

VILNIAUS UNIVERSITETAS
MATEMATIKOS IR INFORMATIKOS FAKULTETAS

MAGISTRO DARBAS

**Stochastinės Verhulsto lygties sprendinių
momentų aproksimavimas Fourier eilučių
dalinėmis sumomis**

**Approximation of moments of solutions to stochastic Verhulst
equation by partial sums of Fourier series**

Monika MAZURKEVIČIŪTĖ

Vilnius 2016

MATEMATINĖS ANALIZĖS KATEDRA

Darbo vadovas *prof. Vigirdas Mackevičius*

Darbo recenzentas *doc. dr. Martynas Manstavičius*

Darbas apgintas 2016 m. sausio 14 d.

Darbas įvertintas _____

Registravimo nr. _____

2016-01-04 _____

Stochastinės Verhulsto lygties sprendinių momentų aproksimavimas Fourier eilučių dalinėmis sumomis

Santrauka

Finansų matematikoje trumpojo laikotarpio palūkanų normų modeliavimui dažnai naudojama CIR procesą Mackevičius [5] pasiūlė keisti Verhulsto stochastine (SV) diferencialine lygtimi. Tačiau SV lygties sprendinių momentai nėra žinomi išreikštiniu pavidalu. Dėl šios priežasties [5] buvo pasiūlyta įvesti momentų uždarumo sąlygą, aprašomą lygtimi $q(t) = \mathbb{E}X_t^2 / \mathbb{E}X_t$. Baravykas magistriniame darbe [1] funkciją $q(t)$ aproksimavo Fourier eilučių dalinių sumų metodu. Šiame darbe tęsiame pradėtus tyrimus, pirma, Baravyko metodą pagerindami optimalių parametrų radimu ir skaičiavimų supaprastinimu. Antra, pasinaudodami tomis pačiomis Fourier eilučių dalinių sumų savybėmis sukonstruojame naują funkcijos $q(t)$ aproksimaciją, kuri ne tik duoda geresnius rezultatus, bet ir yra paprasčiau konstruojama. Skaičiavimai atlikti statistiniu paketu R.

Raktiniai žodžiai: Verhulsto lygtis, CIR lygtis, momentų uždarumo sąlyga, Fourier eilučių dalinės sumos, split-step metodas.

Approximation of moments of solutions to stochastic Verhulst equation by partial sums of Fourier series

Abstract

In financial mathematics, CIR process is widely used for modeling interest rates. Mackevičius [5] proposed, instead, to use the stochastic Verhulst process. The main disadvantage is that explicit expressions of moments are not known. Therefore, the moment closure condition $q(t) = \mathbb{E}X_t^2 / \mathbb{E}X_t$ was proposed. Baravykas in his master thesis [1] analyzed $q(t)$ approximations by the method of partial sums of Fourier series. In this diploma project, first, we continue research in this direction by optimizing freely chosen parameters and simplifying calculations. Second, using the same properties of partial sums of Fourier series, we construct a new $q(t)$ approximation that gives more accurate results and is easily implemented. For calculations, we use the statistical package R.

Key words: Verhulst equation, CIR equation, moment closure condition, partial sums of Fourier series, split-step method.

Turinys

Įvadas	3
1 Teorinė dalis	4
1.1 Apibrėžimai ir teoremos	4
1.2 Momentų uždarumo sąlyga	6
2 Fourier dalinių sumų metodas I	7
2.1 Pirmo tipo aproksimacija	7
2.2 Antro tipo aproksimacija	10
3 Fourier dalinių sumų metodas II	14
4 Rezultatai	18
4.1 Fourier dalinių sumų metodas I	18
4.1.1 Pirmas tankio tipas	18
4.1.2 Antras tankio tipas	20
4.1.3 Trečias tankio tipas	22
4.2 Fourier dalinių sumų metodas II	26
4.2.1 Pirmas tankio tipas	26
4.2.2 Antras tankio tipas	28
4.2.3 Trečias tankio tipas	29
4.3 Optimalaus τ priklausomybė nuo parametrų	31
Išvados	33
Literatūra	34
Priedai	35
A Fourier dalinių sumų metodas I	35
B Fourier dalinių sumų metodas II	41

Įvadas

Finansų matematikoje trumpojo laikotarpio palūkanų normų modeliavimui dažnai naudojamas CIR procesas, nusakomas stochastine diferencialine lygtimi

$$dX_t = \lambda(\mu - X_t)dt + \sigma\sqrt{X_t}dB_t, \quad X_0 = x > 0, \quad \sigma, \lambda, \mu \in \mathbb{R}^+. \quad (0.1)$$

Šis procesas patrauklus tuo, kad sprendiniai neįgyja neigiamų reikšmių (esant teigiamoms pradinėms reikšmėms), vidurkiai konverguoja į baigtinę reikšmę bei sprendinio momentai yra išreikštinio pavidalo. Nepaisant to, procesas turi kelis esminius trūkumus: nėra žinomas išreikštinis sprendinio pavidalas, o lygtyje esanti šaknis tik dar labiau apsunkina jo aproksimacijų radimą. Dėl šios priežasties Mackevičius [5] pasiūlė CIR lygtį keisti Verhulsto stochastine (SV) diferencialine lygtimi, plačiai naudojamą įvairiose srityse [2],

$$dX_t = \lambda X_t(\bar{\mu} - X_t)dt + \sigma X_t dB_t, \quad X_0 = x > 0; \quad (0.2)$$

čia $\bar{\mu} = \mu + \frac{\sigma^2}{2\lambda}$. Šios lygties sprendiniai, kaip ir CIR, yra neneigiami, jų vidurkiai konverguoja į baigtines reikšmes bei SV lygties sprendinio stacionarus tankis sutampa su CIR proceso stacionariuoju tankiu. Tai leidžia teigti, kad ilguoju laikotarpiu sprendinių tikimybinė elgsena supanašėja. Svarbiausia, kad SV lygties sprendinys yra lengvai randamas išreikštinio pavidalu (žr., pvz., [4]).

Kita vertus, lyginant su CIR, SV lygtis turi ir trūkumą – sprendinių momentai nėra žinomi išreikštinio pavidalu. Dėl šios priežasties [5] buvo pasiūlyta įvesti momentų uždarumo sąlygą, aprašomą lygtimi $q(t) = \mathbb{E}X_t^2 / \mathbb{E}X_t$. Kadangi SV lygties sprendinių momentai gali būti užrašomi rekurentiškai, tai sukonstravę funkcijos $q(t)$ aproksimacijas, galime gauti apytiksles visų momentų išraiškas.

Baravykas [1] funkciją $q(t)$ aproksimavo eksponentinių funkcijų sistemos $\{e^{-k\tau t}, k = 1, 2, 3\}$ tiesiniais dariniais, pasinaudodamas tų funkcijų sistemos ortogonalizavimu ir Fourier eilučių dalinių sumų savybėmis. Gautos funkcijos $q(t)$ aproksimacijos priklauso nuo laisvojo parametro τ , kuris darbe parenkamas bandymų keliu, o gauta apytikslė $q(t)$ funkcija pradinę sąlygą $q(0) = 1$ taip pat tenkina tik apytiksliai. Mūsų darbo pagrindiniai tikslai – rasti optimalų laisvajį parametą τ , išspręsti $q(t)$ „pradinio taško“ problemą bei supaprastinti reikalingus skaičiavimus.

Pagrindiniai šio darbo rezultatai yra šie:

- 1) Minimizuojant paklaidą tarp sukonstruotos aproksimacijos ir skaitiniais metodais gautos funkcijos, gautas optimalus parametras τ (2 skyrius);
- 2) Supaprastinti metodo skaičiavimai (2 skyrius);
- 3) Pasinaudojant tomis pačiomis Fourier eilučių dalinių sumų savybėmis, sukonstruota nauja funkcijos $q(t)$ aproksimacija, kuri išsprendė funkcijos $q(t)$ „pradinio taško“ problemą (3 skyrius).

Darbas sudarytas iš 4 skyrių. Pirmame skyriuje pateikiama visa reikalinga teorinė medžiaga apie SV lygties savybes, reikalingas momentų aproksimacijų modeliavimui. Antrame skyriuje tęsiamas Baravyko [1] pradėtos aproksimacijos konstravimas. Metodas pagerinamas optimalaus laisvojo parametro radimu bei supaprastintais skaičiavimais. Trečiame skyriuje konstruojama nauja funkcijos $q(t)$ aproksimacija bei pateikiami detalūs skaičiavimai. Taip pat gautai $q(t)$ aproksimacijai išvedamos pirmojo momento išraiškos bendruoju ir išimtiniais atvejais. Ketvirtame skyriuje apžvelgiami gauti rezultatai. Galiausiai pateikiamos darbo išvados ir apibendrinti rezultatai. Priede pateikiami programų kodai programavimo kalba R.

1 Teorinė dalis

Šiame skyriuje pateiksime visą teorinę medžiagą, reikalingą tolimesniam Verhulsto lygties sprendinių momentų aproksimavimui. Pradėsime nuo pagrindinių apibrėžimų ir teoremų, kurių mums prireiks.

1.1 Apibrėžimai ir teoremos

1.1 Apibrėžimas. Diskrečiojo laiko atsitiktinių procesų šeima X^h , $h > 0$ vadinama SDL sprendinio X n -tosios eilės *silpnąja aproksimacija*, jei su visais $t \in [0, T]$

$$\mathbf{E}f(X_t^h) - \mathbf{E}f(X_t) = O(h^n), \quad h \rightarrow 0,$$

pakankamai plačiai funkcijų $f : \mathbb{R} \rightarrow \mathbb{R}$ klasei.

1.2 Apibrėžimas. Stochastinės diferencialinės lygties

$$X_t = x_0 + \int_0^t b(X_s, s) ds + \int_0^t \sigma(X_s, s) dB_s, \quad t \geq 0,$$

kuriuos koeficientai b, σ tenkina sprendinio egzistavimo ir vienaties sąlygas, sprendinys X yra vadinamas *difuziniu procesu*.

1.3 Apibrėžimas. Sakoma, kad difuzinis procesas X su perėjimo tankiu $p(t, x, y)$ turi stacionarųjį tankį p_0 intervale (a, b) , jei

$$\int_a^b p(t, x, y) dy = 1, \quad t > 0, \quad x \in (a, b)$$

ir

$$p_0(y) = \int_a^b p(t, x, y) p_0(x) dx, \quad t > 0, \quad y \in (a, b).$$

1.4 Teorema. Stochastinės Verhulsto lygties *antros eilės split-step aproksimacija* apibrėžiama lygybe

$$\begin{aligned} \tilde{X}_t^h &:= \tilde{X}_t^h(x, h) = D \left(S \left(D \left(x, \frac{h}{2} \right), h \right), \frac{h}{2} \right) \\ &= \frac{\bar{\mu}}{1 + \exp \left\{ -\frac{1}{2} h \lambda \bar{\mu} \right\} \left(\exp \left\{ \frac{h \sigma^2}{2} - \sigma B_h \right\} \left(1 + \exp \left\{ -\frac{1}{2} h \lambda \bar{\mu} \right\} \left(\frac{\bar{\mu}}{x} - 1 \right) \right) - 1 \right)}, \end{aligned}$$

Čia:

$$D(x, t) := \frac{\bar{\mu}}{1 + \left(\frac{\bar{\mu}}{x} - 1 \right) \exp \left\{ -\lambda \bar{\mu} t \right\}}$$

yra *Verhulsto lygties deterministinės dalies sprendinys*.

Daugiau informacijos galite rasti [5].

Sakykime, \mathbf{E} yra realioji tiesinė erdvė su skaliarine sandauga $\langle \cdot, \cdot \rangle$.

1.5 Apibrėžimas. Skaičiai $c_k := c_k(x) = \langle x, \psi_k \rangle$, $k \in \mathbb{N}$, vadinami elemento $x \in \mathbf{E}$ Fourier koeficientais ortonormuotos sekos $(\psi_k, k \in \mathbb{N})$ atžvilgiu, o eilutė

$$\sum_k c_k \psi_k$$

vadinama elemento x Fourier eilute.

1.6 Apibrėžimas. Ortonormuotoji seka $(\psi_k, k \in \mathbb{N})$ vadinama erdvės \mathbf{E} ortonormuotąja baze, jei kiekvienas $x \in \mathbf{E}$ yra lygus atitinkamos Fourier eilutės sumai, t.y.

$$\sum_k c_k \psi_k$$

1.7 Teiginys. Verhulsto lygties (0.2) stacionarusis tankis yra gama skirstinio tankis

$$p_0(x) = \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} \exp\{-\beta x\}, \quad x \geq 0;$$


čia

$$\alpha = \frac{2\lambda\mu}{\sigma^2}, \quad \beta = \frac{2\lambda}{\sigma^2}.$$

Pastaba. Skiriami trys šio tankio tipai:

- 1) $0 < \alpha < 1 \Leftrightarrow 0 < \frac{2\lambda\mu}{\sigma^2} < 1 \Leftrightarrow \lambda\mu < \frac{\sigma^2}{2}$;
- 2) $1 < \alpha < 2 \Leftrightarrow 1 < \frac{2\lambda\mu}{\sigma^2} < 2 \Leftrightarrow \frac{\sigma^2}{2} < \lambda\mu < \sigma^2$;
- 3) $\alpha > 2 \Leftrightarrow \frac{2\lambda\mu}{\sigma^2} > 2 \Leftrightarrow \lambda\mu > \sigma^2$.

Atitinkamos tankio formos:



1 pav.: Gama skirstinio tankio formos

1.8 Teiginys. Lygties (0.2) sprendinio momentus galima išreikšti rekurentiškai. Pažymėjus

$$M_i(t) = \mathbb{E}X_t^i, \quad i = 1, 2, 3 \dots$$

turime:

$$M_i(t) = x_i + \int_0^\infty \left(\left(i\lambda\bar{\mu} + \frac{i(i-1)}{2}\sigma^2 \right) M_i(s) - i\lambda M_{i+1}(s) \right) ds. \quad (1.1)$$

1.9 Teiginys. Lygties (0.2) sprendinio pirmųjų dviejų momentų ribos yra lygios

$$\lim_{t \rightarrow \infty} M_1(t) = \frac{\alpha}{\beta} = \mu, \quad (1.2)$$

$$\lim_{t \rightarrow \infty} M_2(t) = \frac{\alpha(\alpha+1)}{\beta^2} = \mu\bar{\mu} = \mu \left(\mu + \frac{\sigma^2}{2\lambda} \right). \quad (1.3)$$

Šių teiginių įrodymus galima rasti [5].

1.2 Momentų uždarumo sąlyga

Stochastinės Verhulsto lygties momentai išreikštiniu pavidalu nėra žinomi, todėl naudosimės momentų uždarumo sąlyga, kuri apibrėžiama

$$q(t) = \frac{M_2(t)}{M_1^2(t)}, \quad t \geq 0. \quad (1.4)$$

Funkcija $q(t)$ pilnai apibrėžia visus momentus, tačiau išreikštiniu pavidalu nėra žinoma. Gerai parinkus apytikrę $q(t)$ išraišką, galima rasti apytiksles visų Verhulsto lygties sprendinių momentų reikšmes.

1.10 Teiginys.

$$q(\infty) := \lim_{t \rightarrow \infty} q(t) = 1 + \frac{\sigma^2}{2\lambda\mu}.$$

Irodymas. Išplaukia iš ribų (1.2) ir (1.3).

Pasinaudojus (1.1) lygtimi, gali būti išvesta pirmo momento bendra išraiška

$$M_1^{-1}(t) = e^{-\lambda\bar{\mu}t} \left(M_1^{-1}(0) + \lambda \int_0^t q(s) e^{\lambda\bar{\mu}s} ds \right). \quad (1.5)$$

Lygties išvedimas pateiktas [6].

Tuomet pasinaudojus momentų uždarumo sąlyga gauname:

$$M_2(t) = q(t)M_1^2(t)$$

2 Fourier dalinių sumų metodas I

Baravykas savo darbe [1] funkciją $q(t)$ aproksimavo eksponentinių funkcijų $f_k(t) = e^{-k\tau t}$, $k \in \mathbb{N}$ sistemos tiesiniais dariniais, pasinaudodamas tų funkcijų ortogonalizavimu ir Fourier eilučių dalinių sumų savybėmis. Tačiau jis parametrą τ parinkdavo bandymų keliu. Mūsų tikslas – kiekvienam parametrų $(\lambda, \sigma, \mu, x_0)$ rinkiniui rasti optimalų parametrą τ , kartu supaprastinant šio metodo skaičiavimus.

Pagrindinė šio metodo idėja – pasinaudojus skaitiniais metodais gautomis reikšmėmis, atsižvelgti į $q(t)$ elgesį trumpuoju laikotarpiu. Taip pat šis metodas remiasi faktu, kad mažiausi skirtumai nagrinėjamos normos prasme tarp funkcijos ir ortogonalios sistemos tiesinių darinių yra realizuojami būtent Fourier eilutės dalinėmis sumomis (žr. pvz. [3], p. 178).

Aproksimuojant q pagal erdvės $L^2[0, \infty)$ normą, neužtikrinama pradinė sąlyga $q(0) = 1$. Norint išvengti šio trūkumo, Lebesgue mato pustiesėje $[0, \infty)$ pridedamas diskretus matas, priskiriantis teigiamą reikšmę taškui 0 (plačiau [1]). Pažymėkime

$$m_0 = m + c\delta_0;$$

čia m yra Lesbegue matas, δ_0 – Diraco matas, o $c \in \mathbb{R}^+$ – konstanta, kuri bus parenkama vėliau. Tada erdvėje $L^2_{m_0}[0, \infty)$, kuriai priklauso visos mačios integruojamo kvadrato funkcijos $f : [0, \infty) \rightarrow \mathbb{R}$ mato m_0 atžvilgiu, norma yra

$$\|f\| = \left(\int_0^\infty f(s)^2 m_0(ds) \right)^{1/2} = \left(cf^2(0) + \int_0^\infty f^2(s) ds \right)^{1/2},$$

o skaliarinė sandauga

$$\langle f, g \rangle = cf(0)g(0) + \int_0^\infty f(s)g(s) ds.$$

Tada eksponentinių funkcijų $f_k(t) = e^{-k\tau t}$, $t \geq 0$, normos yra lygios

$$\|f_k\| = \left(cf_k^2(0) + \int_0^\infty e^{-2k\tau t} dt \right)^{1/2} = \sqrt{c + \frac{1}{2k\tau}}, \quad k \in \mathbb{N}.$$

2.1 Pirmo tipo aproksimacija

Žinodami $q(t)$ ribą begalybėje, ieškosime funkcijos

$$f(t) := \frac{(q(t) - 1)2\lambda\mu}{\sigma^2} - 1,$$

kurios riba $\lim_{t \rightarrow \infty} f(t) = 0$, aproksimacijos pavidalo

$$f(t) \approx \alpha_1 f_1(t) + \alpha_2 f_2(t) = \alpha_1 e^{-\tau t} + \alpha_2 e^{-2\tau t}.$$

Tam pirma ortonormuosime dviejų funkcijų sistemą $\{g_1, g_2\}$, po to funkciją f aproksimuosime tos ortonormuotosios sistemos Fourier suma ir galiausiai grįšime prie pradinių funkcijų $\{f_1, f_2\}$.

Toliau, ieškodami Fourier koeficientų, ortogonalizuojame pagal Schmidta:

$$\begin{aligned} g_1 &:= f_1, & g_2 &:= f_2 + a_{21}f_1, & \langle g_2, g_1 \rangle &= 0, & \Rightarrow \\ a_{21} &= -\frac{\langle f_2, g_1 \rangle}{\|g_1\|^2} = -\frac{c + \int_0^\infty e^{-3\tau s} ds}{c + \int_0^\infty e^{-2\tau s} ds} =: -\frac{A(3)}{A(2)}; \\ g_2 &= f_2 + a_{21}f_1 = e^{-2\tau t} + a_{21}e^{-\tau t}. \end{aligned}$$

Čia:

$$\begin{aligned} A(m) &:= c + \int_0^\infty e^{-m\tau s} ds = c + \frac{1}{m\tau}, \quad \text{kur } m = 1, 2, 3, \dots \\ a_{21} &:= -\frac{A(3)}{A(2)}, & a_{11} &:= \frac{1}{A(2)} = \frac{1}{\|g_1\|^2}. \end{aligned}$$

Pirmi du funkcijos $f(t)$ aproksimacijos Fourier eilutės nariai atrodo taip:

$$f(t) \approx \frac{\langle f, g_1 \rangle}{\|g_1\|^2} g_1(t) + \frac{\langle f, g_2 \rangle}{\|g_2\|^2} g_2(t). \quad (2.1)$$

Rasime $\|g_2\|^2$:

$$\begin{aligned} \|g_2\|^2 &= c g_2^2(0) + \int_0^\infty g_2^2(s) ds = c \left(1 - \frac{A(3)}{A(2)}\right)^2 + \int_0^\infty \left(e^{-2\tau s} - \frac{A(3)}{A(2)} e^{-\tau s}\right)^2 ds \\ &= c \left(1 - \frac{A(3)}{A(2)}\right)^2 + \frac{1}{4\tau} - \frac{2A(3)}{3\tau A(2)} + \frac{A(3)^2}{2\tau A(2)^2} \\ &= \underbrace{\left(c + \frac{1}{4\tau}\right)}_{A(4)} - 2 \frac{A(3)}{A(2)} \underbrace{\left(c + \frac{1}{3\tau}\right)}_{A(3)} + \left(\frac{A(3)}{A(2)}\right)^2 \underbrace{\left(c + \frac{1}{2\tau}\right)}_{A(2)} \\ &= A(4) - \frac{A(3)^2}{A(2)}. \end{aligned}$$

Pažymėkime $a_{22} := \frac{1}{\|g_2\|^2} = \frac{A(2)}{A(4)A(2) - A(3)^2}$.

Rasime pirmąjį funkcijos $f(t)$ aproksimacijos narį:

$$\begin{aligned} \frac{\langle f, g_1 \rangle}{\|g_1\|^2} g_1(t) &= \frac{1}{\|g_1\|^2} \left(c f(0) g_1(0) + \int_0^\infty f(s) g_1(s) ds \right) g_1(t) \\ &= a_{11} e^{-\tau t} \left(c f(0) + \int_0^\infty f(s) e^{-\tau s} ds \right). \end{aligned}$$

Rasime $\frac{\langle f, g_2 \rangle}{\|g_2\|^2}$ išraišką:

$$\begin{aligned} \frac{\langle f, g_2 \rangle}{\|g_2\|^2} &= \frac{1}{\|g_2\|^2} \left(c f(0) g_2(0) + \int_0^\infty f(s) g_2(s) ds \right) \\ &= a_{22} \left((1 + a_{21}) c f(0) + \int_0^\infty f(s) (e^{-2\tau s} + a_{21} e^{-\tau s}) ds \right). \end{aligned}$$

Rasime antrąjį funkcijos $f(t)$ aproksimacijos narį:

$$\frac{\langle f, g_2 \rangle}{\|g_2\|^2} g_2(t) = a_{22} \left((1 + a_{21}) c f(0) + \int_0^\infty f(s) (e^{-2\tau s} + a_{21} e^{-\tau s}) ds \right) (e^{-2\tau t} + a_{21} e^{-\tau t}).$$

Tada, pasinaudojus (3), rasime $f(t)$ aproksimacijos išraišką:

$$\begin{aligned}
f(t) &\approx a_{11}e^{-\tau t} \left(cf(0) + \int_0^\infty f(s)e^{-\tau s} ds \right) \\
&\quad + a_{22} \left((1 + a_{21})cf(0) + \int_0^\infty f(s) (e^{-2\tau s} + a_{21}e^{-\tau s}) ds \right) (e^{-2\tau t} + a_{21}e^{-\tau t}) \\
&= \left(\underbrace{(a_{11} + a_{21}a_{22}(1 + a_{21}))}_{\beta_{10}} cf(0) + \underbrace{(a_{11} + a_{21}^2 a_{22})}_{\beta_{11}} \int_0^\infty f(s)e^{-\tau s} ds \right. \\
&\quad \left. + \underbrace{a_{21}a_{22}}_{\beta_{12}} \int_0^\infty f(s)e^{-2\tau s} ds \right) e^{-\tau t} \\
&\quad + \left(\underbrace{a_{22}(1 + a_{21})}_{\beta_{20}} cf(0) + \underbrace{a_{21}a_{22}}_{\beta_{21}} \int_0^\infty f(s)e^{-\tau s} ds + \underbrace{a_{22}}_{\beta_{22}} \int_0^\infty e^{-2\tau s} ds \right) e^{-2\tau t} \\
&= \left(\beta_{10}f(0) + \beta_{11} \int_0^\infty f(s)e^{-\tau s} ds + \beta_{12} \int_0^\infty f(s)e^{-2\tau s} ds \right) e^{-\tau t} \\
&\quad + \left(\beta_{20}f(0) + \beta_{21} \int_0^\infty f(s)e^{-\tau s} ds + \beta_{22} \int_0^\infty f(s)e^{-2\tau s} ds \right) e^{-2\tau t} \\
&=: \alpha_1 e^{-\tau t} + \alpha_2 e^{-2\tau t}.
\end{aligned} \tag{2.2}$$

Rasime paklaidą tarp skaitiniais metodais gautos funkcijos $\tilde{f}(t)$ bei sukonstruotos funkcijos $f(t)$ pirmo tipo aproksimacijos:

$$\begin{aligned}
\epsilon(\tau) &= \int_0^\infty (\tilde{f}(t) - f(t))^2 m_0(dt) = \left\| \tilde{f} - \sum_{i=1}^2 \frac{\langle f, g_i \rangle}{\|g_i\|^2} g_i \right\|^2 \\
&= \left\langle \tilde{f} - \sum_{i=1}^2 \frac{\langle f, g_i \rangle}{\|g_i\|^2} g_i, \tilde{f} - \sum_{i=1}^2 \frac{\langle f, g_i \rangle}{\|g_i\|^2} g_i \right\rangle \\
&= \|\tilde{f}\|^2 - 2 \sum_{i=1}^2 \frac{\langle f, g_i \rangle^2}{\|g_i\|^2} + \sum_{i=1}^2 \frac{\langle f, g_i \rangle^2}{\|g_i\|^4} \|g_i\|^2 = \|\tilde{f}\|^2 - \sum_{i=1}^2 \frac{\langle f, g_i \rangle^2}{\|g_i\|^2} \\
&= \|\tilde{f}\|^2 - a_{11} \langle f, g_1 \rangle^2 - a_{22} \langle f, g_2 \rangle^2 = \|\tilde{f}\|^2 - a_{11} \left(cf(0) + \int_0^\infty f(s)e^{-\tau s} ds \right)^2 \\
&\quad - a_{22} \left((1 + a_{21})cf(0) + a_{21} \int_0^\infty f(s)e^{-\tau s} ds + \int_0^\infty f(s)e^{-2\tau s} ds \right)^2.
\end{aligned} \tag{2.3}$$

Ši vidutinė kvadratinė paklaida priklauso nuo laisvojo parametro τ , kuris, kaip minėta, Baravyko darbe [1] buvo parenkamas bandymo keliu. Mūsų tikslas – rasti optimalų parametą τ , su kuriuo gauta paklaida būtų minimali. Skaičiavimams atlikti naudosimės programa R. Fourier koeficientus galime apytiksliai apskaičiuoti integralus pakeisdami Riemano sumomis nagrinėjamame intervale $[0, T]$, o $f(s)$ – skaitiniais metodais gautomis funkcijos aproksimacijomis. Optimalaus τ radimui naudosimės programos R funkcija `optimize`.

Pasinaudojus sukonstruota funkcijos $f(t)$ pirmojo tipo aproksimacija, gaunama $q(t)$ aproksimacija pavidalo

$$q(t) \approx 1 + \frac{\sigma^2}{2\lambda\mu} (1 + \alpha_1 e^{-\tau t} + \alpha_2 e^{-2\tau t}).$$

Gautai $q(t)$ aproksimacijai pirmo momento išraiška randama pasinaudojus lygtimi (1.5):

$$\begin{aligned}
M_1^{-1}(t) &\approx e^{-\lambda\bar{\mu}t} \left(\frac{1}{x} + \lambda \int_0^t \left(1 + \frac{\sigma^2}{2\lambda\mu} (1 + \alpha_1 e^{-\tau s} + \alpha_2 e^{-2\tau s}) \right) e^{\lambda\bar{\mu}s} ds \right) \\
&= e^{-\lambda\bar{\mu}t} \left(\frac{1}{x} + \lambda \int_0^t \left(1 + \frac{\sigma^2}{2\lambda\mu} \right) e^{\lambda\bar{\mu}s} + \frac{\alpha_1\sigma^2}{2\lambda\mu} e^{-\tau s + \lambda\bar{\mu}s} + \frac{\alpha_2\sigma^2}{2\lambda\mu} e^{-2\tau s + \lambda\bar{\mu}s} ds \right) \\
&= e^{-\lambda\bar{\mu}t} \left(\frac{1}{x} + \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} e^{\lambda\bar{\mu}s} \Big|_0^t + \frac{\alpha_1\sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} e^{\lambda\bar{\mu}s - \tau s} \Big|_0^t + \frac{\alpha_2\sigma^2}{2\mu(\lambda\bar{\mu} - 2\tau)} e^{\lambda\bar{\mu}s - 2\tau s} \Big|_0^t \right) \\
&= \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} + \left(\frac{1}{x} - \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} - \frac{\alpha_1\sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} - \frac{\alpha_2\sigma^2}{2\mu(\lambda\bar{\mu} - 2\tau)} \right) e^{-\lambda\bar{\mu}t} \\
&\quad + \frac{\alpha_1\sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} e^{-\tau t} + \frac{\alpha_2\sigma^2}{2\mu(\lambda\bar{\mu} - 2\tau)} e^{-2\tau t}.
\end{aligned}$$

Iš čia:

$$\begin{aligned}
M_1(t) &\approx 2\mu \left(\frac{2\lambda\mu + \sigma^2}{\lambda\bar{\mu}} + \left(\frac{2\mu}{x} - \frac{2\lambda\mu + \sigma^2}{\lambda\bar{\mu}} - \frac{\alpha_1\sigma^2}{\lambda\bar{\mu} - \tau} - \frac{\alpha_2\sigma^2}{\lambda\bar{\mu} - 2\tau} \right) e^{-\lambda\bar{\mu}t} \right. \\
&\quad \left. + \frac{\alpha_1\sigma^2}{\lambda\bar{\mu} - \tau} e^{-\tau t} + \frac{\alpha_2\sigma^2}{\lambda\bar{\mu} - 2\tau} e^{-2\tau t} \right)^{-1}.
\end{aligned} \tag{2.4}$$

Matome, kad pirmas momentas būtų neapibrėžtas, jei $\tau = \lambda\bar{\mu}$, todėl, šiuo atveju, analogiškai išvedama kitokia pirmo momento išraiška

$$\begin{aligned}
M_1^{-1}(t) &\approx e^{-\lambda\bar{\mu}t} \left(\frac{1}{x} + \lambda \int_0^t \left(1 + \frac{\sigma^2}{2\lambda\mu} (1 + \alpha_1 e^{-\lambda\bar{\mu}s} + \alpha_2 e^{-2\tau s}) \right) e^{\lambda\bar{\mu}s} ds \right) \\
&= \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} + \left(\frac{1}{x} - \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} + \frac{\alpha_1\sigma^2 t}{2\mu} - \frac{\alpha_2\sigma^2}{2\mu(\lambda\bar{\mu} - 2\tau)} \right) e^{-\lambda\bar{\mu}t} \\
&\quad + \frac{\alpha_2\sigma^2}{2\mu(\lambda\bar{\mu} - 2\tau)} e^{-2\tau t}; \\
M_1(t) &\approx 2\mu \left(\frac{2\lambda\mu + \sigma^2}{\lambda\bar{\mu}} + \left(\frac{2\mu}{x} - \frac{2\lambda\mu + \sigma^2}{\lambda\bar{\mu}} + \alpha_1\sigma^2 t - \frac{\alpha_2\sigma^2}{\lambda\bar{\mu} - 2\tau} \right) e^{-\lambda\bar{\mu}t} \right. \\
&\quad \left. + \frac{\alpha_2\sigma^2}{\lambda\bar{\mu} - 2\tau} e^{-2\tau t} \right)^{-1}.
\end{aligned}$$

Kai $2\tau = \lambda\bar{\mu}$, taip pat turime neapibrėžtumą, kurį panaikinus, pirmo momento išraiška atrodo taip:

$$\begin{aligned}
M_1(t) &\approx 2\mu \left(\frac{2\lambda\mu + \sigma^2}{\lambda\bar{\mu}} + \left(\frac{2\mu}{x} - \frac{2\lambda\mu + \sigma^2}{\lambda\bar{\mu}} - \frac{\alpha_1\sigma^2}{\lambda\bar{\mu} - \tau} + \alpha_2\sigma^2 t \right) e^{-\lambda\bar{\mu}t} \right. \\
&\quad \left. + \frac{\alpha_1\sigma^2}{\lambda\bar{\mu} - \tau} e^{-\tau t} \right)^{-1}.
\end{aligned}$$

2.2 Antro tipo aproksimacija

Siekdami gauti tikslesnius rezultatus, funkciją $f(t)$ aproksimuosime trimis eksponentėmis. Naudodamiesi tuo pačiu algoritmu, ortonormuosime trijų funkcijų sistemą $\{g_1, g_2, g_3\}$, po to funkciją f aproksimuosime tos ortonormuotosios sistemos Fourier eilutės daline suma ir galiausiai grįšime prie pradinių funkcijų $\{f_1, f_2, f_3\}$.

Toliau analogiškai ortogonalizuojame pagal Schmidta:

$$\begin{aligned}
g_3 &:= f_3 + a_{31}g_1 + a_{32}g_2, \quad \langle g_3, g_1 \rangle = \langle g_3, g_2 \rangle = 0 \quad \Rightarrow \\
a_{31} &:= -\frac{\langle f_3, g_1 \rangle}{\|g_1\|^2} = -\frac{c + \int_0^\infty e^{-4\tau s} ds}{c + \int_0^\infty e^{-2\tau s} ds} = -\frac{A(4)}{A(2)}; \\
a_{32} &:= -\frac{\langle f_3, g_2 \rangle}{\|g_2\|^2} = -\frac{\langle f_3, f_2 \rangle + a_{21} \langle f_3, f_1 \rangle}{\|g_2\|^2} \\
&= -\frac{(c + \int_0^\infty e^{-5\tau s} ds) + a_{21}(c + \int_0^\infty e^{-4\tau s} ds)}{\|g_2\|^2} \\
&= a_{22}(A(5) + a_{21}A(4)).
\end{aligned}$$

Tada

$$\begin{aligned}
g_3 &= f_3 + a_{31}g_1 + a_{32}g_2 = e^{-3\tau t} + a_{31}e^{-\tau t} + a_{32}(e^{-2\tau t} + a_{21}e^{-\tau t}) \\
&= e^{-3\tau t} + a_{32}e^{-2\tau t} + (a_{31} + a_{32}a_{21})e^{-\tau t}.
\end{aligned}$$

Pirmi trys funkcijos $f(t)$ aproksimacijos Fourier eilutės nariai atrodo taip:

$$f(t) \approx \frac{\langle f, g_1 \rangle}{\|g_1\|^2} g_1(t) + \frac{\langle f, g_2 \rangle}{\|g_2\|^2} g_2(t) + \frac{\langle f, g_3 \rangle}{\|g_3\|^2} g_3(t). \quad (2.5)$$

Rasime g_3 normą:

$$\begin{aligned}
\|g_3\|^2 &= cg_3^2(0) + \int_0^\infty g_3^2(s) ds = cg_3^2(0) + \int_0^\infty \left(e^{-3\tau s} + a_{32}e^{-2\tau s} + (a_{31} + a_{32}a_{21})e^{-\tau s} \right)^2 ds \\
&= cg_3^2(0) + \int_0^\infty \left(e^{-6\tau s} + a_{32}^2 e^{-4\tau s} + (a_{31} + a_{32}a_{21})^2 e^{-2\tau s} + 2a_{32}e^{-5\tau s} + 2(a_{31} + a_{32}a_{21})e^{-4\tau s} \right. \\
&\quad \left. + 2a_{32}(a_{31} + a_{32}a_{21})e^{-3\tau s} \right) ds = c(1 + a_{32} + a_{31} + a_{32}a_{21})^2 + \frac{1}{6\tau} + \left(a_{32}^2 + 2(a_{31} + a_{32}a_{21}) \right) \frac{1}{4\tau} \\
&\quad + (a_{31} + a_{32}a_{21})^2 \frac{1}{2\tau} + 2a_{32} \frac{1}{5\tau} + 2a_{32}(a_{31} + a_{32}a_{21}) \frac{1}{3\tau}.
\end{aligned} \quad (2.6)$$

Analogiškai kaip ir anksčiau, pažymėkime $a_{33} := \frac{1}{\|g_3\|^2}$.

Pirmi du funkcijos $f(t)$ aproksimacijos nariai mums jau žinomi. Rasime trečiąjį:

$$\begin{aligned}
\frac{\langle f, g_3 \rangle}{\|g_3\|^2} g_3(t) &= a_{33} \left(cf(0)g_3(0) + \int_0^\infty f(s) \left(e^{-3\tau s} + a_{32}e^{-2\tau s} + (a_{31} + a_{32}a_{21})e^{-\tau s} \right) ds \right) \\
&\quad * \left(e^{-3\tau t} + a_{32}e^{-2\tau t} + (a_{31} + a_{32}a_{21})e^{-\tau t} \right).
\end{aligned} \quad (2.7)$$

Pasinaudoję (2.5) lygybe, gauname:

$$\begin{aligned}
f(t) &\approx \frac{\langle f, g_1 \rangle}{\|g_1\|^2} g_1(t) + \frac{\langle f, g_2 \rangle}{\|g_2\|^2} g_2(t) + \frac{\langle f, g_3 \rangle}{\|g_3\|^2} g_3(t) \\
&= \left(\beta'_{10}f(0) + \int_0^\infty f(s) (\beta'_{11}e^{-\tau s} + \beta'_{12}e^{-2\tau s} + \beta'_{13}e^{-3\tau s}) ds \right) e^{-\tau t} \\
&\quad + \left(\beta'_{20}f(0) + \int_0^\infty f(s) (\beta'_{21}e^{-\tau s} + \beta'_{22}e^{-2\tau s} + \beta'_{23}e^{-3\tau s}) ds \right) e^{-2\tau t} \\
&\quad + \left(\beta'_{30}f(0) + \int_0^\infty f(s) (\beta'_{31}e^{-\tau s} + \beta'_{32}e^{-2\tau s} + \beta'_{33}e^{-3\tau s}) ds \right) e^{-3\tau t}.
\end{aligned} \quad (2.8)$$

Čia:

$$\begin{aligned}
\beta'_{10} &= \beta_{10} + ca_{33}(a_{31} + a_{32}a_{21})(1 + a_{32} + a_{31} + a_{32}a_{21}); \\
\beta'_{11} &= \beta_{11} + a_{33}(a_{31} + a_{32}a_{21})^2; \\
\beta'_{12} &= \beta_{12} + a_{33}a_{32}(a_{31} + a_{32}a_{21}); \\
\beta'_{13} &= a_{33}(a_{31} + a_{32}a_{21}); \\
\beta'_{20} &= \beta_{20} + ca_{33}a_{32}(1 + a_{32} + a_{31} + a_{32}a_{21}); \\
\beta'_{21} &= \beta_{21} + a_{33}a_{32}(a_{31} + a_{32}a_{21}); \\
\beta'_{22} &= \beta_{22} + a_{33}a_{32}^2; \\
\beta'_{23} &= a_{33}a_{32}; \\
\beta'_{30} &= ca_{33}(1 + a_{32} + a_{31} + a_{32}a_{21}); \\
\beta'_{31} &= a_{33}(a_{31} + a_{32}a_{21}); \\
\beta'_{32} &= a_{33}a_{32}; \\
\beta'_{33} &= a_{33}.
\end{aligned} \tag{2.9}$$

Kaip ir pirmojo aproksimacijos tipo atveju, rasime paklaidą tarp skaitiniais metodais gautos funkcijos $\tilde{f}(t)$ bei sukontruotos funkcijos $f(t)$ antro tipo aproksimacijos:

$$\begin{aligned}
\epsilon(\tau) &= \int_0^\infty (\tilde{f}(t) - f(t, \tau))^2 m_0(dt) = \|\tilde{f}\|^2 - \sum_{i=1}^3 \frac{\langle f, g_i \rangle^2}{\|g_i\|^2} \\
&= \|\tilde{f}\|^2 - (a_{11} \langle f, g_1 \rangle^2 + a_{22} \langle f, g_2 \rangle^2 + a_{33} \langle f, g_3 \rangle^2) \\
&= \|\tilde{f}\|^2 - a_{11} \left(cf(0) + \int_0^\infty f(s)e^{-\tau s} ds \right)^2 \\
&\quad - a_{22} \left((1 + a_{21})cf(0) + a_{21} \int_0^\infty f(s)e^{-\tau s} ds + \int_0^\infty f(s)e^{-2\tau s} ds \right)^2 \\
&\quad - a_{33} \left(cf(0)g_3(0) + (a_{31} + a_{32}a_{21}) \int_0^\infty f(s)e^{-\tau s} ds + a_{32} \int_0^\infty f(s)e^{-2\tau s} ds + \int_0^\infty f(s)e^{-3\tau s} ds \right)^2.
\end{aligned}$$

Toliau analogiškai minimizavę paklaidą ϵ , gausime optimalų parametą τ , kurią naudosime funkcijos $f(t)$ antro tipo aproksimacijos radimui.

Pasinaudojus lygybe $q(t) = \frac{(f(t)+1)\sigma^2}{2\lambda\mu} + 1$, gaunama tokio pavidalo funkcijos $q(t)$ aproksimacija:

$$q(t) \approx 1 + \frac{\sigma^2}{2\lambda\mu} (1 + \alpha_1 e^{-\tau t} + \alpha_2 e^{-2\tau t} + \alpha_3 e^{-3\tau t}).$$

Šiuo atveju, pirmo momento išraiška, gaunama remiantis lygtimi (1.5), bendruoju atveju atrodo

taip:

$$\begin{aligned}
M_1^{-1}(t) &\approx e^{-\lambda\bar{\mu}t} \left(\frac{1}{x} + \lambda \int_0^t \left(1 + \frac{\sigma^2}{2\lambda\mu} (1 + \alpha_1 e^{-\tau s} + \alpha_2 e^{-2\tau s} + \alpha_3 e^{-3\tau s}) \right) e^{\lambda\bar{\mu}s} ds \right) \\
&= \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} + \left(\frac{1}{x} - \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} - \frac{\alpha_1\sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} - \frac{\alpha_2\sigma^2}{2\mu(\lambda\bar{\mu} - 2\tau)} \right. \\
&\quad \left. - \frac{\alpha_3\sigma^2}{2\mu(\lambda\bar{\mu} - 3\tau)} \right) e^{-\lambda\bar{\mu}t} + \frac{\alpha_1\sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} e^{-\tau t} + \frac{\alpha_2\sigma^2}{2\mu(\lambda\bar{\mu} - 2\tau)} e^{-2\tau t} \\
&\quad + \frac{\alpha_3\sigma^2}{2\mu(\lambda\bar{\mu} - 3\tau)} e^{-3\tau t} \tag{2.10} \\
M_1(t) &\approx 2\mu \left(\frac{2\lambda\mu + \sigma^2}{\lambda\bar{\mu}} + \left(\frac{2\mu}{x} - \frac{2\lambda\mu + \sigma^2}{\lambda\bar{\mu}} - \frac{\alpha_1\sigma^2}{\lambda\bar{\mu} - \tau} - \frac{\alpha_2\sigma^2}{\lambda\bar{\mu} - 2\tau} - \frac{\alpha_3\sigma^2}{\lambda\bar{\mu} - 3\tau} \right) e^{-\lambda\bar{\mu}t} \right. \\
&\quad \left. + \frac{\alpha_1\sigma^2}{\lambda\bar{\mu} - \tau} e^{-\tau t} + \frac{\alpha_2\sigma^2}{\lambda\bar{\mu} - 2\tau} e^{-2\tau t} + \frac{\alpha_3\sigma^2}{\lambda\bar{\mu} - 3\tau} e^{-3\tau t} \right)^{-1}
\end{aligned}$$

Kaip matome, ir šį kartą turime atsižvelgti į išimtinius atvejus bei rasti kitokias momentų išraiškas, kai

- $\tau = \lambda\bar{\mu}$:

$$\begin{aligned}
M_1(t) &\approx 2\mu \left(\frac{2\lambda\mu + \sigma^2}{\lambda\bar{\mu}} + \left(\frac{2\mu}{x} - \frac{2\lambda\mu + \sigma^2}{\lambda\bar{\mu}} + \alpha_1\sigma^2 t - \frac{\alpha_2\sigma^2}{\lambda\bar{\mu} - 2\tau} - \frac{\alpha_3\sigma^2}{\lambda\bar{\mu} - 3\tau} \right) e^{-\lambda\bar{\mu}t} \right. \\
&\quad \left. + \frac{\alpha_2\sigma^2}{\lambda\bar{\mu} - 2\tau} e^{-2\tau t} + \frac{\alpha_3\sigma^2}{\lambda\bar{\mu} - 3\tau} e^{-3\tau t} \right)^{-1}
\end{aligned}$$

- $2\tau = \lambda\bar{\mu}$:

$$\begin{aligned}
M_1(t) &\approx 2\mu \left(\frac{2\lambda\mu + \sigma^2}{\lambda\bar{\mu}} + \left(\frac{2\mu}{x} - \frac{2\lambda\mu + \sigma^2}{\lambda\bar{\mu}} - \frac{\alpha_1\sigma^2}{\lambda\bar{\mu} - \tau} + \alpha_2\sigma^2 t - \frac{\alpha_3\sigma^2}{\lambda\bar{\mu} - 3\tau} \right) e^{-\lambda\bar{\mu}t} \right. \\
&\quad \left. + \frac{\alpha_1\sigma^2}{\lambda\bar{\mu} - \tau} e^{-\tau t} + \frac{\alpha_3\sigma^2}{\lambda\bar{\mu} - 3\tau} e^{-3\tau t} \right)^{-1}
\end{aligned}$$

- $3\tau = \lambda\bar{\mu}$:

$$\begin{aligned}
M_1(t) &\approx 2\mu \left(\frac{2\lambda\mu + \sigma^2}{\lambda\bar{\mu}} + \left(\frac{2\mu}{x} - \frac{2\lambda\mu + \sigma^2}{\lambda\bar{\mu}} - \frac{\alpha_1\sigma^2}{\lambda\bar{\mu} - \tau} - \frac{\alpha_2\sigma^2}{\lambda\bar{\mu} - 2\tau} + \alpha_3\sigma^2 t \right) e^{-\lambda\bar{\mu}t} \right. \\
&\quad \left. + \frac{\alpha_1\sigma^2}{\lambda\bar{\mu} - \tau} e^{-\tau t} + \frac{\alpha_2\sigma^2}{\lambda\bar{\mu} - 2\tau} e^{-2\tau t} \right)^{-1}
\end{aligned}$$

3 Fourier dalinių sumų metodas II

Prieš tai aprašytame metode pavyko optimizuoti laisvąjį parametą τ ir, kaip matysime vėliau, gauti pakankamai tikslias funkcijos $q(t)$ aproksimacijas. Tačiau aproksimuotos funkcijos q reikšmė pradiniam taške gaunama tik apytikriai lygi 1, nes q aproksimuojuama tik kvadratinio vidurkio prasme. Šio trūkumo pavyksta išvengti funkciją q aproksimuojant specialiai parinkta eksponentinio tipo funkcijų šeima, tenkinančia šią pradinę sąlygą.

Visų pirma yra žinoma, kad funkcija $q(t)$, kurią aproksimuosime, tenkina tokias pradines sąlygas:

- $q(0) = 1$
- $\lim_{t \rightarrow \infty} q(t) = 1 + \frac{\sigma^2}{2\lambda\mu}$.

Pažymėkime $q_0(t) := 1 + a - ae^{-\tau t}$, $a = \frac{\sigma^2}{2\lambda\mu}$. Šios funkcijos reikšmės galiniuose intervalo $(0, +\infty)$ taškuose 0 ir $+\infty$ sutampa su funkcijos q reikšmėmis tuose taškuose.

Ieškosime funkcijos $h(t) := q(t) - q_0(t)$ aproksimacijos Fourier eilučių dalinių sumų metodu. Ši funkcija taškuose $\{0, +\infty\}$ lygi 0, todėl ją aproksimuosime kvadratinio vidurkio prasme eksponentinio tipo funkcijomis, kurios tuose taškuose taip pat lygios 0. Taip visų pirma gausime funkcijos q aproksimaciją, kurios reikšmės intervalo galuose automatiškai sutampa su pačios funkcijos q reikšmėmis. Antra, išvengsime būtinybės priskirti taškui 0 papildomą svorį, dėl kurio anksčiau ženkliai pasunkėjo skaičiavimai. Taigi funkciją h aproksimuosime erdvėje $L^2[0, \infty)$ su įprastine norma

$$\|f\| = \left(\int_0^\infty f^2(s) ds \right)^{1/2}$$

ir skaliarine sandauga

$$\langle f, g \rangle = \int_0^\infty f(s)g(s) ds.$$

Funkcijos $h(t)$ aproksimavimui pasirinkome gana paprastas funkcijas

$$f_1(t) = e^{-\tau t} - e^{-2\tau t} \quad \text{ir} \quad f_2(t) = e^{-2\tau t} - e^{-3\tau t},$$

kurios lygios 0 intervalo $(0, +\infty)$ galuose. Šią porą ortogonalizuosime, gaudami dviejų ortogonalinių funkcijų porą $\{g_1, g_2\}$, po to funkciją h aproksimuosime tos ortogonalios sistemos Fourier eilutės daline suma ir galiausiai grįšime prie funkcijos h aproksimacijos pradinių funkcijų $\{f_1, f_2\}$ tiesiniu dariniu.

Kaip ir anksčiau, porą $\{f_1, f_2\}$ ortogonalizuojame pagal Schmidą. Pažymėkime

$$g_1 := f_1 = e^{-\tau t} - e^{-2\tau t};$$

$$g_2 := f_2 + a_{21}f_1.$$

Pasinaudodami tuo, kad $\langle g_1, g_2 \rangle = 0$, randame

$$a_{21} := -\frac{\langle g_1, f_2 \rangle}{\langle g_1, g_1 \rangle} = -\frac{2}{5}.$$

- $\langle g_1, f_2 \rangle = \int_0^\infty (e^{-\tau t} - e^{-2\tau t})(e^{-2\tau t} - e^{-3\tau t}) dt = \int_0^\infty (e^{-3\tau t} - 2e^{-4\tau t} + e^{-5\tau t}) dt$
 $= \frac{1}{3\tau} - \frac{1}{2\tau} + \frac{1}{5\tau} = \frac{1}{30\tau};$
- $\langle g_1, g_1 \rangle = \|g_1\|^2 = \int_0^\infty (e^{-\tau t} - e^{-2\tau t})^2 dt = \int_0^\infty (e^{-2\tau t} - 2e^{-3\tau t} + e^{-4\tau t}) dt$
 $= \frac{1}{2\tau} - \frac{2}{3\tau} + \frac{1}{4\tau} = \frac{1}{12\tau}.$

Iš čia

$$g_2 := f_2 + a_{21}f_1 = e^{-2\tau t} - e^{-3\tau t} - \frac{2}{5}e^{-\tau t} + \frac{2}{5}e^{-2\tau t} = \frac{7}{5}e^{-2\tau t} - e^{-3\tau t} - \frac{2}{5}e^{-\tau t}.$$

Randame funkcijos g_2 normą erdvėje $L^2[0, \infty)$:

$$\begin{aligned} \|g_2\|^2 &= \int_0^\infty \left(\frac{7}{5}e^{-2\tau t} - e^{-3\tau t} - \frac{2}{5}e^{-\tau t} \right)^2 dt \\ &= \int_0^\infty \left(\frac{49}{25}e^{-4\tau t} + \frac{4}{25}e^{-2\tau t} + e^{-6\tau t} - \frac{28}{25}e^{-3\tau t} - \frac{14}{5}e^{-5\tau t} + \frac{4}{5}e^{-4\tau t} \right) dt \\ &= \frac{49}{100\tau} + \frac{4}{50\tau} + \frac{1}{6\tau} - \frac{28}{75\tau} - \frac{14}{25\tau} + \frac{4}{20\tau} = \frac{1}{300\tau}. \end{aligned}$$

Galiausiai, pirmieji funkcijos $h(t)$ Fourier eilutės nariai randami iš lygybės

$$\begin{aligned} h(t) &\approx \frac{\langle h, g_1 \rangle}{\|g_1\|^2} g_1 + \frac{\langle h, g_2 \rangle}{\|g_2\|^2} g_2 \\ &= \left(12\tau \int_0^\infty h(t)g_1(t)dt \right) g_1(t) + \left(300\tau \int_0^\infty h(t)g_2(t)dt \right) g_2(t) \\ &= \left(12\tau \int_0^\infty h(t)g_1(t)dt - 120\tau \int_0^\infty h(t)g_2(t)dt \right) e^{-\tau t} \\ &\quad + \left(-12\tau \int_0^\infty h(t)g_1(t)dt + 420\tau \int_0^\infty h(t)g_2(t)dt \right) e^{-2\tau t} \\ &\quad - \left(300\tau \int_0^\infty h(t)g_2(t)dt \right) e^{-3\tau t} =: \alpha_1 e^{-\tau t} + \alpha_2 e^{-2\tau t} + \alpha_3 e^{-3\tau t}. \end{aligned} \tag{3.1}$$

Šiuo atveju funkcija $h(t)$ taip pat priklauso nuo parametro τ . Norėdami jį optimizuoti, rasime paklaidą tarp skaitiniais metodais gautos funkcijos $\tilde{h}(t)$ bei sukontruotos funkcijos $h(t)$ aproksimacijos:

$$\begin{aligned} \epsilon(\tau) &= \int_0^\infty \left(\tilde{h}(t) - h(t) \right)^2 dt = \left\| \tilde{h} - \sum_{i=1}^2 \frac{\langle h, g_i \rangle}{\|g_i\|^2} g_i \right\|^2 \\ &= \left\langle \tilde{h} - \sum_{i=1}^2 \frac{\langle h, g_i \rangle}{\|g_i\|^2} g_i, \tilde{h} - \sum_{i=1}^2 \frac{\langle h, g_i \rangle}{\|g_i\|^2} g_i \right\rangle \\ &= \|\tilde{h}\|^2 - 2 \sum_{i=1}^2 \frac{\langle h, g_i \rangle^2}{\|g_i\|^2} + \sum_{i=1}^2 \frac{\langle h, g_i \rangle^2}{\|g_i\|^4} \|g_i\|^2 \\ &= \|\tilde{h}\|^2 - \sum_{i=1}^2 \frac{\langle h, g_i \rangle^2}{\|g_i\|^2} \\ &= \int_0^\infty \left(\tilde{q}(t) - q_0(t) \right)^2 dt - 12\tau \left(\int_0^\infty h(t)g_1(t)dt \right)^2 - 300\tau \left(\int_0^\infty h(t)g_2(t)dt \right)^2. \end{aligned} \tag{3.2}$$

Minimizuodami funkciją $\epsilon(\tau)$, randame optimalų parametą τ , kuri toliau naudojame funkcijos $h(t)$ aproksimacijos reikšmėms gauti.

Turėdami funkcijos $h(t)$ aproksimacijos reikšmes ir pasinaudoję lygybe $h(t) = q(t) - q_0(t)$, gauname funkcijos $q(t)$ aproksimaciją pavidalo

$$q(t) \approx 1 + \frac{\sigma^2}{2\lambda\mu} + \left(\alpha_1 - \frac{\sigma^2}{2\lambda\mu} \right) e^{-\tau t} + \alpha_2 e^{-2\tau t} + \alpha_3 e^{-3\tau t}.$$

Paprastumo dėlei šiame darbe šiuo būdu gautą funkcijos $q(t)$ aproksimaciją vadinsime tiesiog trečio tipo aproksimacija.

Toliau šiam $q(t)$ aproksimacijos tipui rasime pirmo momento išraiškas bendruoju ir išimtiniais atvejais.

Pirmo momento išraiška, gaunama remiantis lygtimi (1.5), bendruoju atveju atrodo taip:

$$\begin{aligned}
M_1^{-1}(t) &\approx e^{-\lambda\bar{\mu}t} \left(\frac{1}{x} + \lambda \int_0^t \left[1 + \frac{\sigma^2}{2\lambda\mu} + \left(\alpha_1 - \frac{\sigma^2}{2\lambda\mu} \right) e^{-\tau s} + \alpha_2 e^{-2\tau s} + \alpha_3 e^{-3\tau s} \right] e^{\lambda\bar{\mu}s} ds \right) \\
&= e^{-\lambda\bar{\mu}t} \left[\frac{1}{x} + \lambda \int_0^t \left(1 + \frac{\sigma^2}{2\lambda\mu} \right) e^{\lambda\bar{\mu}s} ds + \lambda \int_0^t \left(\alpha_1 - \frac{\sigma^2}{2\lambda\mu} \right) e^{\lambda\bar{\mu}s - \tau s} ds \right. \\
&\quad \left. + \lambda \int_0^t \alpha_2 e^{\lambda\bar{\mu}s - 2\tau s} ds + \lambda \int_0^t \alpha_3 e^{\lambda\bar{\mu}s - 3\tau s} ds \right] \\
&= e^{-\lambda\bar{\mu}t} \left[\frac{1}{x} + \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} e^{\lambda\bar{\mu}s} \Big|_0^t + \frac{2\alpha_1\lambda\mu - \sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} e^{\lambda\bar{\mu}s - \tau s} \Big|_0^t \right. \\
&\quad \left. + \frac{\alpha_2\lambda}{\lambda\bar{\mu} - 2\tau} e^{\lambda\bar{\mu}s - 2\tau s} \Big|_0^t + \frac{\alpha_3\lambda}{\lambda\bar{\mu} - 3\tau} e^{\lambda\bar{\mu}s - 3\tau s} \Big|_0^t \right] \\
&= e^{-\lambda\bar{\mu}t} \left[\frac{1}{x} + \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} \left(e^{\lambda\bar{\mu}t} - 1 \right) + \frac{2\alpha_1\lambda\mu - \sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} \left(e^{\lambda\bar{\mu}t - \tau t} - 1 \right) \right. \\
&\quad \left. + \frac{\alpha_2\lambda}{\lambda\bar{\mu} - 2\tau} \left(e^{\lambda\bar{\mu}t - 2\tau t} - 1 \right) + \frac{\alpha_3\lambda}{\lambda\bar{\mu} - 3\tau} \left(e^{\lambda\bar{\mu}t - 3\tau t} - 1 \right) \right] \tag{3.3} \\
&= \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} + \left(\frac{1}{x} - \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} - \frac{2\alpha_1\lambda\mu - \sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} - \frac{\alpha_2\lambda}{\lambda\bar{\mu} - 2\tau} - \frac{\alpha_3\lambda}{\lambda\bar{\mu} - 3\tau} \right) e^{-\lambda\bar{\mu}t} \\
&\quad + \frac{2\alpha_1\lambda\mu - \sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} e^{-\tau t} + \frac{\alpha_2\lambda}{\lambda\bar{\mu} - 2\tau} e^{-2\tau t} + \frac{\alpha_3\lambda}{\lambda\bar{\mu} - 3\tau} e^{-3\tau t}; \\
M_1(t) &\approx \left(\frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} + \left(\frac{1}{x} - \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} - \frac{2\alpha_1\lambda\mu - \sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} - \frac{\alpha_2\lambda}{\lambda\bar{\mu} - 2\tau} - \frac{\alpha_3\lambda}{\lambda\bar{\mu} - 3\tau} \right) e^{-\lambda\bar{\mu}t} \right. \\
&\quad \left. + \frac{2\alpha_1\lambda\mu - \sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} e^{-\tau t} + \frac{\alpha_2\lambda}{\lambda\bar{\mu} - 2\tau} e^{-2\tau t} + \frac{\alpha_3\lambda}{\lambda\bar{\mu} - 3\tau} e^{-3\tau t} \right)^{-1}.
\end{aligned}$$

Iš (3.3) lygties matome, kad pirmas momentas neapibrėžtas, kai $\tau = \lambda\bar{\mu}$, $2\tau = \lambda\bar{\mu}$ arba $3\tau = \lambda\bar{\mu}$. Toliau išvesime pirmojo momento išraiškas šiais išimtiniais atvejais.

- $\tau = \lambda\bar{\mu}$:

$$\begin{aligned}
M_1^{-1}(t) &\approx e^{-\lambda\bar{\mu}t} \left(\frac{1}{x} + \lambda \int_0^t \left[1 + \frac{\sigma^2}{2\lambda\mu} + \left(\alpha_1 - \frac{\sigma^2}{2\lambda\mu} \right) e^{-\lambda\bar{\mu}s} + \alpha_2 e^{-2\tau s} + \alpha_3 e^{-3\tau s} \right] e^{\lambda\bar{\mu}s} ds \right) \\
&= e^{-\lambda\bar{\mu}t} \left[\frac{1}{x} + \lambda \int_0^t \left(1 + \frac{\sigma^2}{2\lambda\mu} \right) e^{\lambda\bar{\mu}s} ds + \lambda \int_0^t \left(\alpha_1 - \frac{\sigma^2}{2\lambda\mu} \right) ds \right. \\
&\quad \left. + \lambda \int_0^t \alpha_2 e^{\lambda\bar{\mu}s - 2\tau s} ds + \lambda \int_0^t \alpha_3 e^{\lambda\bar{\mu}s - 3\tau s} ds \right] \\
&= e^{-\lambda\bar{\mu}t} \left[\frac{1}{x} + \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} e^{\lambda\bar{\mu}s} \Big|_0^t + \frac{2\alpha_1\lambda\mu - \sigma^2}{2\mu} s \Big|_0^t \right. \\
&\quad \left. + \frac{\alpha_2\lambda}{\lambda\bar{\mu} - 2\tau} e^{\lambda\bar{\mu}s - 2\tau s} \Big|_0^t + \frac{\alpha_3\lambda}{\lambda\bar{\mu} - 3\tau} e^{\lambda\bar{\mu}s - 3\tau s} \Big|_0^t \right] \\
&= e^{-\lambda\bar{\mu}t} \left[\frac{1}{x} + \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} \left(e^{\lambda\bar{\mu}t} - 1 \right) + \frac{2\alpha_1\lambda\mu - \sigma^2}{2\mu} t \right. \\
&\quad \left. + \frac{\alpha_2\lambda}{\lambda\bar{\mu} - 2\tau} \left(e^{\lambda\bar{\mu}t - 2\tau t} - 1 \right) + \frac{\alpha_3\lambda}{\lambda\bar{\mu} - 3\tau} \left(e^{\lambda\bar{\mu}t - 3\tau t} - 1 \right) \right] \\
&= \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} + \left(\frac{1}{x} - \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} + \frac{2\alpha_1\lambda\mu - \sigma^2}{2\mu} t - \frac{\alpha_2\lambda}{\lambda\bar{\mu} - 2\tau} - \frac{\alpha_3\lambda}{\lambda\bar{\mu} - 3\tau} \right) e^{-\lambda\bar{\mu}t} \\
&\quad + \frac{\alpha_2\lambda}{\lambda\bar{\mu} - 2\tau} e^{-2\tau t} + \frac{\alpha_3\lambda}{\lambda\bar{\mu} - 3\tau} e^{-3\tau t}; \\
M_1(t) &\approx \left(\frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} + \left(\frac{1}{x} - \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} + \frac{2\alpha_1\lambda\mu - \sigma^2}{2\mu} t - \frac{\alpha_2\lambda}{\lambda\bar{\mu} - 2\tau} - \frac{\alpha_3\lambda}{\lambda\bar{\mu} - 3\tau} \right) e^{-\lambda\bar{\mu}t} \right. \\
&\quad \left. + \frac{\alpha_2\lambda}{\lambda\bar{\mu} - 2\tau} e^{-2\tau t} + \frac{\alpha_3\lambda}{\lambda\bar{\mu} - 3\tau} e^{-3\tau t} \right)^{-1};
\end{aligned}$$

- $2\tau = \lambda\bar{\mu}$:

$$\begin{aligned}
M_1(t) &\approx \left(\frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} + \left(\frac{1}{x} - \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} - \frac{2\alpha_1\lambda\mu - \sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} + \alpha_2\lambda t - \frac{\alpha_3\lambda}{\lambda\bar{\mu} - 3\tau} \right) e^{-\lambda\bar{\mu}t} \right. \\
&\quad \left. + \frac{2\alpha_1\lambda\mu - \sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} e^{-\tau t} + \frac{\alpha_3\lambda}{\lambda\bar{\mu} - 3\tau} e^{-3\tau t} \right)^{-1};
\end{aligned}$$

- $3\tau = \lambda\bar{\mu}$:

$$\begin{aligned}
M_1(t) &\approx \left(\frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} + \left(\frac{1}{x} - \frac{2\lambda\mu + \sigma^2}{2\lambda\mu\bar{\mu}} - \frac{2\alpha_1\lambda\mu - \sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} - \frac{\alpha_2\lambda}{\lambda\bar{\mu} - 2\tau} + \alpha_3\lambda t \right) e^{-\lambda\bar{\mu}t} \right. \\
&\quad \left. + \frac{2\alpha_1\lambda\mu - \sigma^2}{2\mu(\lambda\bar{\mu} - \tau)} e^{-\tau t} + \frac{\alpha_2\lambda}{\lambda\bar{\mu} - 2\tau} e^{-2\tau t} \right)^{-1}.
\end{aligned}$$

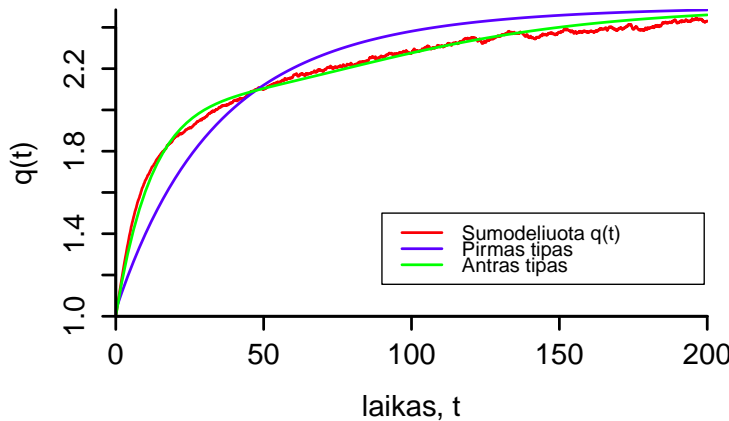
4 Rezultatai

Šiame skyriuje patikrinsime Fourier eilutės dalinių sumų metodais gautų aproksimacijų tikslumą. Aproksimacijas lyginsime su antros eilės *split-step* skaitiniu metodu Verhulsto lygčiai (žr.[5]) gautomis reikšmėmis. Bandymų skaičius N , naudotas *split-step* aproksimacijoje, lygus 100000, o žingsnio dydis $h = 0.1$. Nagrinėsime tris parametrų rinkinius $(\lambda, \mu, \sigma, x)$, po vieną kiekvienam stacionaraus tankio tipui (toliau trumpumo dėlei vadinsime tiesiog tankio tipais). Norėdami, kad pirmo ir antro momentų grafikai prasidėtų tame pačiame taške, vietoj antrojo momento grafikuose vaizduosime $\tilde{M}_2(t) = \sqrt{M_2(t)}$ reikšmes. Toliau $\tilde{M}_2(t)$ grafikus trumpumo dėlei vadinsime antro momento grafikais. Modeliavimai atlikti naudojantis programa R, o programos kodai pateikti priede.

4.1 Fourier dalinių sumų metodas I

Pradėsime nuo pirmojo Fourier eilutės dalinių sumų metodo. Šiuo atveju, pirmojo ir antrojo tipo aproksimacijas lyginsime su skaitiniais metodais gautomis reikšmėmis. Kiekvienam tankio tipui vaizduosime funkcijų $q(t)$, $\epsilon(\tau)$, $M_1(t)$ ir $\sqrt{M_2(t)}$ reikšmes.

4.1.1 Pirmas tankio tipas

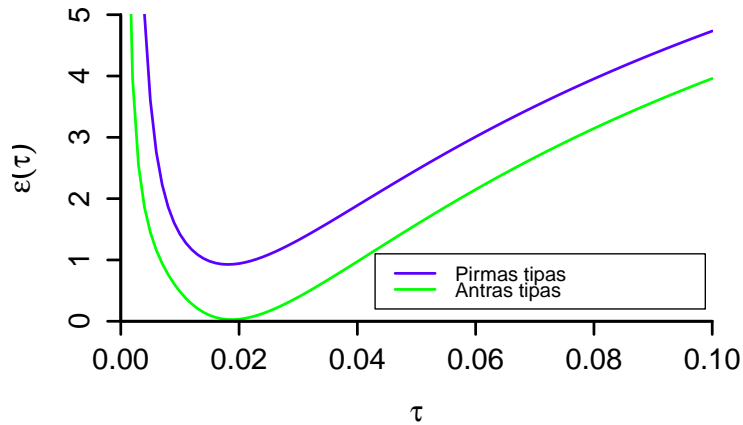


2 pav.: $x_0 = 0.03, \lambda = 1.2, \sigma = 0.3, \mu = 0.025$

2 paveiksle matome funkcijos $q(t)$ pirmo ir antro tipo aproksimacijas, kurios modeliuotos su parametrais $x_0 = 0.03, \lambda = 1.2, \sigma = 0.3, \mu = 0.025$. Kaip matome iš grafiko, pirmo tipo aproksimacija iki tam tikro laiko momento ne visai tiksliai aproksimuoja funkciją $q(t)$. Iki laiko momento $T = 50$ pirmo tipo kreivė auga lėčiau, tačiau nuo laiko momento $T = 50$ auga greičiau nei teorinė funkcijos $q(t)$ kreivė. Tuo tarpu antro tipo aproksimacija beveik idealiai sutampa su modeliuojama trajektorija. Modeliavimui pasirinktas ilgesnis laiko intervalas $T = 200$ tam, kad įsitikintume, jog galiausiai visos kreivės susilieja į vieną pluoštą. Nežymūs skirtumai nuo sumodeliuotos kreivės gali būti stochastinės prigimties ir modeliuojant kitą kartą skirtumai gali atsirasti kitais laiko momentais.

Vienas pagrindinių darbo tikslų buvo optimizuoti Fourier eilučių dalinių sumų metode naudojamą ir bandymo keliu parenkamą parametą τ . Tam ieškojome tokio parametro τ , su kuriuo paklaida $\epsilon(\tau)$ būtų mažiausia. 3 paveiksle matome funkcijų $\epsilon(\tau)$ grafikus, gautus modeliuojant pirmo ir antro tipo aproksimacijas su parametrų rinkiniu $x_0 = 0.03, \lambda = 1.2, \sigma = 0.3, \mu = 0.025$. Šiuo atveju pirmo tipo aproksimacijos optimalus parametras $\tau = 0.0191$, o antro aproksimacijos


tipo $\tau = 0.0197$. Taip pat galime pastebėti, kad pirmo ir antro tipo aproksimacijų paklaidos optimaliame taške gerokai skiriasi. Pirmo tipo aproksimacijos paklaida, esant optimaliam τ , siekia 0.92, o antro tipo atveju nežymiai viršija nulį ir yra lygi 0.026. Tai iš dalies paaškina gautus skirtumus tarp pirmo ir antro tipo aproksimacijų.




3 pav.: $x_0 = 0.03, \lambda = 1.2, \sigma = 0.3, \mu = 0.025$

4 paveiksle pavaizduoti pirmo aproksimacijos tipo momentai. Šiuo atveju tiek pirmas, tiek antras momentai įgyja lokalius maksimumus. Tačiau, kaip ir buvo galima tikėtis iš stebėtų $q(t)$ reikšmių, būtent šiuos maksimumus pirmo tipo aproksimacija aproksimuoja gana netiksliai. 5 paveiksle pavaizduoti antro tipo aproksimacijos momentai nuo pat pradžių daug tiksliau aproksimuoja ieškomas trajektorijas. Stebimi nedideli skirtumai gali būti tik stochastinės prigimties.

Pirmo tipo momentai



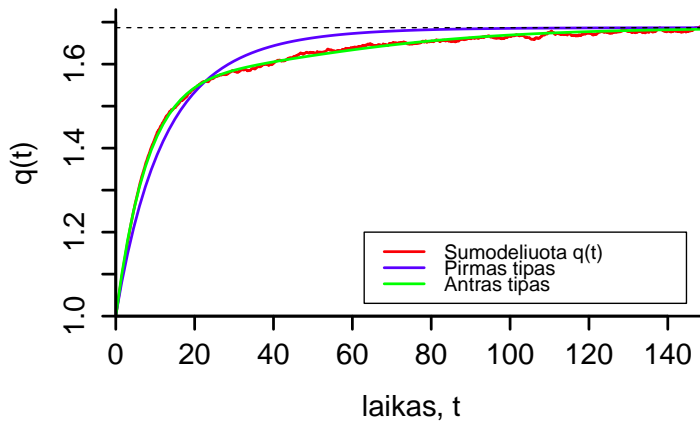
4 pav.: $x_0 = 0.03, \lambda = 1.2, \sigma = 0.3, \mu = 0.025$



5 pav.: $x_0 = 0.03, \lambda = 1.2, \sigma = 0.3, \mu = 0.025$


4.1.2 Antras tankio tipas

Šiame skyrelyje pateiksime grafikus, modeliuotus su antrą stacionaraus tankio tipą atitinkančiais pradiniais parametrais $x_0 = 0.03, \lambda = 1.3, \sigma = 0.25, \mu = 0.035$. Iš 6 paveiksle pavaizduoto grafiko matome, kad abi funkcijos q aproksimacijos elgiasi panašiai kaip 2 paveiksle. Pirmojo tipo aproksimacija iki laiko momento $T = 20$ auga šiek tiek lėčiau, o nuo $T = 20$ šiek tiek greičiau nei sumodeliuota kreivė. Nepaisant to, kreivė ilginiui išilieja į bendrą aproksimacijų pluoštą. Antro tipo aproksimacija elgiasi taip pat gerai, kaip ir pirmo tankio tipo atveju.



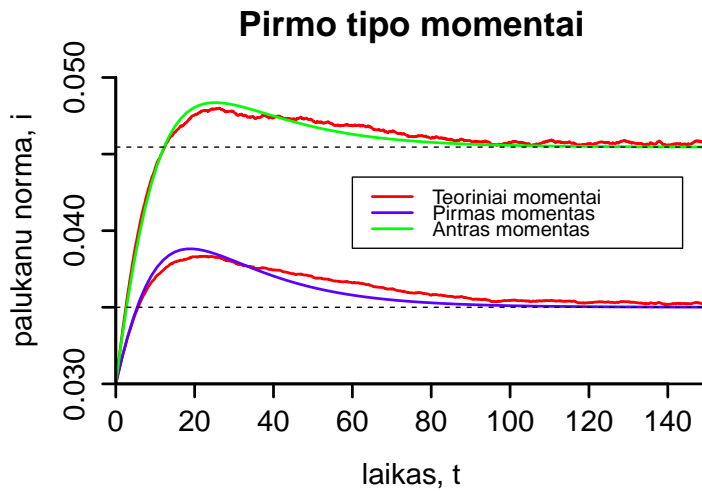
6 pav.: $x_0 = 0.03, \lambda = 1.3, \sigma = 0.25, \mu = 0.035$

7 paveiksle pavaizduoti minimizuojamos paklaidos $\epsilon(\tau)$ grafikai pirmo ir antro tipo aproksimacijoms. Šiuo atveju, pirmo tipo aproksimacijos optimalus parametras τ lygus 0.0515, su kuriuo $\epsilon(\tau) = 0.1811$. Tuo tarpu antrojo tipo aproksimacijos atveju gautas optimalus τ lygus 0.0331, su kuriuo paklaida yra labai artima nuliui ir siekia vos 0.0024.




7 pav.: $x_0 = 0.03, \lambda = 1.3, \sigma = 0.25, \mu = 0.035$

Toliau pateikiami abiejų aproksimacijų tipų pirmo ir antro momentų grafikai. Kaip matėme iš 6 grafiko, pirmo tipo aproksimacija ne taip tiksliai aproksimuoja skaitiniais metodais gautas funkcijos q reikšmes. Šie netikslumai taip pat atsispindi ir momentų grafike (žr. 8 pav.). Tuo tarpu antro tipo aproksimacija (žr. 9 pav.) ir šiuo atveju momentus aproksimuoja gana tiksliai.



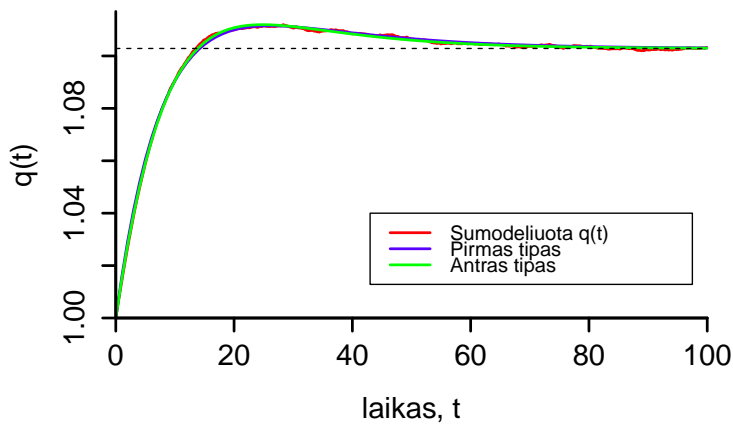
8 pav.: $x_0 = 0.03, \lambda = 1.3, \sigma = 0.25, \mu = 0.035$



9 pav.: $x_0 = 0.03, \lambda = 1.3, \sigma = 0.25, \mu = 0.035$


4.1.3 Trečias tankio tipas

Galiausiai pavaizduosime trečio tankio tipo grafikus modeliuotus su parametrais $x_0 = 0.03, \lambda = 1.4, \sigma = 0.12, \mu = 0.05$, kurie atitinka trečią tankio tipą. Iš 10 grafiko matome, kad abiejų tipų funkcijos q aproksimacijų reikšmės beveik sutampa su skaitiniais metodais gautomis reikšmėmis.



10 pav.: $x_0 = 0.03, \lambda = 1.4, \sigma = 0.12, \mu = 0.05$

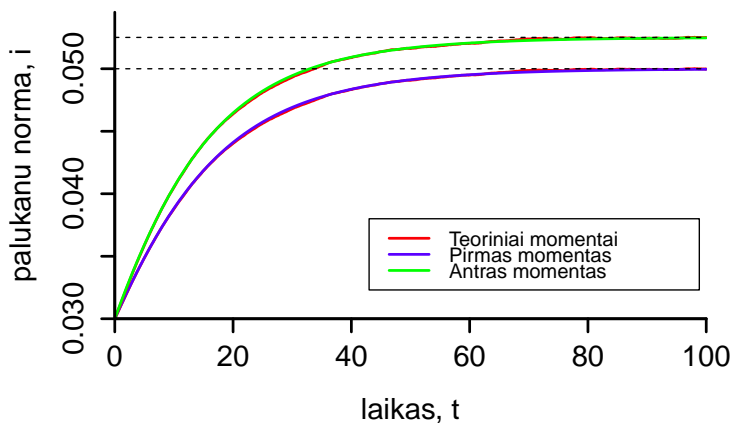
Šiuo atveju pirmo tipo aproksimacijos optimalus parametras τ lygus 0.058, o antro – 0.066. Paklaidos, esant optimalioms τ reikšmėms, abiem atvejais yra labai mažos ir vos siekia 0.0005 (žr. 11 pav.).



11 pav.: $x_0 = 0.03, \lambda = 1.4, \sigma = 0.12, \mu = 0.05$


Toliau 12 ir 13 paveiksluose pateikiami pirmo ir antro momentų grafikai. Šiuo atveju abiejų tipų aproksimacijos labai artimos teorinėms reikšmėms.

Pirmo tipo momentai



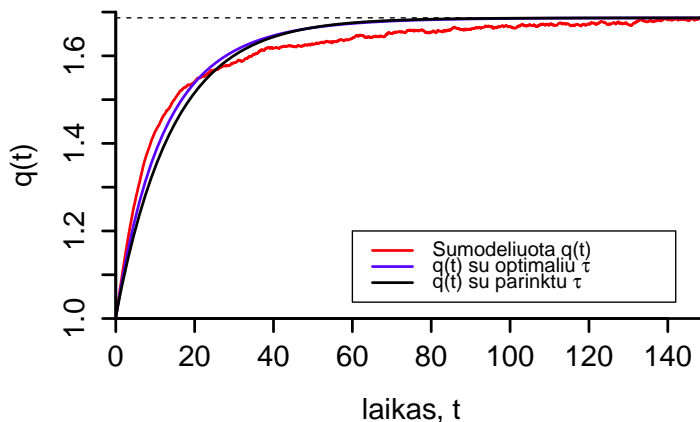
12 pav.: $x_0 = 0.03, \lambda = 1.4, \sigma = 0.12, \mu = 0.05$

Antro tipo momentai



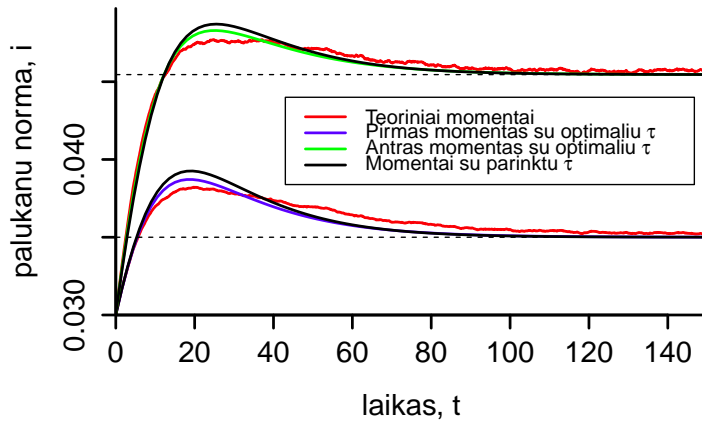
13 pav.: $x_0 = 0.03, \lambda = 1.4, \sigma = 0.12, \mu = 0.05$

Pabaigoje norime atkreipti dėmesį į skirtumą tarp rezultatų gautų šiame ir Baravyko darbe. Priminsime, kad Baravykas savo darbe parametą τ kiekvienam tankio tipui parinko bandymų keliu. Mes savo darbe optimizuodami parametą τ , ne tik atsikratėme rankinio parametro parinkimo, bet ir pagerinome aproksimacijos tikslumą. Pavyzdžiui, palyginkime rezultatus gautus su antro tankio tipo atveji atitinkančiais parametrais $x_0 = 0.03, \lambda = 1.3, \sigma = 0.25, \mu = 0.035$. Esant šiai situacijai, Baravyko darbe pasirinktas $\tau = \lambda\mu/1.3 = 0.035$. Toks pat τ naudojamas tiek pirmo, tiek antro tipo aproksimacijoms. Šiame darbe, optimizavus parametą τ radimą, gavome, kad pirmo aproksimacijos tipo atveju optimalus $\tau = 0.0515$, o antro tipo atveju $\tau = 0.0331$. Jau pastebėjome, kad antro tipo aproksimacija visais atvejais gana gerai aproksimuoja norimas funkcijas, todėl nagrinėsime tik pirmo tipo aproksimacijų skirtumus. 14 paveiksle pavaizduotos funkcijos $q(t)$ pirmo tipo aproksimacijos gautos su optimaliu ir analogiškai kaip Baravyko darbe parinktu parametru τ . Kaip matome, mūsų gauta aproksimacija, nors ir nedaug, bet yra arčiau prie skaitiniais metodais gautos funkcijos. Taip pat 15 paveiksle pavaizduoti momentų grafikai dar kartą patvirtina, kad šiame darbe gauta aproksimacija yra tikslesnė.



14 pav.: $x_0 = 0.03, \lambda = 1.3, \sigma = 0.25, \mu = 0.035$. Juoda spalva – q su Baravyko [1] parinktu $\tau = 0.035$, mėlyna spalva – su optimaliu $\tau = 0.0515$.

Pirmo tipo momentai




15 pav.: $x_0 = 0.03, \lambda = 1.3, \sigma = 0.25, \mu = 0.035$

4.2 Fourier dalinių sumų metodas II

Šioje dalyje apžvelgsime rezultatus, gautus naudojant Fourier dalinių sumų metodą II (plačiau 3 skyrius). Gautą trečio tipo aproksimaciją lyginsime su antros eilės *split-step* skaitiniu metodu Verhulsto lygčiai gautomis reikšmėmis. Analogiškai nagrinėsime tris parametrų rinkinius $(\lambda, \mu, \sigma, x)$, po vieną kiekvienam stacionaraus tankio tipui. Kiekvienam tankio tipui vaizduosime funkcijų $q(t)$, $\epsilon(\tau)$, $M_1(t)$ ir $\sqrt{M_2(t)}$ reikšmes.


4.2.1 Pirmas tankio tipas

16 paveiksle pavaizduota funkcijos $q(t)$ trečio tipo aproksimacija, modeliuota su parametrais $x_0 = 0.03$, $\lambda = 1.2$, $\sigma = 0.3$, $\mu = 0.025$. Iš grafiko matyti, kad didelių skirtumų tarp aproksimacijos ir skaitiniais metodais gautų reikšmių nėra. Stebimi nežymūs nukrypimai gali būti tik stochastinės prigimties.




16 pav.: $x_0 = 0.03, \lambda = 1.2, \sigma = 0.3, \mu = 0.025$

Konstruodami trečio tipo $q(t)$ aproksimaciją, taip pat ieškojome optimalaus laisvojo parametro τ . Iš 16 grafiko matyti, kad $\epsilon(\tau)$ įgyja minimumą ir yra minimali, kai $\tau = 0.01924$. Gauta paklaida optimaliaime taške yra labai maža ir lygi 0.142.



17 pav.: $x_0 = 0.03, \lambda = 1.2, \sigma = 0.3, \mu = 0.025$


18 grafike pavaizduoti pirmo bei antro momentų grafikai. Matome, kad gautos momentų išraiškos yra gana tikslios ir didelių nukrypimų nuo skaitiniais metodais gautų reikšmių nėra.



18 pav.: $x_0 = 0.03, \lambda = 1.2, \sigma = 0.3, \mu = 0.025$


4.2.2 Antras tankio tipas

Šiame skyrelyje pavaizduoti rezultatai, gauti su antrą tankio tipo atitinkančiu parametru rinkiniu $x_0 = 0.03$, $\lambda = 1.3$, $\sigma = 0.25$, $\mu = 0.035$. Iš 18 grafiko matome, kad šiuo atveju trečio tipo funkcijos q aproksimacija yra dar tikslesnė. Nėra didelių skirtumų tarp aproksimacijos ir skaitiniais metodais gautų reikšmių.



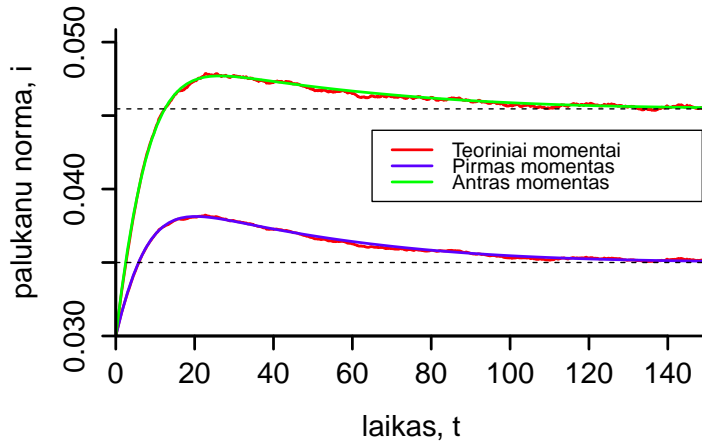
19 pav.: $x_0 = 0.03, \lambda = 1.3, \sigma = 0.25, \mu = 0.035$

20 grafike pavaizduotas paklaidos $\epsilon(\tau)$ kitimas. Šiuo atveju optimalus parametras $\tau = 0.0352$, o su juo gauta paklaida dar mažesnė nei anksčiau ir siekia 0.0025.



20 pav.: $x_0 = 0.03, \lambda = 1.3, \sigma = 0.25, \mu = 0.035$


21 grafike pavaizduoti pirmo ir antro momentų grafikai. Kaip ir buvo galima tikėtis iš gautų $q(t)$ reikšmių, momentai abiem atvejais aproksimuojami gana tiksliai.



21 pav.: $x_0 = 0.03, \lambda = 1.3, \sigma = 0.25, \mu = 0.035$


4.2.3 Trečias tankio tipas

Šioje dalyje apžvelgsime rezultatus gautus su parametrais $x_0 = 0.03, \lambda = 1.4, \sigma = 0.12, \mu = 0.05$. 22 paveiksle pavaizduoti funkcijų $q(t)$ grafikai. Kaip matome, šiuo atveju trečio tipo aproksimacija yra labai tiksli ir praktiškai sutampa su skaitiniais metodais gautomis reikšmėmis.



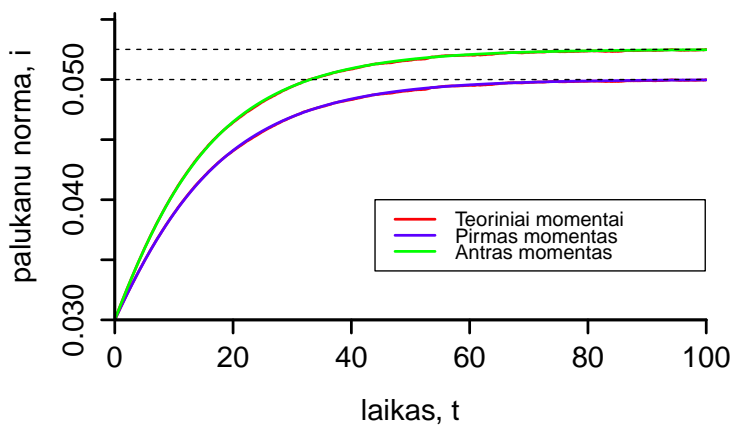
22 pav.: $x_0 = 0.03, \lambda = 1.4, \sigma = 0.12, \mu = 0.05$

Šiuo atveju gavome, kad optimalus $\tau = 0.0698$. Kaip matome iš 23 grafiko, paklaida optimalia-
me taške yra labai arti nulio ir lygi 0.000014.



23 pav.: $x_0 = 0.03, \lambda = 1.4, \sigma = 0.12, \mu = 0.05$

Galiausiai, 24 paveiksle pavaizduotos gautos momentų reikšmės. Kaip matome, tiek pirmas,
tiek antras momentai labai tiksliai aproksimuojami sukonstruota trečio tipo aproksimacija.

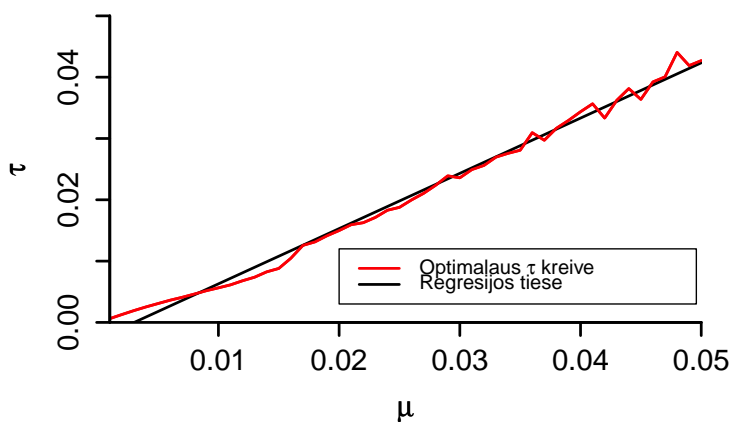


24 pav.: $x_0 = 0.03, \lambda = 1.4, \sigma = 0.12, \mu = 0.05$

4.3 Optimalaus τ priklausomybė nuo parametru

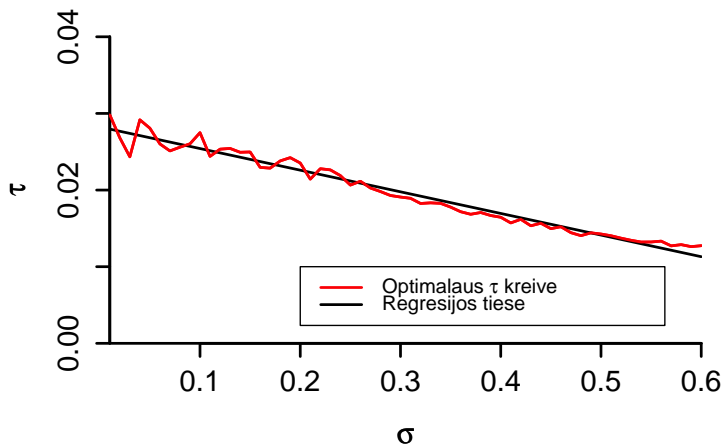
Vienas iš mūsų darbo tikslų buvo Fourier dalinių sumų metodui rasti optimalų parametru τ , su kuriuo sukonstruotos aproksimacijos būtų kuo tikslesnės. Toliau nagrinėsime, kaip optimalus τ priklauso nuo parametru x , λ , σ , μ . Naudosime trečio aproksimacijos tipo skaičiavimuose naudojamą optimalaus τ radimo algoritmu. Taip pat visur naudosime pirmo tankio tipo parametru rinkinį $x_0 = 0.03$, $\lambda = 1.2$, $\sigma = 0.3$, $\mu = 0.025$.

25 grafike pavaizduota optimalaus τ elgsena keičiant parametru μ . Matome, kad didėjant parametru μ , didėja ir optimalaus τ reikšmė. Papildomai išvedėme regresijos tiesę ir gavome, kad šiuo atveju regresijos koeficientas artimas 1 ir lygus 0.9923. Tai rodo, kad optimalaus τ priklausomybė nuo μ yra beveik tiesinė. Stebimi didesni τ svyravimai susiję su sumodeliuotos funkcijos q paklaidomis.




25 pav.: $x_0 = 0.03, \lambda = 1.2, \sigma = 0.3$

26 grafike matome, kaip optimalus τ priklauso nuo parametro σ . Čia situacija priešinga: didėjant parametro σ reikšmėms, optimalus τ mažėja. Tiesinė priklausomybė šiuo atveju ne tokia stipri, nes regresijos koeficientas mažesnis ir lygus 0.9667.



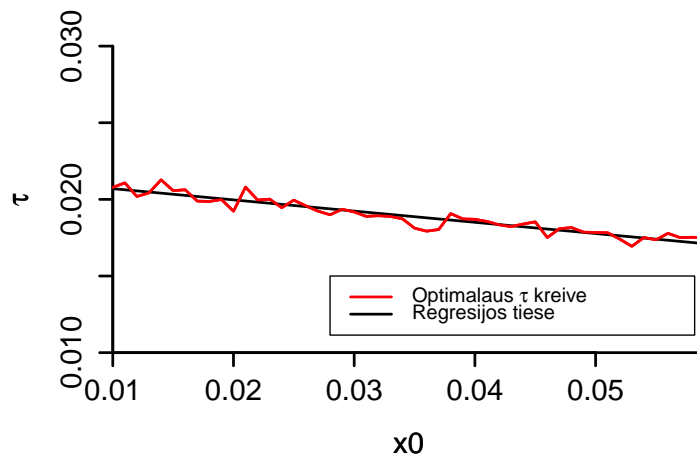
26 pav.: $x_0 = 0.03, \lambda = 1.2, \mu = 0.025$

27 grafike matome, kaip keičiantis λ reikšmėms, keičiasi optimalaus τ reikšmės. Galime pastebėti, kad nors optimalaus τ reikšmių kreivė svyruojanti, tačiau regresijos koeficientas išlieka gana aukštas ir siekia 0.9848.



27 pav.: $x_0 = 0.03, \sigma = 0.3, \mu = 0.025$

Galiausiai 28 paveiksle matome, kaip optimalaus τ reikšmės priklauso nuo pradinio taško x pasirinkimo. Čia taip pat galime išvengti tiesinę priklausomybę, tačiau ji ne tokia stipri, nes regresijos koeficientas mažiausias ir lygus 0.8965.



28 pav.: $\lambda = 1.2, \sigma = 0.3, \mu = 0.025$

Visais atvejais gauti pakankamai dideli regresijos koeficientai rodo, kad optimalaus τ kitimas nuo parametrų x , λ , σ , μ yra beveik tiesiškas. Gauti didesni τ svyravimai susiję su sumodeliuotos funkcijos q paklaidomis.

Išvados

Šiame darbe pateikėme Verhulsto lygties sprendinio momentų uždarumo funkcijos q trijų tipų aproksimacijas eksponentinių funkcijų sumomis. Norėdami gauti pirmąsias dvi aproksimacijas, turėjome optimizuoti laisvojo parametro τ radimą. Tam minimizavome paklaidą tarp sukonstruotos aproksimacijos ir skaitiniais metodais gautos funkcijos. Naudodami split-step skaitinį metodą, generavome Verhulsto SDL sprendinio momentų trajektorijas ir lyginome jas su gautos aproksimacijos reikšmėmis. Nustatėme, kad optimalaus parametro τ radimas pirmo ir antro tipų aproksimacijose ne tik duoda geresnius rezultatus, bet ir palengvina jų realizavimą. Nebereikia bandymų keliu kiekvienam parametru rinkiniui ieškoti geriausių rezultatus duodančio parametro τ . Tačiau aproksimuotos funkcijos q reikšmė pradiniam taške gavosi tik apytikriai lygi jos tikrajai reikšmei 1. Norėdami išspręsti šią problemą, naudodamiesi tomis pačiomis Fourier dalinių sumų savybėmis sukonstravome naują funkcijos q aproksimaciją. Minėto trūkumo pavyko išvengti funkciją q aproksimuojant specialiai parinkta eksponentinio tipo funkcijų šeima, tenkinančia pradinę sąlygą. Šią trečio tipo aproksimaciją laikome svarbiausiu darbo rezultatu, nes ji ne tik išsprendžia „pradinės reikšmės“ problemą, bet ir visais atvejais labai tiksliai aproksimuoja funkcijos q reikšmes. Be to, gautos aproksimacijos išraiškos yra žymiai paprastesnės ir lengviau realizuojamos.

Literatūra

- [1] A. Baravykas. Stochastinės Verhulsto lygties sprendinių momentų modeliavimas ir kalibravimas. Master's thesis, Vilniaus universitetas, 2013.
- [2] W. Horsthemke and R. Lefever. *Noise-Induced Transitions*. Springer, 2006.
- [3] V. Paulauskas ir A. Račkauskas. *Funkcinė analizė. I dalis*. TEV, 2007.
- [4] V. Mackevičius. *Stochastinė analizė*. Vilniaus universiteto leidykla, 2005.
- [5] V. Mackevičius. Verhulst versus CIR. *Lithuanian Mathematical Journal*, 55:119–133, 2014.
- [6] S. Matkėnaitė. Stochastinės Verhulsto lygties sprendinių momentų aproksimavimas. Master's thesis, Vilniaus universitetas, 2012.

Priedai

A Fourier dalinių sumų metodas I

```
1 # funkcija generuojanti q(t) reikšmes split-step metodu.
2 Moments <- function(h=H,Nm=NN,x1=X1,x2=X2,grsk=gr,la=lambda,mu=miu,si=sigma,T=TT){
3 Ef<-system2("verh_MIM2m4.exe",args=c(h,Nm,x1,x2,grsk,la,mu,si,T),stdout=TRUE)
4 N<-T/h
5 M1<-array(0,dim=c(grsk,N+1))
6 M2<-array(0,dim=c(grsk,N+1))
7 M1apr<-array(0,dim=c(grsk,N+1))
8 M1apr<-array(0,dim=c(grsk,N+1))
9 M2apr<-array(0,dim=c(grsk,N+1))
10 for(k in 1:grsk){
11 M1[k,]<-Ef[((4*k-4)*N+4*k-3):((4*k-3)*N+4*k-3)] #M1
12 M2[k,]<-Ef[((4*k-3)*N+4*k-2):((4*k-2)*N+4*k-2)] #sqrt(M2)
13 M1apr[k,]<-Ef[((4*k-2)*N+4*k-1):((4*k-1)*N+4*k-1)] #sqrt(M2)
14 M2apr[k,]<-Ef[((4*k-1)*N+4*k):((4*k)*N+4*k)]
15 }
16 M11<-as.numeric(M1[k,])
17 M22<-as.numeric(M2[k,])
18 q<-(M22^2)/(M11^2)
19 pirmas<-M11 #pirmas momentas
20 antras<-M22 #saknis is antro momento
21 return(cbind(q,pirmas,antras))
22 }
23 #f-ja generuojanti q(t) pirmo aproksimacijos tipo reikšmes. Is pradziu pasinaudojus
24 2.2 lygtimi gaunamos funkcijos f reikšmes. Toliau zinant q israiska, randamos
25 q reikšmes.
26 f2<-function(t){
27 A2<-1/(2*12)+c
28 A3<-1/(3*12)+c
29 A4<-1/(4*12)+c
30 a21<-(-A3)/A2
31 a22<-A2/(A4*A2-A3^2)
32 a11<-1/A2
33 b10<-(a11+a21*a22*(1+a21))*c
34 b11<-a11+a21*a21*a22
35 b12<-a21*a22
36 b20<-a22*(1+a21)*c
37 b21<-a22*a21
38 b22<-a22
39 x1<-seq(0,TT,H)
40 f0<-(-1) #nes q(0)=1
41 intgr1<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-l2*x1))
42 intgr2<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-2*12*x1))
43 ft<-(b10*(-1)+b11*intgr1+b12*intgr2)*exp(-l2*t)+
44 (b20*(-1)+b21*intgr1+b22*intgr2)*exp(-2*12*t)
45 qt<-(ft+1)*sigma^2/(2*lambda*miu)+1
46 }
47 return(qt)
48 }
49 #f-ja generuojanti q(t) antro aproksimacijos tipo reikšmes. Is pradziu pasinaudojus
50 2.8 lygtimi gaunamos funkcijos f reikšmes. Toliau zinant q israiska, randamos
51 q reikšmes.
52 f3<-function(t){
53 A2<-1/(2*13)+c
54 A3<-1/(3*13)+c
55 A4<-1/(4*13)+c
56 A5<-1/(5*13)+c
57 a21<-(-A3)/A2
58 a22<-A2/(A4*A2-A3^2)
59 a11<-1/A2
60 b10<-(a11+a21*a22*(1+a21))*c
61 b11<-a11+a21*a21*a22
```

```

59 b12<-a21*a22
60 b20<-a22*(1+a21)*c
61 b21<-a22*a21
62 b22<-a22
63 a31<-(-A4)/A2
64 a32<-(-a22)*(A5+a21*A4)
65 g3n<-c*(1+a32+a31+a32*a21)^2+1/(6*13)+(a32^2+2*a31+2*a32*a21)/(4*13)+(a31+a32*a21
)^(2/(2*13))+2*a32/(5*13)+2*a32*(a31+a32*a21)/(3*13)
66 a33<-1/g3n
67 bb10<-b10+c*a33*(a31+a32*a21)*(1+a32+a31+a32*a21)
68 bb11<-b11+a33*(a31+a32*a21)^2
69 bb12<-b12+a33*a32*(a31+a32*a21)
70 bb13<-a33*(a31+a32*a21)
71 bb20<-b20+c*a33*a32*(1+a32+a31+a32*a21)
72 bb21<-b21+a33*a32*(a31+a32*a21)
73 bb22<-b22+a33*a32*a32
74 bb23<-a33*a32
75 bb30<-c*a33*(1+a32+a31+a32*a21)
76 bb31<-a33*(a31+a32*a21)
77 bb32<-a33*a32
78 bb33<-a33
79 x1<-seq(0,TT,H)
80 f0<-(-1) #nes q(0)=1
81 intgr1<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-13*x1))
82 intgr2<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-2*13*x1))
83 intgr3<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-3*13*x1))
84 ft<-(bb10*(-1)+bb11*intgr1+bb12*intgr2+bb13*intgr3)*exp(-13*t)+
85 (bb20*(-1)+bb21*intgr1+bb22*intgr2+bb23*intgr3)*exp(-2*13*t)+
86 (bb30*(-1)+bb31*intgr1+bb32*intgr2+bb33*intgr3)*exp(-3*13*t)
87 qt<-(ft+1)*sigma^2/(2*lambda*miu)+1
88
89 return(qt)
90 }
91
92
93 #Darbe suskaiciuota paklaidos israiska sudaryta is dviejų narių (2.3 lygtis). Tik
antrasis (su minuso zenklu) priklauso nuo parametro tau. Todel vietoj visos
paklaidos minimizavimo, mes ieskome antro nario (be minuso) didziausios
reikšmes. Antro nario israiska:
94 tau2<-function(l){
95 A2<-1/(2*l)+c
96 A3<-1/(3*l)+c
97 A4<-1/(4*l)+c
98 a21<-(-A3)/A2
99 a22<-A2/(A4*A2-A3^2)
100 a11<-1/A2
101 x1<-seq(0,TT,H)
102 f0<-(-1) #nes q(0)=1
103 intgr1<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-1*x1))
104 intgr2<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-2*l*x1))
105
106 min<-(a11*(c*(-1)+intgr1)^2+a22*(c*(-1)*(1+a21)+a21*intgr1+intgr2)^2)
107 return(min)
108 }
109 #optimalaus tau radimui naudojama funkcija antro aproksimacijos tipo atveju.
Paklaidos antro nario israiska.
110 tau3<-function(l){
111 A2<-1/(2*l)+c
112 A3<-1/(3*l)+c
113 A4<-1/(4*l)+c
114 A5<-1/(5*l)+c
115 a21<-(-A3)/A2
116 a22<-A2/(A4*A2-A3^2)
117 a11<-1/A2
118 a31<-(-A4)/A2
119 a32<-(-a22)*(A5+a21*A4)

```

```

120 g3n<-c*(1+a32+a31+a32*a21)^2+1/(6*1)+(a32^2+2*a31+2*a32*a21)/(4*1)+(a31+a32*a21)
      ^2/(2*1)+2*a32/(5*1)+2*a32*(a31+a32*a21)/(3*1)
121 a33<-1/g3n
122
123 x1<-seq(0,TT,H)
124 f0<-(-1) #nes q(0)=1
125 intgr1<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-1*x1))
126 intgr2<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-2*1*x1))
127 intgr3<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-3*1*x1))
128
129 min<- (a11*(c*(-1)+intgr1)^2+a22*(c*(-1)*(1+a21)+a21*intgr1+intgr2)^2+a33*(c*(-1)*
      (1+a32+a31+a32*a21)+intgr3+a32*intgr2+(a31+a32*a21)*intgr1)^2 )
130 return(min)
131 }
132
133 #grafiku braizymo funkcija
134 grafikai<-function() {
135
136 #funkcijos q(t) grafiko braizymas.
137 rang<-c(min(y),max(y))
138 par(mfrow=c(1,1))
139 discr<-seq(time[1],time[2],H)
140 plot(cbind(discr,y),type="l",xlim=time,ylim=rang,xlab="laikas",t",ylab="q(t)",
141       xaxs="i",yaxs="i",col="red",axes=FALSE,lwd=2)
142 par(new=TRUE)
143 plot(f2,time[1],time[2],xlab="",ylab="",xlim=time,ylim=rang,
144       xaxs="i",yaxs="i",col="blue",axes=FALSE,lwd=2)
145 par(new=TRUE)
146 plot(f3,time[1],time[2],xlab="",ylab="",ylim=rang,
147       xaxs="i",yaxs="i",col="green",axes=FALSE,lwd=2)
148 aa<-(2*lambda*miu/(sigma*sigma))-1
149 d<-1+(sigma*sigma)/(2*lambda*miu)
150 lines(rbind(c(time[1],d),c(time[2],d)),lty=2)
151 axis(1,lwd=2)
152 axis(2,lwd=2)
153 box(bty="l",lwd=2)
154 legend(x=43,y=1.04,c("Sumodeliuota q(t)", "Pirmas tipas", "Antras tipas"),col=c("
      red", "blue", "green"),
155        cex=0.7, bty="o", bg="white", y.intersp=0.7, text.width=strwidth("Teoriniai
      momen"),
156        lwd=c(2,2,2), lty=c(1,1,1) )
157
158
159 #Paklaidu Epsilon grafikai pagal parametra tau
160 z2=array()
161 s<-0
162 zing<-0.001
163 for(i in c(1:101)){
164   s<-s+zing
165   z2[i]<-c+H*sum(((y-1)*2*lambda*miu/sigma^2-1)^2)-tau2(s)}
166
167 z3=array()
168 s<-0
169 zing<-0.001
170 for(i in c(1:101)){
171   s<-s+zing
172   z3[i]<-c+H*sum(((y-1)*2*lambda*miu/sigma^2-1)^2)-tau3(s)+0.045
173 }
174 rang1<-c(min(min(z2),min(z3))+20, max(max(z2),max(z3))+5)
175 x1<-seq(0,0.1,0.001)
176 par(mfrow=c(1,1))
177 plot(x1,z2,type="l",xlab=expression(tau),ylab=expression(epsilon(tau)),
178       xaxs="i",yaxs="i",col="blue",axes=FALSE,xlim=c(0,0.1),ylim=c(0,1),lwd=2)
179 par(new=TRUE)
180 plot(x1,z3,type="l",xlab="",ylab="",
181       xaxs="i",yaxs="i",col="green",axes=FALSE,ylim=c(0,1),lwd=2)
182 axis(1,lwd=2)

```

```

183 axis(2, lwd=2)
184 box(bty="l", lwd=2)
185 legend(x=0.043,y=2.5,c("Pirmas tipas", "Antras tipas"),col=c("blue", "green"),
186       cex=0.7, bty="o", bg="white", y.intersp=0.7, text.width=strwidth("Teoriniai
        moment"),
187       lwd=c(2,2), lty=c(1,1))
188
189 #Momentu grafikai
190 d1<-miu
191 d2<-sqrt(miu*mub)
192 rang2<-c(min(y2,y1),max(y2,y1,d1,d2))
193 par(mfrow=c(1,1))
194 discr<-seq(time[1],time[2],H)
195 plot(cbind(discr,y1),type="l",xlim=time, ylim=rang2,xlab="laikas",t",ylab="palukanu
        norma, i",
196       xaxs="i",yaxs="i",col="red", axes=FALSE, lwd=2)
197 par(new=TRUE)
198 plot(pirmas2,time[1],time[2],xlab="",ylab="",xlim=time, ylim=rang2,
199       xaxs="i",yaxs="i",col="blue",axes=FALSE, lwd=2)
200 par(new=TRUE)
201 plot(cbind(discr,y2),type="l",xlim=time, ylim=rang2,xlab="",ylab="",
202       xaxs="i",yaxs="i",col="red", axes=FALSE, lwd=2)
203 par(new=TRUE)
204 plot(antras2,time[1],time[2],xlab="",ylab="",xlim=time, ylim=rang2,
205       xaxs="i",yaxs="i",col="green",axes=FALSE, lwd=2)
206 lines(rbind(c(time[1],d1),c(time[2],d1)),lty=2)
207 lines(rbind(c(time[1],d2),c(time[2],d2)),lty=2)
208 axis(1,lwd=2)
209 axis(2, lwd=2)
210 box(bty="l", lwd=2)
211 legend(x=43, y=0.038 ,c("Teoriniai momentai", "Pirmas momentas", "Antras momentas")
        ,col=c("red", "blue", "green"),
212       cex=0.7, bty="o", bg="white", y.intersp=0.7, text.width=strwidth("Teoriniai
        moment"),
213       lwd=c(2,2,2), lty=c(1,1,1))
214 title("Pirmo tipo momentai")
215
216 d1<-miu
217 d2<-sqrt(miu*mub)
218 rang2<-c(min(y2,y1),max(y2,y1,d1,d2))
219 par(mfrow=c(1,1))
220 discr<-seq(time[1],time[2],H)
221 plot(cbind(discr,y1),type="l",xlim=time, ylim=rang2,xlab="laikas",t",ylab="palukanu
        norma, i",
222       xaxs="i",yaxs="i",col="red", axes=FALSE, lwd=2)
223 par(new=TRUE)
224 plot(pirmas3,time[1],time[2],xlab="",ylab="",xlim=time, ylim=rang2,
225       xaxs="i",yaxs="i",col="blue",axes=FALSE, lwd=2)
226 par(new=TRUE)
227 plot(cbind(discr,y2),type="l",xlim=time, ylim=rang2,xlab="",ylab="",
228       xaxs="i",yaxs="i",col="red", axes=FALSE, lwd=2)
229 par(new=TRUE)
230 plot(antras3,time[1],time[2],xlab="",ylab="",xlim=time, ylim=rang2,
231       xaxs="i",yaxs="i",col="green",axes=FALSE, lwd=2)
232
233 lines(rbind(c(time[1],d1),c(time[2],d1)),lty=2)
234 lines(rbind(c(time[1],d2),c(time[2],d2)),lty=2)
235 axis(1,lwd=2)
236 axis(2, lwd=2)
237 box(bty="l", lwd=2)
238 legend(x=43, y=0.038,c("Teoriniai momentai", "Pirmas momentas", "Antras momentas"),
        col=c("red", "blue", "green"),
239       cex=0.7, bty="o", bg="white", y.intersp=0.7, text.width=strwidth("Teoriniai
        moment"),
240       lwd=c(2,2,2), lty=c(1,1,1))
241 title("Antro tipo momentai")
242 }

```



```

243
244 #Pirmo aproksimacijos tipo momentu funkcijos (2.4 lygtis).
245 pirmas2<-function(x){
246   A2<-1/(2*12)+c
247   A3<-1/(3*12)+c
248   A4<-1/(4*12)+c
249   a21<-(-A3)/A2
250   a22<-A2/(A4*A2-A3^2)
251   a11<-1/A2
252   b10<-(a11+a21*a22*(1+a21))*c
253   b11<-a11+a21*a21*a22
254   b12<-a21*a22
255   b20<-a22*(1+a21)*c
256   b21<-a22*a21
257   b22<-a22
258   x1<-seq(0,TT,H)
259   f0<-(-1) #nes q(0)=1
260   intgr1<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-12*x1))
261   intgr2<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-2*12*x1))
262   alpha1<- (b10*(-1)+b11*intgr1+b12*intgr2)
263   alpha2<- (b20*(-1)+b21*intgr1+b22*intgr2)
264   if (12==lambda*mub) { 2*miu/((2*lambda*miu+sigma^2)/(lambda*mub)+(2*miu/x0-(2*miu
    *lambda+sigma^2)/(lambda*mub)+alpha1*sigma^2*x-alpha2*sigma^2/(lambda*mub-2*
    12))*exp(-1*lambda*mub*x)+ alpha2*sigma^2/(lambda*mub-2*12)*exp(-2*12*x))}
265   else if (2*12==lambda*mub){ 2*miu/((2*lambda*miu+sigma^2)/(lambda*mub)+(2*miu/x0
    -(2*miu*lambda+sigma^2)/(lambda*mub)-alpha1*sigma^2/(lambda*mub-12)+alpha2*
    sigma^2*x)*exp(-1*lambda*mub*x)+ alpha1*sigma^2/(lambda*mub-12)*exp(-1*12*x))
    }
266   else { 2*miu/((2*lambda*miu+sigma^2)/(lambda*mub)+(2*miu/x0-(2*miu*lambda+sigma
    ^2)/(lambda*mub)-alpha1*sigma^2/(lambda*mub-12)-alpha2*sigma^2/(lambda*mub-2*
    12))*exp(-1*lambda*mub*x)+ alpha1*sigma^2/(lambda*mub-12)*exp(-1*12*x)+alpha2
    *sigma^2/(lambda*mub-2*12)*exp(-2*12*x))}
267 }
268 antras2<-function(x){
269   sqrt(pirmas2(x)*pirmas2(x)*f2(x))
270 }
271
272 #Antro aproksimacijos tipo momentu funkcijos (2.10 lygtis)
273 pirmas3<-function(x){
274   A2<-1/(2*13)+c
275   A3<-1/(3*13)+c
276   A4<-1/(4*13)+c
277   A5<-1/(5*13)+c
278   a21<-(-A3)/A2
279   a22<-A2/(A4*A2-A3^2)
280   a11<-1/A2
281   b10<-(a11+a21*a22*(1+a21))*c
282   b11<-a11+a21*a21*a22
283   b12<-a21*a22
284   b20<-a22*(1+a21)*c
285   b21<-a22*a21
286   b22<-a22
287   a31<-(-A4)/A2
288   a32<-(-a22)*(A5+a21*A4)
289   g3n<-c*(1+a32+a31+a32*a21)^2+1/(6*13)+(a32^2+2*a31+2*a32*a21)/(4*13)+(a31+a32*a21
    )^2/(2*13)+2*a32/(5*13)+2*a32*(a31+a32*a21)/(3*13)
290   a33<-1/g3n
291   bb10<-b10+c*a33*(a31+a32*a21)*(1+a32+a31+a32*a21)
292   bb11<-b11+a33*(a31+a32*a21)^2
293   bb12<-b12+a33*a32*(a31+a32*a21)
294   bb13<-a33*(a31+a32*a21)
295   bb20<-b20+c*a33*a32*(1+a32+a31+a32*a21)
296   bb21<-b21+a33*a32*(a31+a32*a21)
297   bb22<-b22+a33*a32*a32
298   bb23<-a33*a32
299   bb30<-c*a33*(1+a32+a31+a32*a21)
300   bb31<-a33*(a31+a32*a21)

```

```

301 bb32<-a33*a32
302 bb33<-a33
303 x1<-seq(0,TT,H)
304 f0<-(-1) #nes q(0)=1
305 intgr1<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-13*x1))
306 intgr2<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-2*13*x1))
307 intgr3<-H*sum(((y-1)*2*lambda*miu/sigma^2-1)*exp(-3*13*x1))
308 alpha31<-(bb10*(-1)+bb11*intgr1+bb12*intgr2+bb13*intgr3)
309 alpha32<-(bb20*(-1)+bb21*intgr1+bb22*intgr2+bb23*intgr3)
310 alpha33<-(bb30*(-1)+bb31*intgr1+bb32*intgr2+bb33*intgr3)
311
312 if ((13!=lambda*mub)&(2*13!=lambda*mub)&(3*13==lambda*mub)) { 2*miu/((2*lambda*miu
+sigma^2)/(lambda*mub)+ (2*miu/x0-(2*miu*lambda+sigma^2)/(lambda*mub)+(alpha33
)*sigma^2*x-alpha31*sigma^2/(lambda*mub-13)-alpha32*sigma^2/(lambda*mub-2*13))
*exp(-1*lambda*mub*x)+ alpha31*sigma^2/(lambda*mub-13)*exp(-13*x)+alpha32*
sigma^2/(lambda*mub-2*13)*exp(-2*13*x))}
313 else if ((13!=lambda*mub)&(2*13==lambda*mub)&(3*13!=lambda*mub)) { 2*miu/((2*
lambda*miu+sigma^2)/(lambda*mub)+ (2*miu/x0-(2*miu*lambda+sigma^2)/(lambda*
mub)+(alpha32)*sigma^2*x-alpha31*sigma^2/(lambda*mub-13)-alpha33*sigma^2/(
lambda*mub-3*13))*exp(-1*lambda*mub*x)+ alpha31*sigma^2/(lambda*mub-13)*exp(-
13*x)+alpha33*sigma^2/(lambda*mub-3*13)*exp(-3*13*x))}
314 else if ((13==lambda*mub)&(2*13!=lambda*mub)&(3*13!=lambda*mub)) { 2*miu/((2*
lambda*miu+sigma^2)/(lambda*mub)+(2*miu/x0-(2*miu*lambda+sigma^2)/(lambda*mub
)+(alpha31)*sigma^2*x-alpha32*sigma^2/(lambda*mub-2*13)-alpha33*sigma^2/(
lambda*mub-3*13))*exp(-1*lambda*mub*x)+ alpha32*sigma^2/(lambda*mub-2*13)*exp
(-2*13*x)+alpha33*sigma^2/(lambda*mub-3*13)*exp(-3*13*x))}
315 else { 2*miu/((2*lambda*miu+sigma^2)/(lambda*mub)+ (2*miu/x0-(2*miu*lambda+sigma
^2)/(lambda*mub)-alpha31*sigma^2/(lambda*mub-13)-alpha32*sigma^2/(lambda*mub
-2*13)-alpha33*sigma^2/(lambda*mub-3*13))*exp(-1*lambda*mub*x)+ alpha31*sigma
^2/(lambda*mub-13)*exp(-1*13*x)+alpha32*sigma^2/(lambda*mub-2*13)*exp(-2*13*x
)+alpha33*sigma^2/(lambda*mub-3*13)*exp(-3*13*x))}
316 }
317 antras3<-function(x){
318 sqrt(pirmas3(x)*pirmas3(x)*f3(x))
319 }
320
321 #parametru ivedimas
322
323 H<-0.1
324 NN<-99999
325 X1<-0.03
326 X2<-0.03
327 x0<-0.03
328 gr<-1
329
330 lambda<-1.3
331 sigma<-0.25
332 miu<-0.035 #CIR lygties miu naudojama tiek akroksimacijose tiek split-step.
333 mub<-miu+sigma^2/(2*lambda) #Verhulsto lygties miu. Naudojama momentuose
334 TT<-150
335 time=c(0,TT)
336 c<-100
337 split<-Moments() #generuoja Split-Step q(t) funkcija, pirma momenta ir sqrt(antras_
momentas)
338 y<-split[,1]
339 y1<-split[,2]
340 y2<-split[,3]
341
342 #Darbe suskaiciuota paklaidos israiska sudaryta is dviejų nariu. Tik antrasis (su
minuso zenklu) priklauso nuo parametro tau. Todel vietoj visos paklaidos
minimizavimo, mes ieskome antro nario (be minuso) didziausios reikšmes.
343
344 L2<-print(optimize(tau2, interval=c(0, 0.2), maximum=TRUE)) #pirmo tipo
aproksimacijos optimalaus parametro tau radimas
345 l2<-as.numeric(L2[1])
346

```

```

347 L3<-print(optimize(tau3, interval=c(0, 0.2), maximum=TRUE)) #antro tipo
      aproksimacijos optimalaus parametro tau radimas
348 l3<-as.numeric(L3[1])
349
350
351 grafikai()

```

B Fourier dalinių sumų metodas II

```

1 #Funkcija generuojanti q(t) reikšmes split-step metodu.
2 Moments <- function(h=H,Nm=NN,x1=X1,x2=X2,grsk=gr,la=lambda,mu=miu,si=sigma,T=TT){
3 Ef<-system2("C:/Users/Monika/Dropbox/Monika 2015/Kodai/verh_M1M2m4.exe", args=c(h,
      Nm,x1,x2,grsk,la,mu,si,T), stdout=TRUE)
4 N<-T/h
5 M1<-array(0,dim=c(grsk,N+1))
6 M2<-array(0,dim=c(grsk,N+1))
7 M1apr<-array(0,dim=c(grsk,N+1))
8 M1apr<-array(0,dim=c(grsk,N+1))
9 M2apr<-array(0,dim=c(grsk,N+1))
10 for(k in 1:grsk){
11 M1[k,]<-Ef[((4*k-4)*N+4*k-3):((4*k-3)*N+4*k-3)] #M1
12 M2[k,]<-Ef[((4*k-3)*N+4*k-2):((4*k-2)*N+4*k-2)] #sqrt(M2)
13 M1apr[k,]<-Ef[((4*k-2)*N+4*k-1):((4*k-1)*N+4*k-1)] #sqrt(M2)
14 M2apr[k,]<-Ef[((4*k-1)*N+4*k):((4*k)*N+4*k)]
15 }
16 M11<-as.numeric(M1[k,])
17 M22<-as.numeric(M2[k,])
18 q<-(M22^2)/(M11^2)
19 pirmas<-M11 #pirmas momentas
20 antras<-M22 #saknis is antro momento
21 return(cbind(q,pirmas,antras))
22 }
23 #trecio tipo q(t) aproksimacijos reiksmiu gavimas. Pirmą suskaiciuojamos funkcijos
      h reikšmes (3.1 lygtis), toliau raunama funkcija q.
24 h<-function(t){
25 a<-sigma^2/(2*lambda*miu)
26 x1<-seq(0,TT,H)
27 intgr1<-H*sum((y-1-a+a*exp(-1*x1))*(exp(-1*x1)-exp(-2*1*x1)))
28 intgr2<-H*sum((y-1-a+a*exp(-1*x1))*(7/5*exp(-2*1*x1)-exp(-3*1*x1)-2/5*exp(-1*x1))
      )
29 ht<-12*1*intgr1*(exp(-1*t)-exp(-2*1*t))+
30 300*1*intgr2*(7/5*exp(-2*1*t)-exp(-3*1*t)-2/5*exp(-1*t))
31 qt<-ht+1+a-a*exp(-1*t)
32 return(qt)
33 }
34 #Pirmo momento israiska randama pasinaudojus 3.3 lygtimi
35 pirmas<-function(t){
36 a<-sigma^2/(2*lambda*miu)
37 x1<-seq(0,TT,H)
38 intgr1<-H*sum((y-1-a+a*exp(-1*x1))*(exp(-1*x1)-exp(-2*1*x1)))
39 intgr2<-H*sum((y-1-a+a*exp(-1*x1))*(7/5*exp(-2*1*x1)-exp(-3*1*x1)-2/5*exp(-1*x1))
      )
40 alpha1<-12*1*intgr1-120*1*intgr2
41 alpha2<-(-12)*1*intgr1+420*1*intgr2
42 alpha3<-(-300)*1*intgr2
43 if(l==lambda*mub){ 1/((2*lambda*miu+sigma^2)/(2*miu*lambda*mub)+
44 (1/x0-(2*miu*lambda+sigma^2)/(2*miu*lambda*mub)+(2*alpha1*lambda*miu-sigma^2)
      /(2*miu)*t-alpha2*lambda/(lambda*mub-2*1)-alpha3*lambda/(lambda*mub-3*1))
      *exp(-1*lambda*mub*t)+ alpha2*lambda/(lambda*mub-2*1)*exp(-2*1*t)+alpha3*
      lambda/(lambda*mub-3*1)*exp(-3*1*t))}
45 else if (2*l==lambda*mub) { 1/((2*lambda*miu+sigma^2)/(2*miu*lambda*mub)+ (1/x0
      -(2*miu*lambda+sigma^2)/(2*miu*lambda*mub)-(2*alpha1*lambda*miu-sigma^2)/(2*
      miu*(lambda*mub-1))+alpha2*lambda*t-alpha3*lambda/(lambda*mub-3*1))*exp(-1*
      lambda*mub*t)+ (2*alpha1*lambda*miu-sigma^2)/(2*miu*(lambda*mub-1))*exp(-1*1*
      t)+alpha3*lambda/(lambda*mub-3*1)*exp(-3*1*t))}

```

```

46   else if (3*l==lambda*mub) { 1/((2*lambda*miu+sigma^2)/(2*miu*lambda*mub)+ (1/x0
    -(2*miu*lambda+sigma^2)/(2*miu*lambda*mub)-(2*alpha1*lambda*miu-sigma^2)/(2*
    miu*(lambda*mub-1))-alpha2*lambda/(lambda*mub-2*1)+alpha3*lambda*t)*exp(-1*
    lambda*mub*t)+ (2*alpha1*lambda*miu-sigma^2)/(2*miu*(lambda*mub-1))*exp(-1*l*
    t)+alpha2*lambda/(lambda*mub-2*1)*exp(-2*l*t))}
47   else { 1/((2*lambda*miu+sigma^2)/(2*miu*lambda*mub)+ (1/x0-(2*miu*lambda+sigma^2)
    /(2*miu*lambda*mub)-(2*alpha1*lambda*miu-sigma^2)/(2*miu*(lambda*mub-1))-
    alpha2*lambda/(lambda*mub-2*1)-alpha3*lambda/(lambda*mub-3*1))*exp(-1*lambda*
    mub*t)+ (2*alpha1*lambda*miu-sigma^2)/(2*miu*(lambda*mub-1))*exp(-1*l*t)+
    alpha2*lambda/(lambda*mub-2*1)*exp(-2*l*t)+alpha3*lambda/(lambda*mub-3*1)*exp
    (-3*l*t))}
48 }
49 #antro momento israiska
50 antras<-function(x){
51   sqrt(pirmas(x)*pirmas(x)*h(x))
52 }
53 #Siuo atveju abu paklaidos nariai priklauso nuo parametro tau, todel minimizuosime
    visa funkcija, uzrasyta 3.2 lygtimi.
54 opt<-function(l){
55   a<-sigma^2/(2*lambda*miu)
56   x1<-seq(0,TT,H)
57   hn<-H*sum((y-1-a+a*exp(-l*x1))^2)
58   pirmas<-(H*sum((y-1-a+a*exp(-l*x1))*(exp(-l*x1)-exp(-2*l*x1))))^2
59   antras<-(H*sum((y-1-a+a*exp(-l*x1))*(7/5*exp(-2*l*x1)-exp(-3*l*x1)-2/5*exp(-l*x1)
    )))^2
60   min<-hn-12*l*pirmas-300*l*antras
61   return(min)
62 }
63
64 #F-ja braizanti grafikus
65 grafikai<-function(){
66   z3=array()
67   s<-0
68   zing<-0.005
69   for(i in c(1:101)){
70     s<-s+zing
71     z3[i]<-opt(s)
72   }
73
74   x1<-seq(0,0.5,0.005)
75   plot(x1,z3, type="l", xlab=expression(tau(t)),ylab=expression(delta(t)),
76     xaxs="i",yaxs="i",col="blue",lwd=2)
77
78   rang<-c(min(y),max(y)+0.03)
79   par(mfrow=c(1,1))
80   discr<-seq(time[1],time[2],H)
81   plot(cbind(discr,y),type="l",xlim=time,ylim=rang,xlab="laikas",t",ylab="q(t)",
82     xaxs="i",yaxs="i",col="red",axes=FALSE,lwd=2)
83   par(new=TRUE)
84   plot(h,time[1],time[2],xlab="",ylab="",xlim=time,ylim=rang,
85     xaxs="i",yaxs="i",col="blue",axes=FALSE,lwd=2)
86   aa<-(2*lambda*miu/(sigma*sigma))-1
87   d<-1+(sigma*sigma)/(2*lambda*miu)
88   lines(rbind(c(time[1],d),c(time[2],d)),lty=2)
89   axis(1,lwd=2)
90   axis(2,lwd=2)
91   box(bty="l",lwd=2)
92
93 #Momentu grafikai
94 d1<-miu
95 d2<-sqrt(miu*mub)
96 rang2<-c(min(y2,y1),max(y2,y1,d1,d2)+0.003)
97 par(mfrow=c(1,1))
98 discr<-seq(time[1],time[2],H)
99 plot(cbind(discr,y1),type="l",xlim=time,ylim=rang2,xlab="laikas",t",ylab="palukanu
    norma",i",
100   xaxs="i",yaxs="i",col="red",axes=FALSE,lwd=2)

```

```

101 par(new=TRUE)
102 plot(pirmas, time[1], time[2], xlab="", ylab="", xlim=time, ylim=rang2,
103      xaxs="i", yaxs="i", col="blue", axes=FALSE, lwd=2)
104 par(new=TRUE)
105 plot(cbind(discr, y2), type="l", xlim=time, ylim=rang2, xlab="", ylab="",
106      xaxs="i", yaxs="i", col="red", axes=FALSE, lwd=2)
107 par(new=TRUE)
108 plot(antras, time[1], time[2], xlab="", ylab="", xlim=time, ylim=rang2,
109      xaxs="i", yaxs="i", col="green", axes=FALSE, lwd=2)
110 lines(rbind(c(time[1], d1), c(time[2], d1)), lty=2)
111 lines(rbind(c(time[1], d2), c(time[2], d2)), lty=2)
112 axis(1, lwd=2)
113 axis(2, lwd=2)
114 box(bty="l", lwd=2)
115 legend(x=65, y=0.044, c("Teoriniai momentai", "Pirmas momentas", "Antras momentas")
116       , col=c("red", "blue", "green"),
117       cex=0.7, bty="o", bg="white", y.intersp=0.7, text.width=strwidth("Teoriniai
118       moment"),
119       lwd=c(2,2,2), lty=c(1,1,1))
120 title("Pirmos formos momentai")
121 }
122 #Parametru ivedimas
123 H<-0.1
124 NN<-99999
125 X1<-0.03
126 X2<-0.03
127 x0<-0.03
128 gr<-1
129 lambda<-1.4
130 sigma<-0.12
131 miu<-0.05 #CIR lygties miu naudojama tiek akroksimacijose tiek split-step.
132 mub<-miu+sigma^2/(2*lambda) #Verhulsto lygties miu. Naudojama momentuose
133 TT<-100
134 time=c(0, TT)
135 split<-Moments() #generuoja Split-Step q(t) funkcija, pirma monta ir sqrt(antras_
136 momentas)
137 y<-split[,1]
138 y1<-split[,2]
139 y2<-split[,3]
140 #paklaidos minimavimo funkcija
141 L2<-print(optimize(opt, interval=c(0, 0.2)))
142 l<-as.numeric(L2[1])
143 grafikai()

```