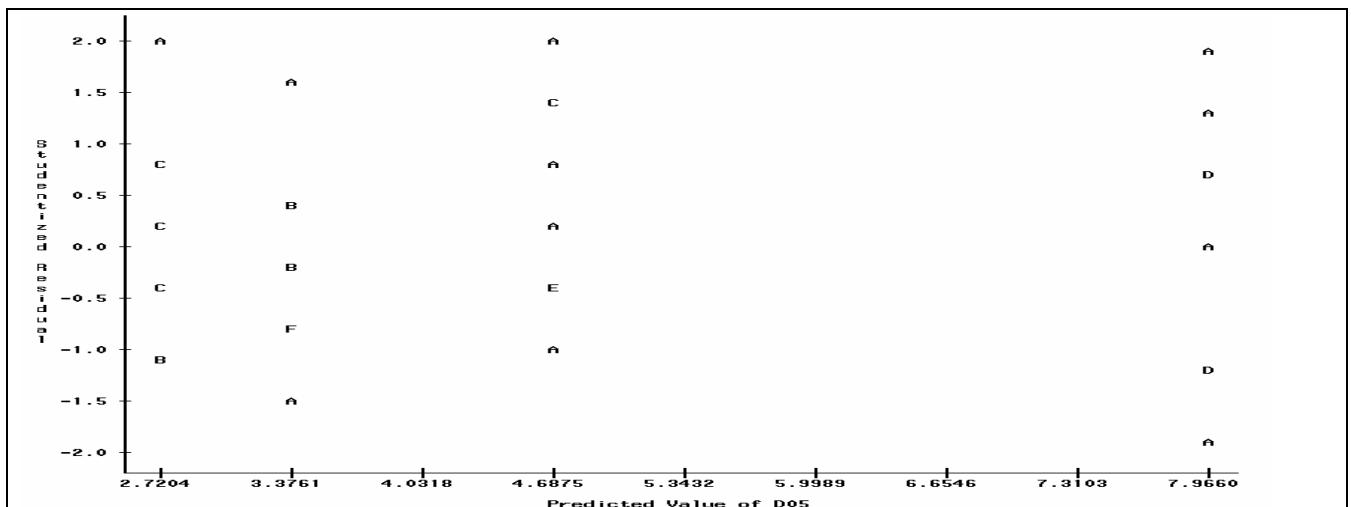


D05 eilė

Summary of Stepwise Selection							
Step Entered	Variable Removed	Label	Number Vars In	Partial R-Square	Model R-Square	C(p)	F Value Pr > F
1 liamda		liamda	1	0.6121	0.6121	3.5937	72.58 <.0001
2 miu		miu	2	0.0264	0.6385	2.3572	3.28 0.0767

Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	1	196.05482	196.05482	72.58	<.0001	
Error	46	124.25768	2.70125			
Corrected Total	47	320.31250				
		Root MSE	1.64355	R-Square	0.6121	
		Dependent Mean	4.68750	Adj R-Sq	0.6036	
		Coeff Var	35.06238			
Parameter Estimates						
Variable	Label	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Intercept	Intercept	1	1.40899	0.45207	3.12	0.0031
Lambda	Lambda	1	0.65570	0.07697	8.52	<.0001
Tests for Normality						
Test	---Statistic---		-----p Value-----			
Shapiro-Wilk	W	0.957249	Pr < W	0.0781		
Kolmogorov-Smirnov	D	0.140749	Pr > D	0.0182		
Cramer-von Mises	W-Sq	0.113916	Pr > W-Sq	0.0748		
Anderson-Darling	A-Sq	0.699857	Pr > A-Sq	0.0667		





D06 eilė

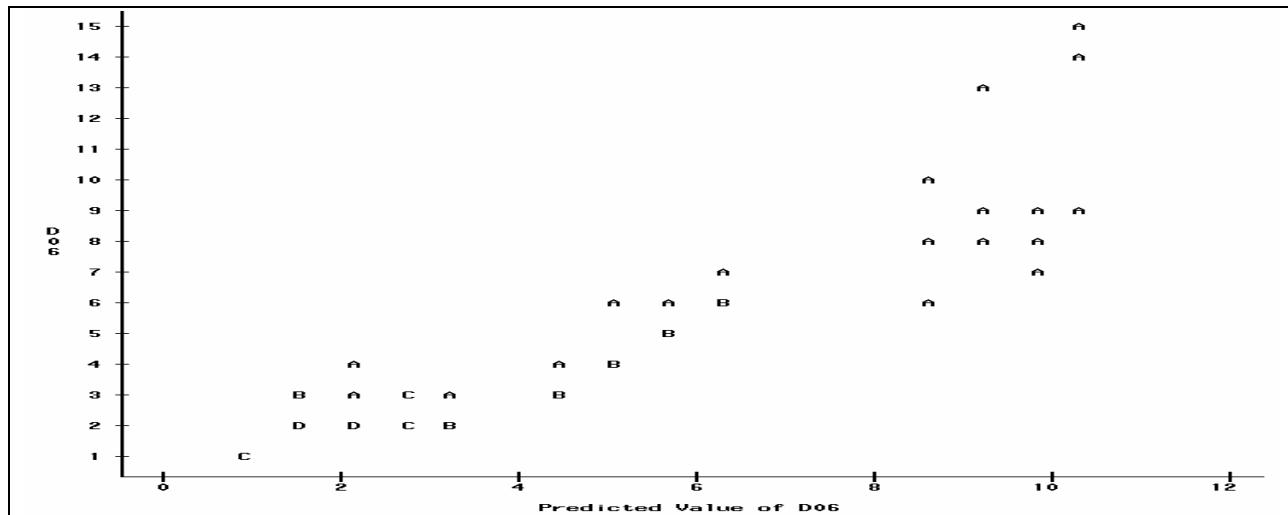
Summary of Stepwise Selection							
Step Entered	Variable Removed	Label	Number Vars In	Partial R-Square	Model R-Square	C(p)	F Value Pr > F
1 liamda		liamda	1	0.7541	0.7541	17.5847	141.04 <.0001
2 sviesafo_laikas		sviesafo_laikas	2	0.0375	0.7915	10.2008	8.09 0.0067
3 miu		miu	3	0.0349	0.8265	3.4494	8.86 0.0047

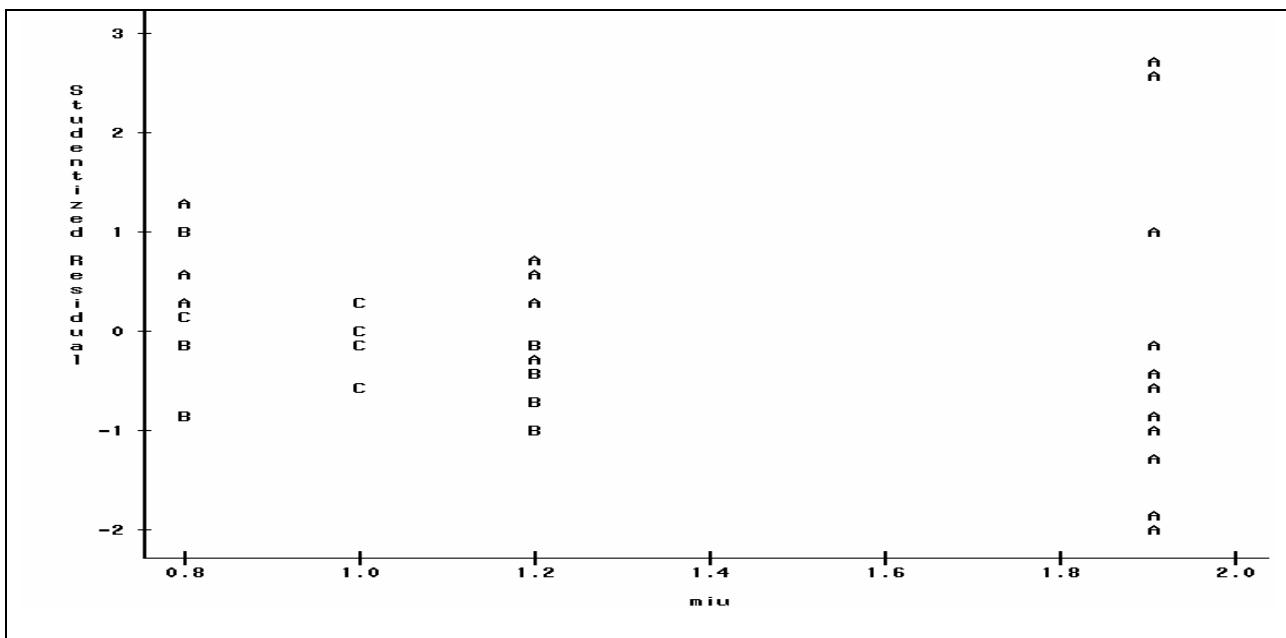
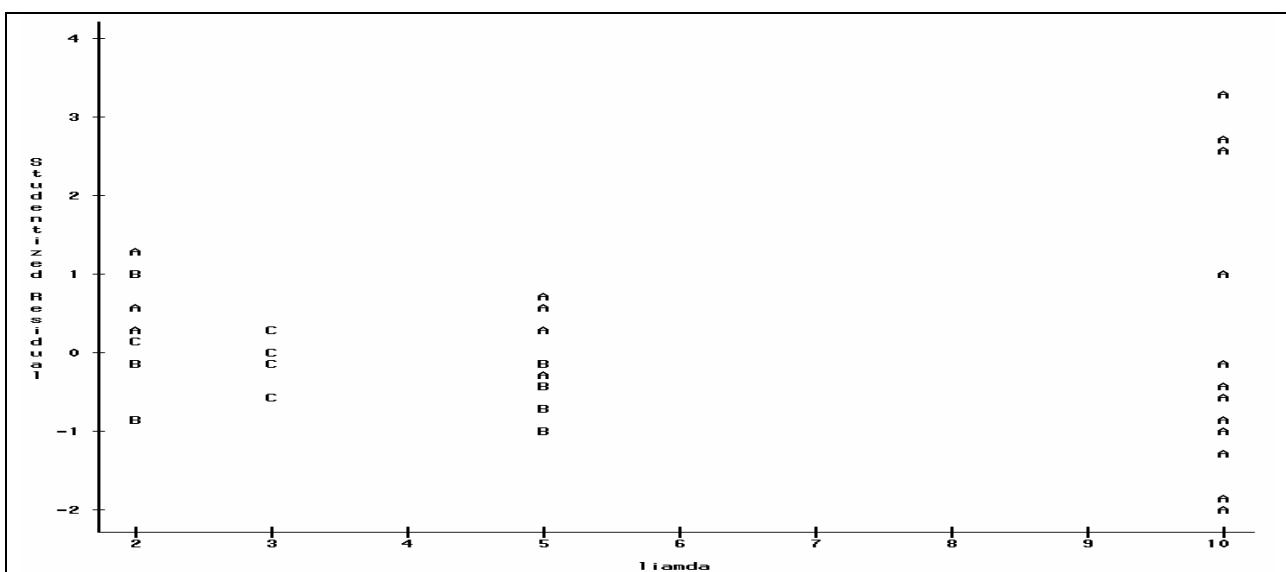
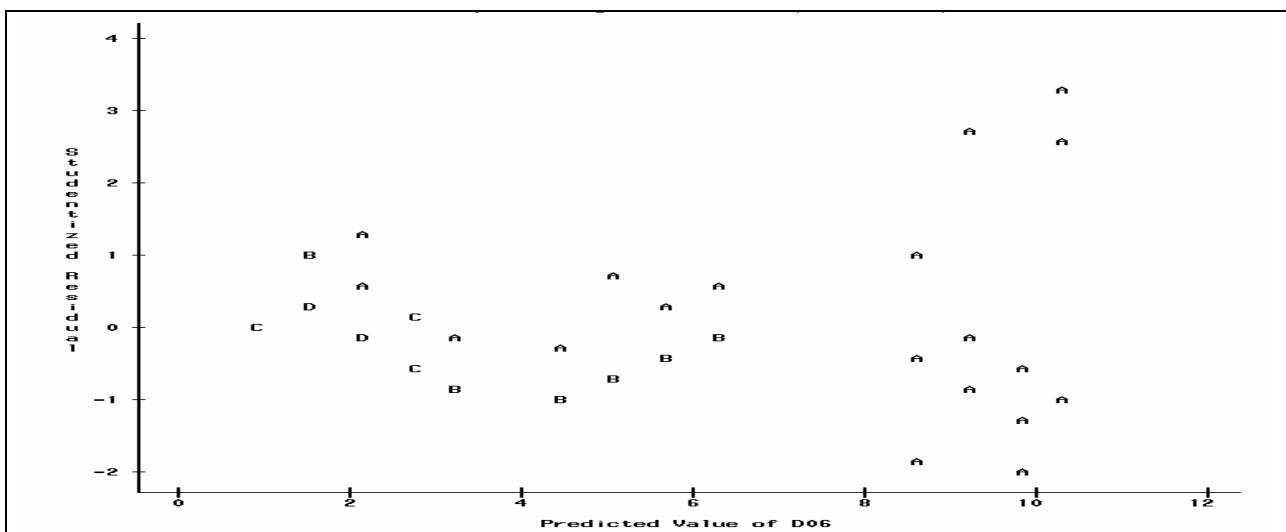
Analysis of Variance					
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	3	463.22609	154.40870	69.86	<.0001
Error	44	97.25308	2.21030		
Corrected Total	47	560.47917			

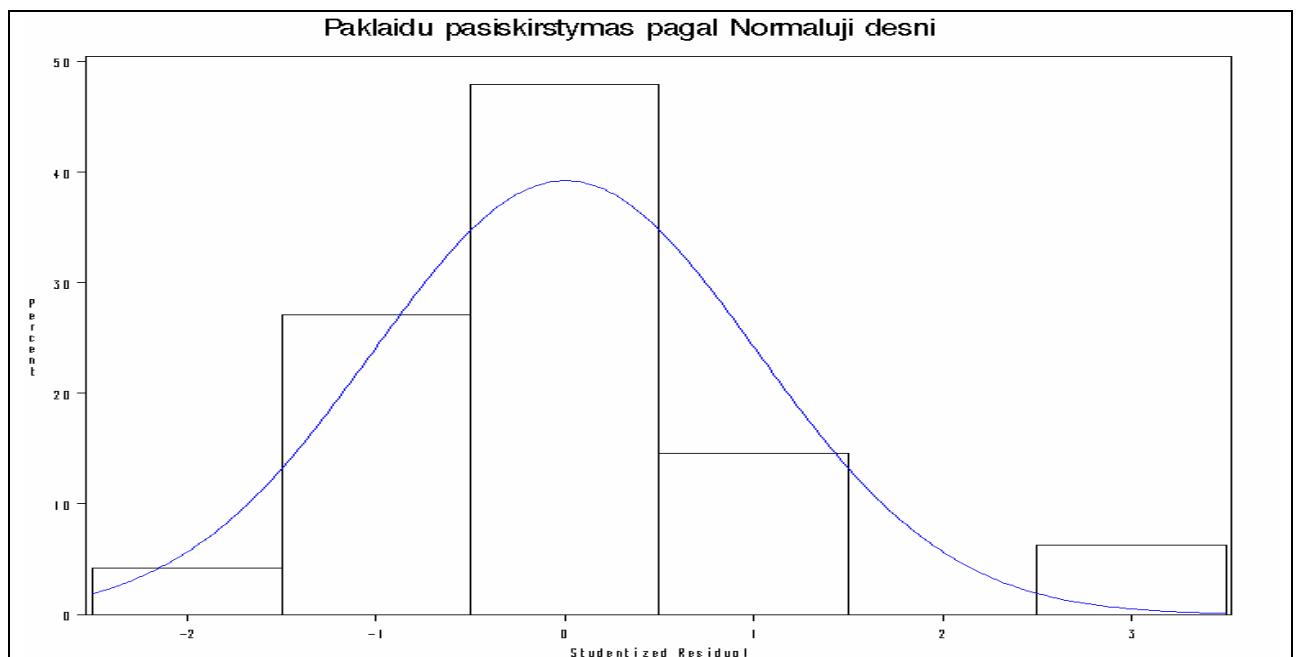
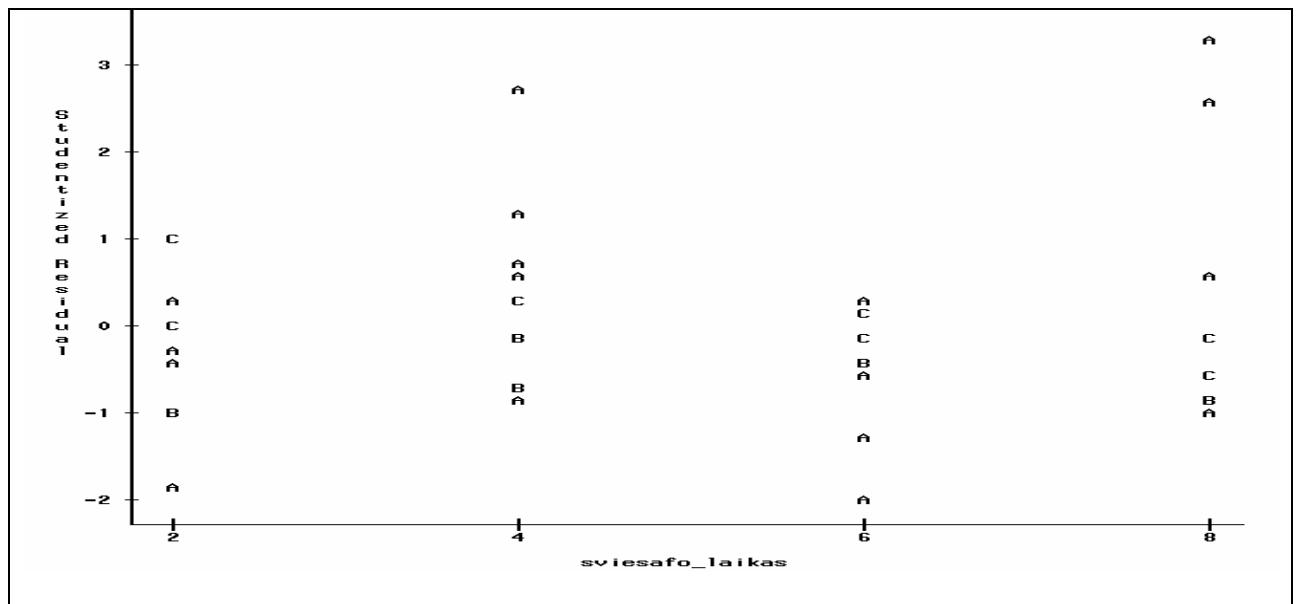
Root MSE	1.48671	R-Square	0.8265
Dependent Mean	4.77083	Adj R-Sq	0.8147
Coeff Var	31.16241		

Parameter Estimates						
Variable	Label	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Intercept	Intercept	1	11.34330	4.36736	2.60	0.0127
liamda	liamda	1	4.07971	1.04935	3.89	0.0003
miu	miu	1	-23.22464	7.80149	-2.98	0.0047
sviesafo_laikas	sviesafo_laikas	1	0.29583	0.09597	3.08	0.0035

Tests for Normality					
Test	--Statistic--	-----p Value-----			
Shapiro-Wilk	W 0.90963	Pr < W			0.0013
Kolmogorov-Smirnov	D 0.160155	Pr > D			<0.0100
Cramer-von Mises	W-Sq 0.198287	Pr > W-Sq			0.0051
Anderson-Darling	A-Sq 1.293614	Pr > A-Sq			<0.0050



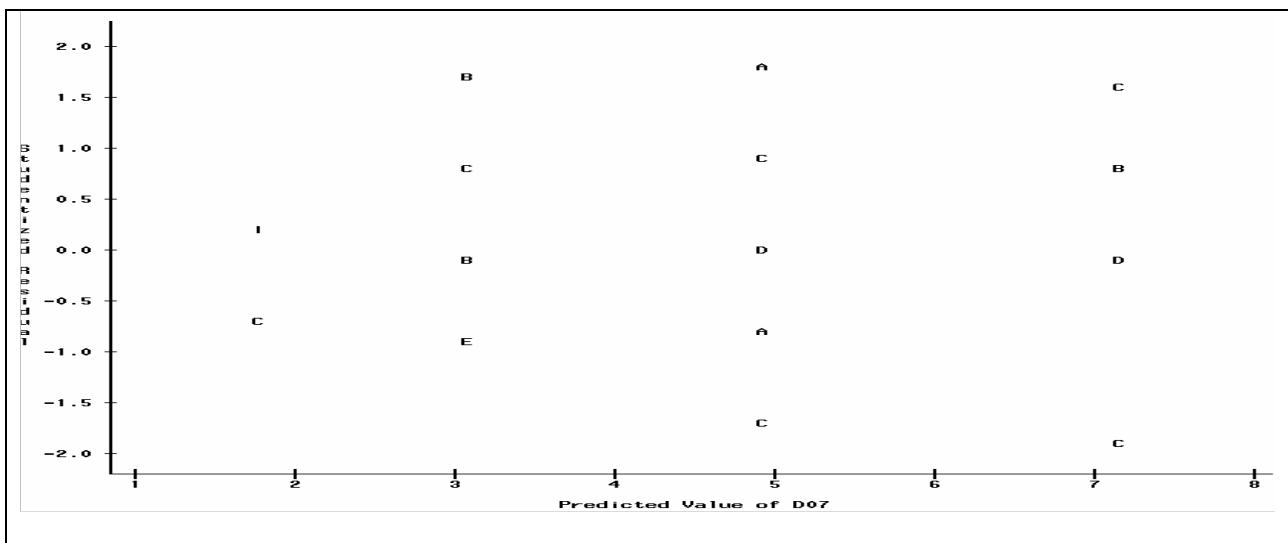
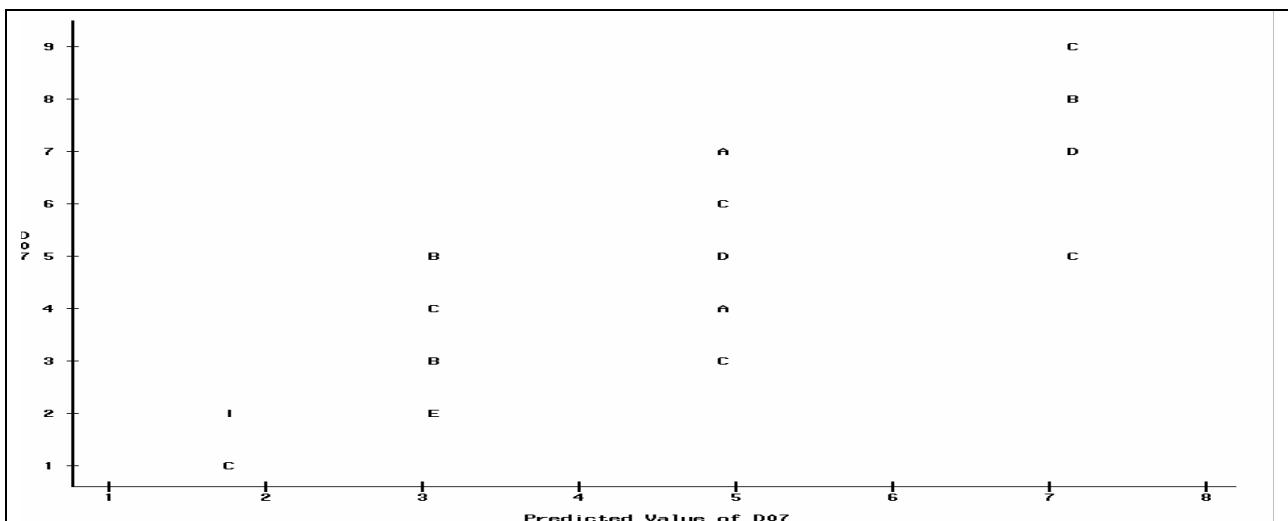


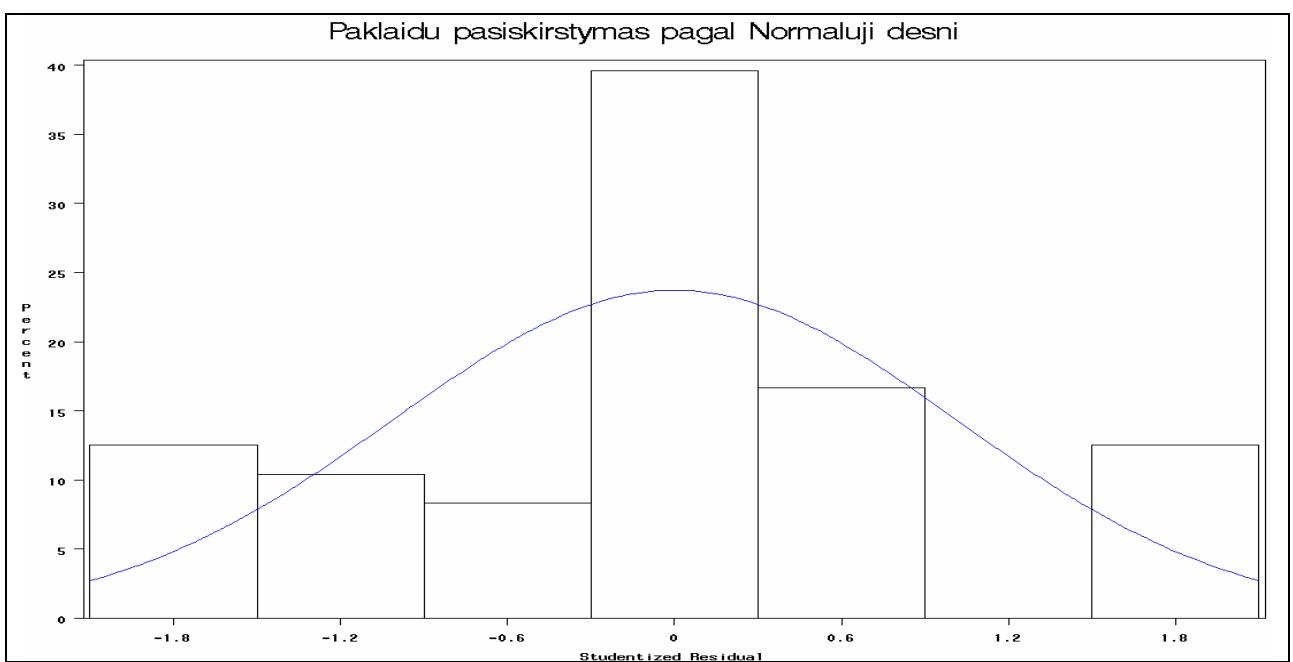
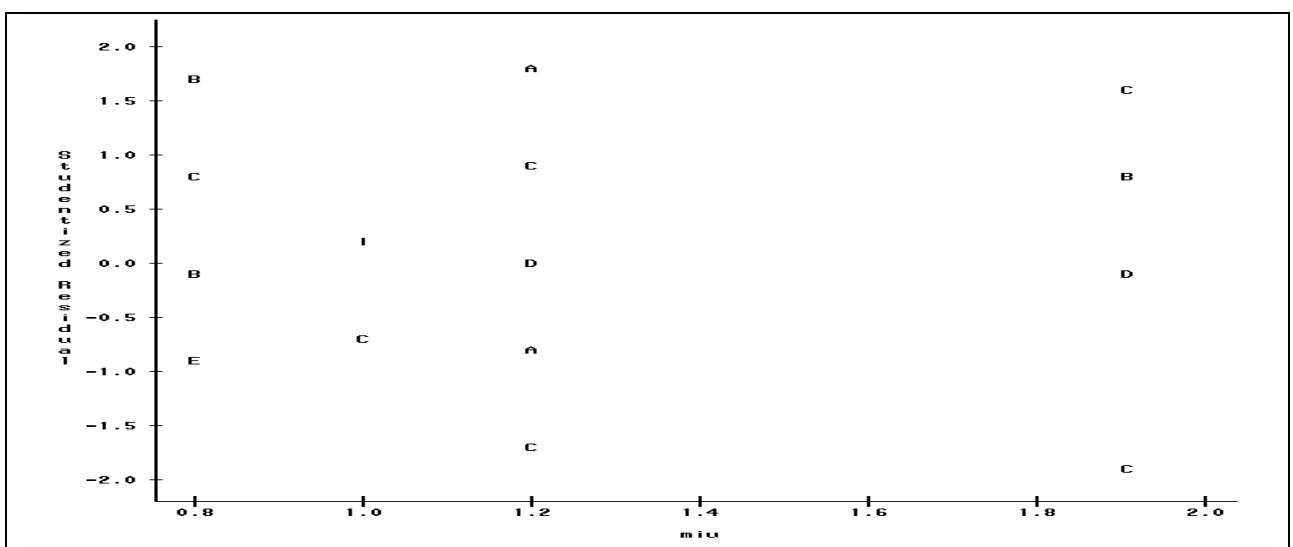
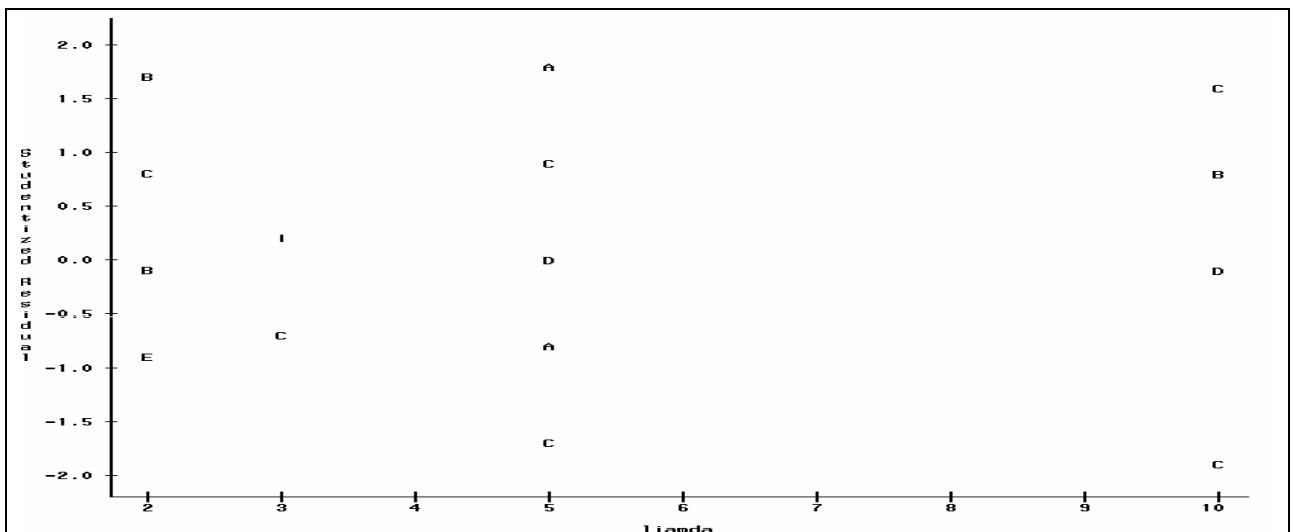


D07 eilė

Summary of Stepwise Selection						
Step Entered	Variable Entered	Variable Removed	Label	Number Vars In	Partial R-Square	Model R-Square
1	Tiamda		Tiamda	1	0.6370	0.6370
2	miu		miu	2	0.1172	0.7541
3	greitis		greitis	3	0.0162	0.7703
				C(p)	F Value	Pr > F
					25.0480	80.71 <.0001
					4.7656	21.44 <.0001
					3.6898	3.10 0.0854

Analysis of Variance						
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F	
Model	2	194.92301	97.46150	69.01	<.0001	
Error	45	63.55616	1.41236			
Corrected Total	47	258.47917				
Root MSE		1.18843	R-Square	0.7541		
Dependent Mean		4.22917	Adj R-Sq	0.7432		
Coeff Var		28.10074				
Parameter Estimates						
Variable	Label	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Intercept	Intercept	1	17.22101	3.47000	4.96	<.0001
Liamda	Liamda	1	4.47645	0.83882	5.34	<.0001
miu	miu	1	-28.87681	6.23627	-4.63	<.0001
Tests for Normality						
Test		--Statistic--	-----p Value-----			
Shapiro-Wilk		W	0.945969	Pr < W	0.0277	
Kolmogorov-Smirnov		D	0.146082	Pr > D	0.0112	
Cramer-von Mises		W-Sq	0.134195	Pr > W-Sq	0.0391	
Anderson-Darling		A-Sq	0.830733	Pr > A-Sq	0.0369	





D12 eilė

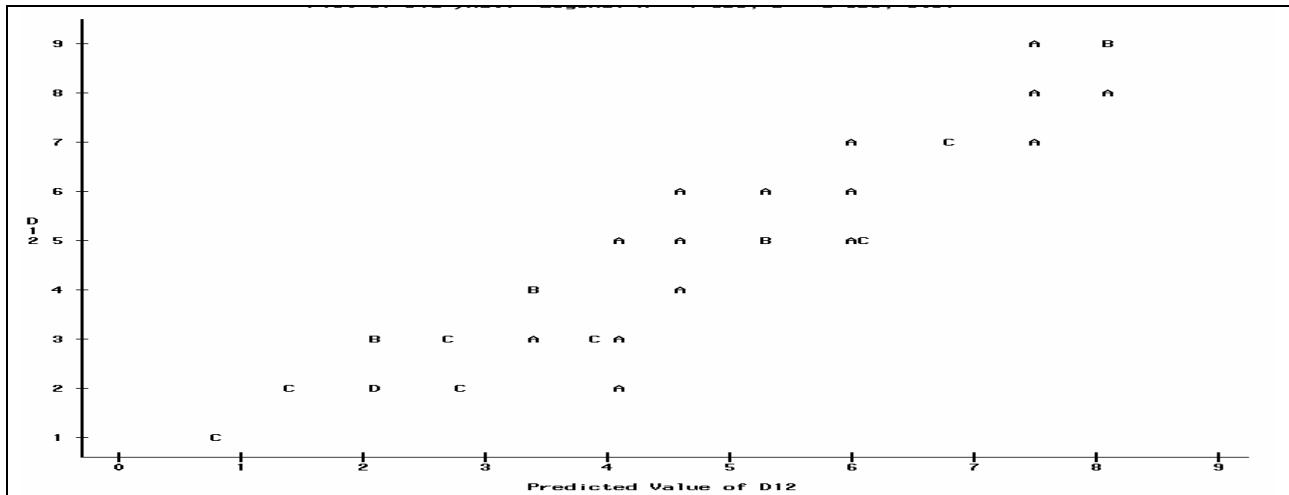
Summary of Stepwise Selection							
Step Entered	Variable Removed	Label	Number Vars In	Partial R-Square	Model R-Square	C(p)	F Value Pr > F
1 liamda		liamda	1	0.6573	0.6573	90.5561	88.23 <.0001
2 miu		miu	2	0.1209	0.7782	45.0867	24.53 <.0001
3 sviesafo_laikas		sviesafo_laikas	3	0.1091	0.8873	4.2340	42.63 <.0001

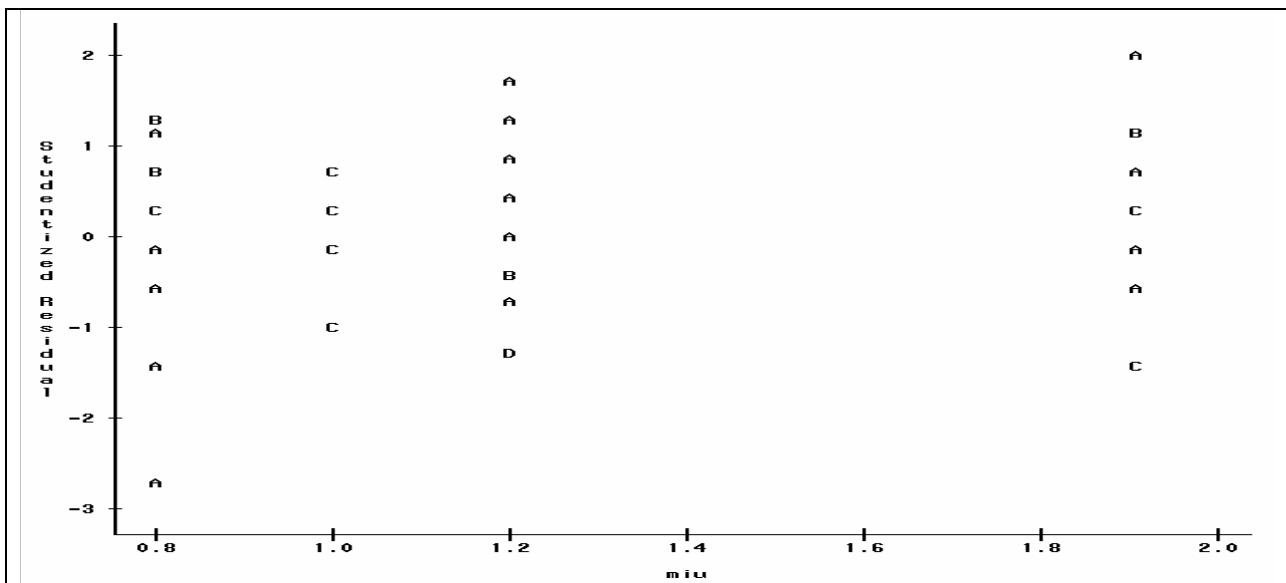
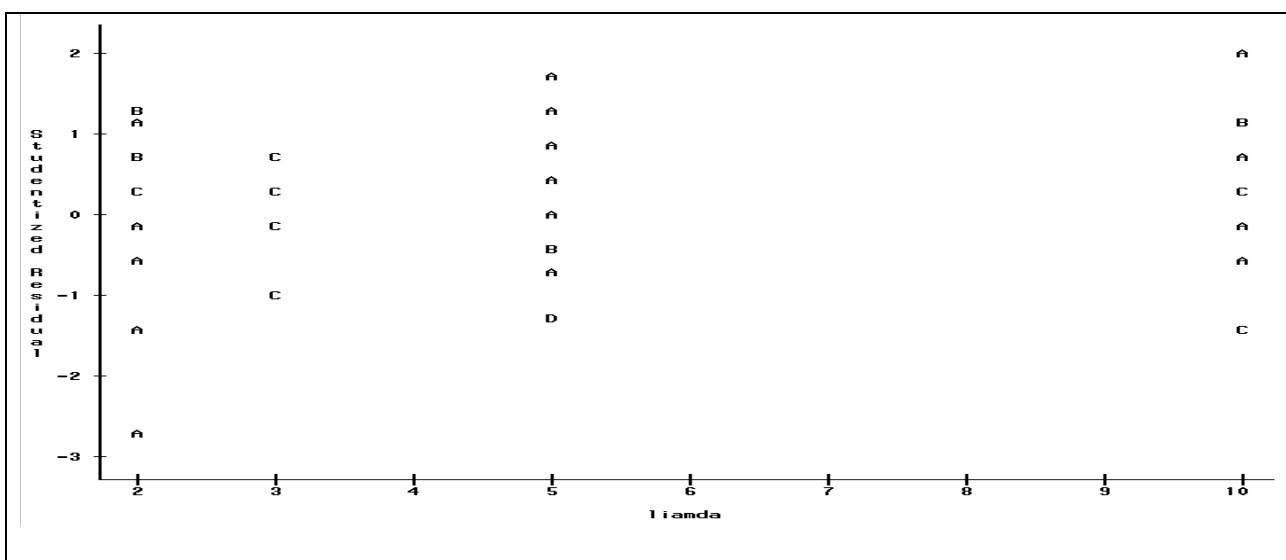
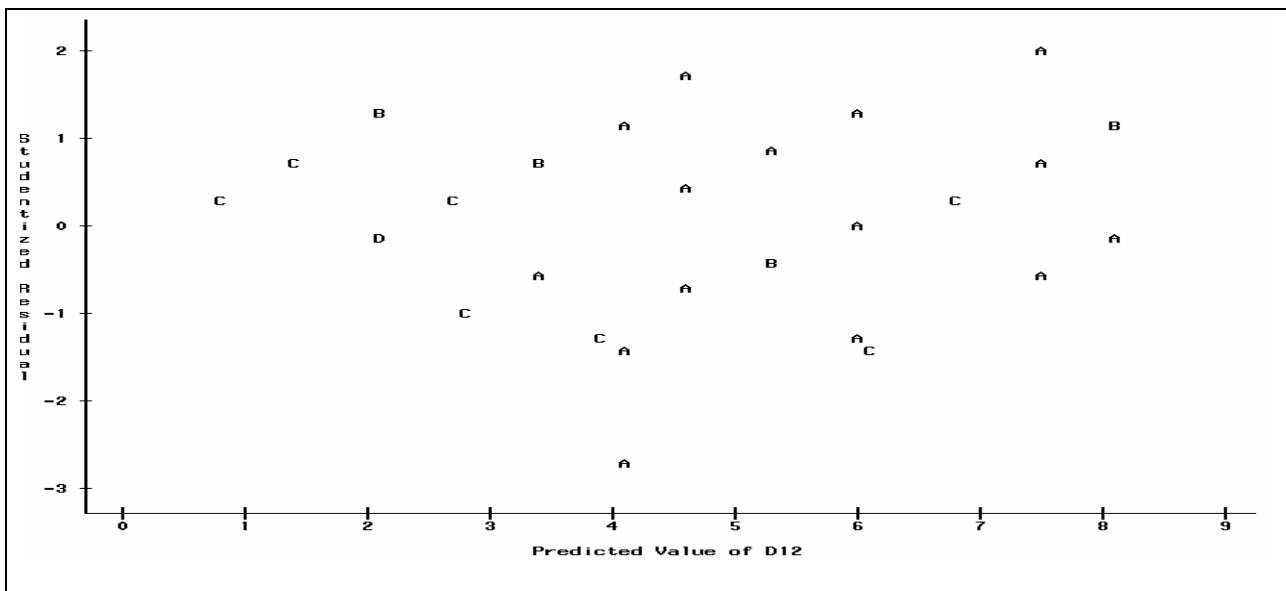
Analysis of Variance					
Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	3	222.26051	74.08684	115.52	<.0001
Error	44	28.21866	0.64133		
Corrected Total	47	250.47917			

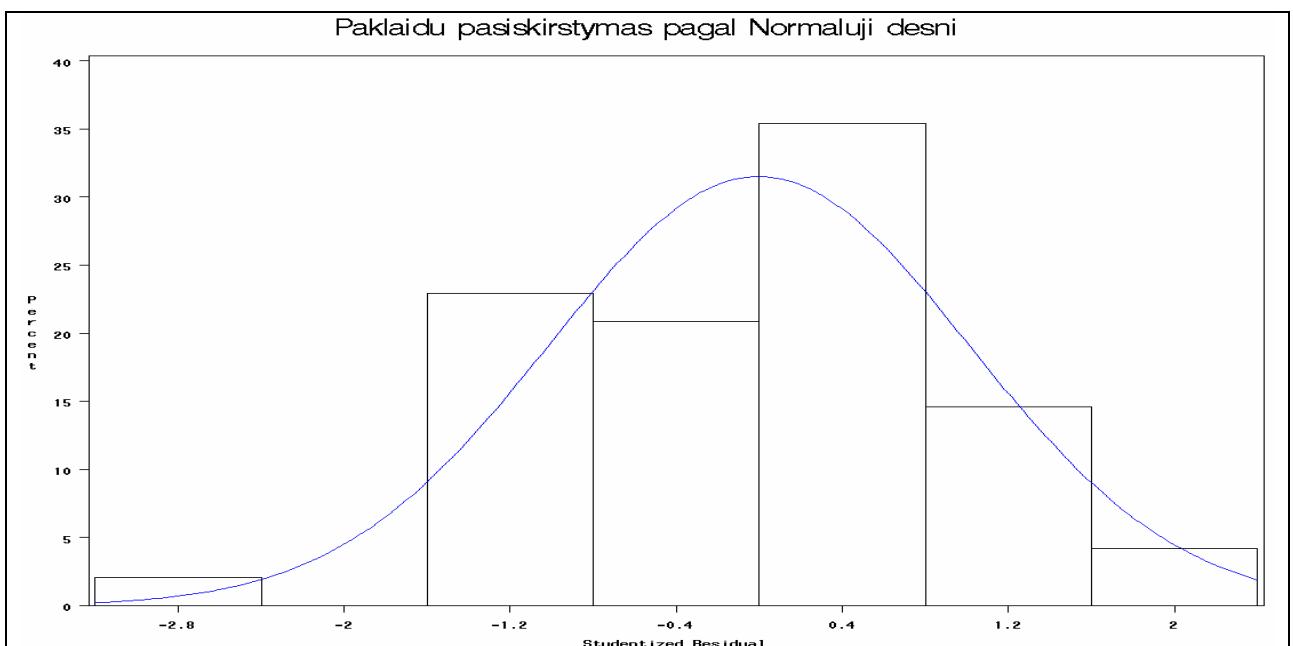
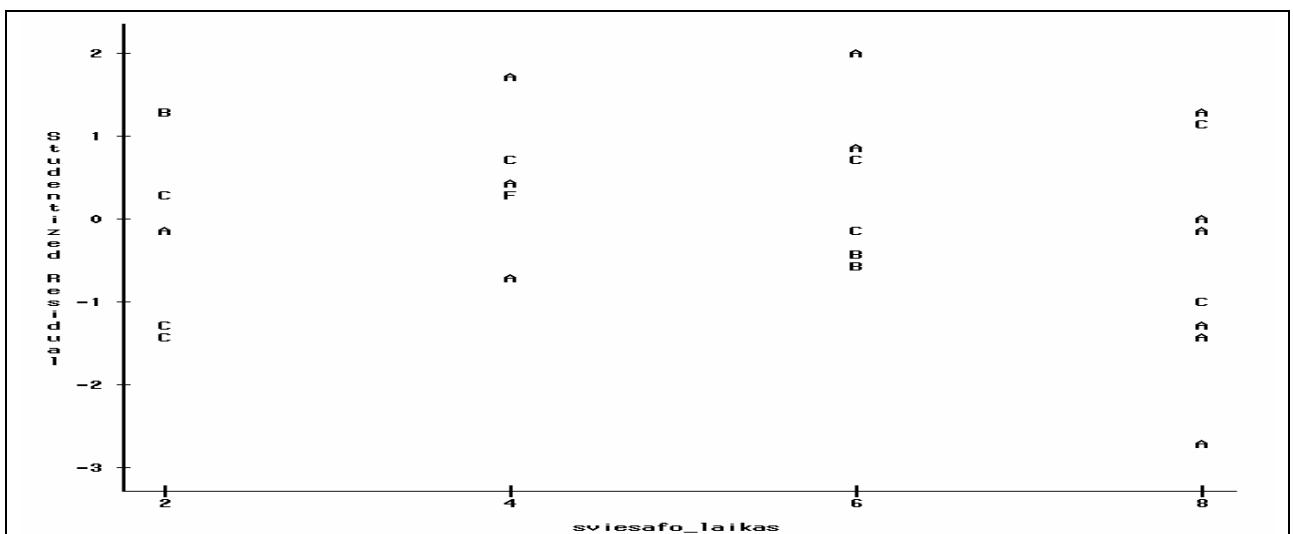
Root MSE	0.80083	R-Square	0.8873
Dependent Mean	4.22917	Adj R-Sq	0.8797
Coeff Var	18.93595		

Parameter Estimates						
Variable	Label	DF	Parameter Estimate	Standard Error	t Value	Pr > t
Intercept	Intercept	1	15.53351	2.35253	6.60	<.0001
liamda	liamda	1	4.47645	0.56525	7.92	<.0001
miu	miu	1	-28.87681	4.20237	-6.87	<.0001
sviesafo_laikas	sviesafo_laikas	1	0.33750	0.05169	6.53	<.0001

Tests for Normality					
Test	--Statistic---		----p Value----		
Shapiro-Wilk	W	0.969923	Pr < W		0.2516
Kolmogorov-Smirnov	D	0.132221	Pr > D		0.0350
Cramer-von Mises	W-Sq	0.094143	Pr > W-Sq		0.1341
Anderson-Darling	A-Sq	0.567624	Pr > A-Sq		0.1385







2 lentelė

Prognozuojami duomenys

D01	D06	D04	D05	D03	D07	D09	D10	D11	D12
4,03	1,51	0,67	2,72	2,03	3,07	2,34	2,70	1,36	2,06
4,72	2,11	1,27	2,72	2,73	3,07	2,92	2,70	1,36	2,74
5,41	2,70	1,87	2,72	3,42	3,07	3,51	2,70	1,36	3,41
6,10	3,29	2,47	2,72	4,11	3,07	4,09	2,70	1,36	4,09
4,03	1,51	0,67	2,72	2,03	3,07	2,34	2,70	1,36	2,06
4,72	2,11	1,27	2,72	2,73	3,07	2,92	2,70	1,36	2,74
5,41	2,70	1,87	2,72	3,42	3,07	3,51	2,70	1,36	3,41

6,10	3,29	2,47	2,72	4,11	3,07	4,09	2,70	1,36	4,09
4,03	1,51	0,67	2,72	2,03	3,07	2,34	2,70	1,36	2,06
4,72	2,11	1,27	2,72	2,73	3,07	2,92	2,70	1,36	2,74
5,41	2,70	1,87	2,72	3,42	3,07	3,51	2,70	1,36	3,41
6,10	3,29	2,47	2,72	4,11	3,07	4,09	2,70	1,36	4,09
2,74	0,95	2,15	3,38	0,74	1,77	0,63	1,62	1,99	0,76
3,42	1,54	2,75	3,38	1,43	1,77	1,22	1,62	1,99	1,44
4,11	2,13	3,35	3,38	2,12	1,77	1,80	1,62	1,99	2,11
4,80	2,72	3,95	3,38	2,81	1,77	2,38	1,62	1,99	2,79
2,74	0,95	2,15	3,38	0,74	1,77	0,63	1,62	1,99	0,76
3,42	1,54	2,75	3,38	1,43	1,77	1,22	1,62	1,99	1,44
4,11	2,13	3,35	3,38	2,12	1,77	1,80	1,62	1,99	2,11
4,80	2,72	3,95	3,38	2,81	1,77	2,38	1,62	1,99	2,79
2,74	0,95	2,15	3,38	0,74	1,77	0,63	1,62	1,99	0,76
3,42	1,54	2,75	3,38	1,43	1,77	1,22	1,62	1,99	1,44
4,11	2,13	3,35	3,38	2,12	1,77	1,80	1,62	1,99	2,11
4,80	2,72	3,95	3,38	2,81	1,77	2,38	1,62	1,99	2,79
5,91	4,46	3,62	4,69	3,91	4,95	4,59	5,25	2,63	3,94
6,60	5,06	4,22	4,69	4,61	4,95	5,17	5,25	2,63	4,61
7,29	5,65	4,82	4,69	5,30	4,95	5,75	5,25	2,63	5,29
7,98	6,24	5,42	4,69	5,99	4,95	6,34	5,25	2,63	5,97
5,91	4,46	3,62	4,69	3,91	4,95	4,59	5,25	2,63	3,94
6,60	5,06	4,22	4,69	4,61	4,95	5,17	5,25	2,63	4,61
7,29	5,65	4,82	4,69	5,30	4,95	5,75	5,25	2,63	5,29
7,98	6,24	5,42	4,69	5,99	4,95	6,34	5,25	2,63	5,97
5,91	4,46	3,62	4,69	3,91	4,95	4,59	5,25	2,63	3,94
6,60	5,06	4,22	4,69	4,61	4,95	5,17	5,25	2,63	4,61
7,29	5,65	4,82	4,69	5,30	4,95	5,75	5,25	2,63	5,29
7,98	6,24	5,42	4,69	5,99	4,95	6,34	5,25	2,63	5,97
8,08	8,61	8,80	7,97	6,08	7,12	7,11	8,52	4,86	6,11
8,77	9,20	9,40	7,97	6,77	7,12	7,69	8,52	4,86	6,78
9,46	9,79	10,00	7,97	7,47	7,12	8,27	8,52	4,86	7,46
10,14	10,38	10,60	7,97	8,16	7,12	8,86	8,52	4,86	8,13
8,08	8,61	8,80	7,97	6,08	7,12	7,11	8,52	4,86	6,11
8,77	9,20	9,40	7,97	6,77	7,12	7,69	8,52	4,86	6,78
9,46	9,79	10,00	7,97	7,47	7,12	8,27	8,52	4,86	7,46
10,14	10,38	10,60	7,97	8,16	7,12	8,86	8,52	4,86	8,13
8,08	8,61	8,80	7,97	6,08	7,12	7,11	8,52	4,86	6,11
8,77	9,20	9,40	7,97	6,77	7,12	7,69	8,52	4,86	6,78
9,46	9,79	10,00	7,97	7,47	7,12	8,27	8,52	4,86	7,46
10,14	10,38	10,60	7,97	8,16	7,12	8,86	8,52	4,86	8,13

3 lentelė

Šviesoforo degimo laikas 60 s.

D01	D06	D04	D05	D03	D07	D09	D10	D11	D12
3,69	1,22	0,37	2,72	1,69	3,07	2,05	2,70	1,36	1,72
3,69	1,22	0,37	2,72	1,69	3,07	2,05	2,70	1,36	1,72
3,69	1,22	0,37	2,72	1,69	3,07	2,05	2,70	1,36	1,72
3,69	1,22	0,37	2,72	1,69	3,07	2,05	2,70	1,36	1,72
3,69	1,22	0,37	2,72	1,69	3,07	2,05	2,70	1,36	1,72

4 lentelė

Šviesoforo degimo laikas 50s.

D01	D06	D04	D05	D03	D07	D09	D10	D11	D12
3,63	1,17	0,32	2,72	1,63	3,07	2,00	2,70	1,36	1,67
3,63	1,17	0,32	2,72	1,63	3,07	2,00	2,70	1,36	1,67
3,63	1,17	0,32	2,72	1,63	3,07	2,00	2,70	1,36	1,67

3 PRIEDAS. MIKROSKOPINIO EISMO SRAUTO K. MINDAUGO PR. – BIRŠTONO G-VĖS
SANKRYŽOS MODELIO REALIZACIJA ARENA 3.0 PROGRAMINIU PAKETU

4 PRIEDAS. PROGRAMŲ TEKSTAI

SAS programoje

D01 eilė

```

proc import datafile="C:\Documents and Settings\Administrator\My
Documents\tyriamoji dalis\duom.xls" out=duom dbms=excel replace;
  run;
e
  format sviesafo_laikas comma3.;
  set duom(rename=(_col4=sviesafo_laikas));
run;
title ' Geriausia regresijos lygtis ';
proc reg data=duom;
  model D01= sviesafo_laikas liamda greitis miu /selection= rsquare cp
adjrsq mse; ;
  run;
    title ' Stepwise Regresija ';
proc reg data=duom;
model D01= sviesafo_laikas liamda greitis miu/selection= stepwise;
run;
title ' Regresijos modelis ';
proc reg data=duom;
model D01= liamda miu sviesafo_laikas;
output out = new p=yhat student=resid;
run;
proc plot data=new;
  plot D01*yhat;
title1 'Regresijos modelio adekvatumo tyrimas
D01 ir y su kepure grafikas';
  plot resid*yhat;
title4 'e(paklaidos) ir liamda grafikas';
  plot resid*liamda;
title4 'e(paklaidos) ir miu grafikas';
  plot resid*miu;
title4 'e(paklaidos) ir sviesafo_laikas grafikas';
  plot resid*sviesafo_laikas;

    title ' Paklaidu pasiskirstymas pagal Normaluji desni ';
proc univariate normal data=new;
  var resid;
  histogram resid / normal;
run;

```

D04 eilė

```

proc import datafile="C:\Documents and Settings\Administrator\My
Documents\tyriamoji dalis\duom.xls" out=duom dbms=excel replace;
  run;
data duom;
  format sviesafo_laikas comma3.;
  set duom(rename=(_col4=sviesafo_laikas));
run;
title ' Geriausia regresijos lygtis ';
proc reg data=duom;
  model D04= sviesafo_laikas liamda greitis miu /selection= rsquare cp
adjrsq mse; ;
  run;
    title ' Stepwise Regresija ';
proc reg data=duom;
```

```

model D04= sviesafo_laikas liamda greitis miu/ selection= stepwise;
run;
title ' Regresijos modelis ';
proc reg data=duom;
model D04= miu sviesafo_laikas;
output out = new p=yhat student=resid;
run;
proc plot data=new;
plot D04*yhat;
title1 'Regresijos modelio adekvatumo tyrimas
      D04 ir y su kepure grafikas';
plot resid*yhat;
title4 'e(paklaidos) ir miu grafikas';
plot resid*miu;
title2 'e(paklaidos) ir sviesafo_laikas grafikas';
plot resid*sviesafo_laikas;
title ' Paklaidu pasiskirstymas pagal Normaluji desni ';
proc univariate normal data=new;
var resid;
histogram resid / normal;
run;

```

D05 eilė

```

proc import datafile="C:\Documents and Settings\Administrator\My
Documents\tyriamoji dalis\duom.xls" out=duom dbms=excel replace;
run;
data duom;
format sviesafo_laikas comma3.;
set duom(rename=(_col4=sviesafo_laikas));
run;
title ' Geriausia regresijos lygtis ';
proc reg data=duom;
model D05= sviesafo_laikas liamda greitis miu /selection= rsquare cp
adjrsq mse; ;
run;
title ' Stepwise Regresija ';
proc reg data=duom;
model D05= sviesafo_laikas liamda greitis miu/ selection= stepwise;
run;
title ' Regresijos modelis ';
proc reg data=duom;
model D05= liamda;
output out = new p=yhat student=resid;
run;
proc plot data=new;
plot D05*yhat;
title1 'Regresijos modelio adekvatumo tyrimas
      D05 ir y su kepure grafikas';
plot resid*yhat;
title4 'e(paklaidos) ir liamda grafikas';
plot resid*liamda;
title ' Paklaidu pasiskirstymas pagal Normaluji desni ';
proc univariate normal data=new;
var resid;
histogram resid / normal;
run;

```

D06 eilė

```

proc import datafile="C:\Documents and Settings\Administrator\My
Documents\tyriamoji dalis\duom.xls" out=duom dbms=excel replace;
  run;
data duom;
  format sviesafo_laikas comma3.;
  set duom(rename=(_col4=sviesafo_laikas));
  run;
  title ' Geriausia regresijos lygtis ';
proc reg data=duom;
  model D06= sviesafo_laikas liamda greitis miu /selection= rsquare cp
adjrsq mse; ;
  run;
  title ' Stepwise Regresija ';
proc reg data=duom;
model D06= sviesafo_laikas liamda greitis miu/ selection= stepwise;
run;
title ' Regresijos modelis ';
proc reg data=duom;
model D06= liamda miu sviesafo_laikas;
output out = new p=yhat student=resid;
run;
proc plot data=new;
  plot D06*yhat;
title1 'Regresijos modelio adekvatumo tyrimas
      D06 ir y su kepure grafikas';
  plot resid*yhat;
title4 'e(paklaidos) ir liamda grafikas';
  plot resid*liamda;
  title4 'e(paklaidos) ir miu grafikas';
  plot resid*miu;
  title4 'e(paklaidos) ir sviesaforo_laikas grafikas';
  plot resid*sviesafo_laikas;
title ' Paklaidu pasiskirstymas pagal Normaluji desni ';
proc univariate normal data=new;
  var resid;
  histogram resid / normal;
run;

```

D07 eilė

```

roc import datafile="C:\Documents and Settings\Administrator\My
Documents\tyriamoji dalis\duom.xls" out=duom dbms=excel replace;
  run;
data duom;
  format sviesafo_laikas comma3.;
  set duom(rename=(_col4=sviesafo_laikas));
  run;
  title ' Geriausia regresijos lygtis ';
proc reg data=duom;
  model D07= sviesafo_laikas liamda greitis miu /selection= rsquare cp
adjrsq mse; ;
  run;
  title ' Stepwise Regresija ';
proc reg data=duom;
model D07= sviesafo_laikas liamda greitis miu/ selection= stepwise;
run;
title ' Regresijos modelis ';
proc reg data=duom;

```

```

model D07= liamda miu;
output out = new p=yhat student=resid;
run;
proc plot data=new;
plot D07*yhat;
title1 'Regresijos modelio adekvatumo tyrimas
        D07 ir y su kepure grafikas';
plot resid*yhat;
title4 'e(paklaidos) ir liamda grafikas';
plot resid*liamda;
title4 'e(paklaidos) ir miu grafikas';
plot resid*miu;
title ' Paklaidu pasiskirstymas pagal Normaluji desni ';
proc univariate normal data=new;
var resid;
histogram resid / normal;
run;
D12 eilė
proc import datafile="C:\Documents and Settings\Administrator\My
Documents\tyriamoji dalis\duom.xls" out=duom dbms=excel replace;
run;
data duom;
format sviesafo_laikas comma3.;
set duom(rename=(_col4=sviesafo_laikas));
run;
title ' Geriausia regresijos lygtis ';
proc reg data=duom;
model D12= sviesafo_laikas liamda greitis miu /selection= rsquare cp
adjrsq mse; ;
run;
title ' Stepwise Regresija ';
proc reg data=duom;
model D12= sviesafo_laikas liamda greitis miu/ selection= stepwise;
run;
title ' Regresijos modelis ';
proc reg data=duom;
model D12= liamda miu sviesafo_laikas;
output out = new p=yhat student=resid;
run;
proc plot data=new;
plot D12*yhat;
title1 'Regresijos modelio adekvatumo tyrimas
        D12 ir y su kepure grafikas';
plot resid*yhat;
title4 'e(paklaidos) ir liamda grafikas';
plot resid*liamda;
title4 'e(paklaidos) ir miu grafikas';
plot resid*miu;
title4 'e(paklaidos) ir sviesafo_laikas grafikas';
plot resid*sviesafo_laikas;

title ' Paklaidu pasiskirstymas pagal Normaluji desni ';
proc univariate normal data=new;
var resid;
histogram resid / normal;

```

5 PRIEDAS. KONFERENCIJOS PRANEŠIMO MEDŽIAGA

MIKROSKOPINIO EISMO SRAUTO STABILUMO ANALIZĖ

J. Jablonskytė, prof. P. Ilgakojis
Kauno technologijos universitetas

Mikroskopinis eismas - tai atskirų transporto priemonių judėjimas kelio segmentuose, santykio transporto priemone – vairuotojas, transporto priemonė – transporto priemonė, transporto priemonė – aplinka prasme. Transporto priemonės vairuotojas turi polinkį sumažinti greitį, jei jis važiuoja greičiau už priekyje judantį automobilį, arba didinti greitį, jei jis važiuoja lėčiau negu priekyje važiuojanti mašina.

Šiame darbe nagrinėsime mikroskopinio eismo srauto stabilumo aktualumą mikroskopinio eismo srauto modeliavimui. Esant neribotam greičiui, sistema tampa nestabili, tad panagrinėsime kas atsitinka esant mažiem greičių skirtumams ir pasistengsime nustatyti eismo srauto stabilumo ribas, kurioms esant mikroskopinio eismo srauto modeliai būtų teisingi [1].

Nagrinėjant vienos juostos, vienpusi kelią ratu, kuriuo važiuoja fiksotas skaičius mašinų. Remiamės tolimesniojo automobilio tiesine lygtimi:

$$x_n''(t+T) = \lambda(x_{n-1}'(t) - x_n'(t)), \quad (1)$$

čia t - laikas, T - reakcijos laikas, λ - jautrumo parametras, $x_{n-1}'(t), x_n'(t)$ - atitinkamai $n-1$ -ojo ir n -ojo automobilių greičiai laiko momentu t .

Eilėje važiuojančio n -jo automobilio greitis $u_n(t)$ apibrėžiamas lygtimi:

$$u_n(t) = a_0 + F(w, \lambda, T, n) e^{i\Omega(w, \lambda, T, n)}, \quad (2)$$

čia $a_0 \leq 0$ - konstanta, w - monochromatinis svyravimų dažnis intervalė $[0, 2\pi]$.

Svyravimų amplitudė

$$F(w, \lambda, T, n) = \left[1 + \left(\frac{w}{\lambda} \right)^2 + 2 \left(\frac{w}{\lambda} \right) \sin(wT) \right]^{\frac{-n}{2}}. \quad (3)$$

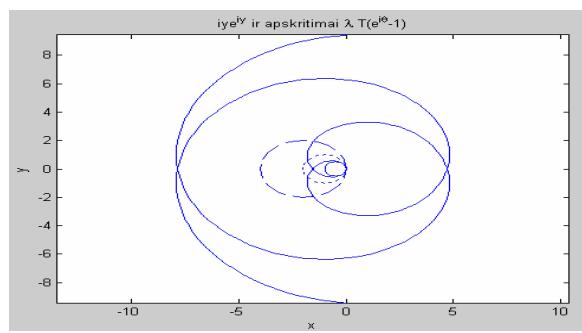
Eismo srauto sistemos stabilumo supratimas yra pateiktas įvairiose publikacijose [2].

Kai riba $w \rightarrow 0$, tai $\lambda T < 1/2$ - sistema stabili, kai $\lambda T > 1/2$ - sistema nestabili.

1 pav., kai $\lambda T = 0.5$ gavome stabilumo ribą, kol apskritimas nekerta spiralės $z \exp(z)$, o taškuota ir punktyrinė kreivės, kai $\lambda T = 1$ ir $\lambda T = 2$, kertančiuose spiralės taškuose rodo eismo srauto nestabilumą.

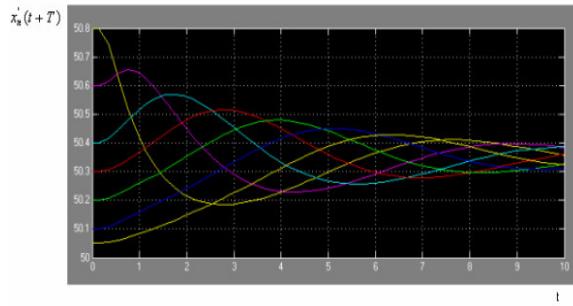
Patikriname gautus teorinius rezultatus modeliuojant SIMULINK'u.

2 ir 3 pav. matome, kad automobilių pagrečiai svyruoja, tačiau laikui bėgant konverguoja į pastovią reikšmę, o atstumai tarp mašinų stabilizuojasi.

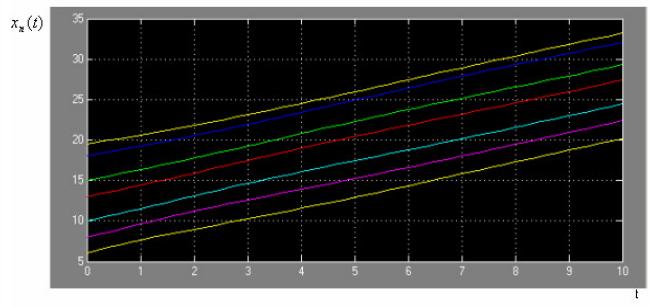


1 pav. Sistemos stabilumas ir nestabilumas

$$\lambda T = 0.24$$



2 pav. Automobilių greičiai laiko momentu t.



3 pav. Automobilių pozicijos laiko momentu t

Atlikus eilę bandymų, nustatyta, kad mikroskopinio eismo srauto stabilumas priklauso nuo vairuotojo reakcijos laiko T ir jautrumo parametru λ .

Išvada:

1. Teoriniai ir praktiniai rezultatai sutampa, mikroskopinis eismo srautas yra stabilus, kai $\lambda T < 0.5$ esant mažiemis greičių svyravimams.

Literatūra

1. Acha-Daza, J. A. and Hall F.L. Application of Catastrophe Theory to Traffic Flow Variables. Transport Research – B, 28B(3). Elsevier Science Ltd., 1994, p. 235–250.

2. Prigogine, I., and Herman R. Kinematic Theory of Vehicular Traffic. American Elsevier Publishing Co., New York, 1971.