



**KAUNO TECHNOLOGIJOS UNIVERSITETAS**  
**FUNDAMENTALIŲJŲ MOKSLŲ FAKULTETAS**  
**MATEMATINĖS SISTEMOTYROS KATEDRA**

**Laima Rinkevičiūtė**

**NE GYVYBĖS DRAUDIMO ANALIZĖ**  
**LIETUVOJE**

Magistro darbas

**Vadovas**  
**doc. dr. V. Karpickaitė**

**KAUNAS, 2006**



**KAUNO TECHNOLOGIJOS UNIVERSITETAS**  
**FUNDAMENTALIŲJŲ MOKSLŲ FAKULTETAS**  
**MATEMATINĖS SISTEMOTYROS KATEDRA**

**TVIRTINU**  
**Katedros vedėjas**  
**prof. habil.dr. V.Pekarskas**  
**2006 06 06**

**NE GYVYBĖS DRAUDIMO ANALIZĖ**  
**LIETUVOJE**

Taikomosios matematikos magistro baigiamasis darbas

**Kalbos konsultantas**  
**dr. J. Džežulskienė**  
**2006 05 30**

**Vadovas**  
**doc. dr. V. Karpickaitė**  
**2006 06 03**

**Recenzentas**  
**doc. dr. J. Vencloviėnė**  
**2006 06 01**

**Atliko**  
**FMMM-4 gr. stud.**  
**L.Rinkevičiūtė**  
**2006 05 25**

**KAUNAS, 2006**

## KVALIFIKACINĖ KOMISIJA

**Pirmininkas:** Leonas Saulis, habil. dr. profesorius (VGTU)

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

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

Vytautas Janilionis, docentas (KTU)

Vidmantas Povilas Pekarskas, profesorius (KTU)

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

Zenonas Navickas, profesorius (KTU)

pavaduotojas Arūnas Barauskas, dr., UAB „Elsis“ generalinio direktoriaus

**Rinkeviciute L. Analysis of non life insurance in Lithuania: Master's work in applied mathematics / supervisor dr. Assoc. V. Karpickaite; Department of Mathematics Research In System, Faculty of Fundamental Sciences, Kaunas University of Technology. – Kaunas, 2006. – 86 p.**

## SUMMARY

Insurance market in Lithuania is evolving yet, but this process is quite rapid.

The destination of this work – analysis of non life insurance in Lithuania, which we will dispense, when we will interpret statistical information of insurance, also we will analyze paying capacity of non life insurance companies. Insurance companies calculate future's contribution using data of past period. It would be better to correct contribution according to predictive future's number of contracts and loss. So the number of contracts and loss, signed by Lithuanian insurance companies each quarter, are studied as time series. Several time series models were created for three principal kinds of insurance (Motor Third Party Liability Insurance, Land vehicles other than railway rolling stock Insurance, Property Insurance) and the one that meets the reality best was selected.

We will analyze variation of number of non life insurance companies, number of paid losses, number of signed contributions and number of contracts. After analyses of Insurance market's indicators, we get strong tendency that Insurance market becomes more stable.

After analysis of insurance companies' paying capacity we got, that two close private companies - "Baltic Polis" and "Industrijos garantas" – was closed to bankrupt in 2004 year.

After forecasting number of Motor Third Party Liability Insurance's and Land vehicles other than railway rolling stock Insurance's contracts we got that Autoregressive model is the best for them.

The best model for Property Insurance's contracts is Simple moving average method.

The best model for Property Insurance's and Motor Third Party Liability Insurance's losses is Autoregressive model.

Parabolic trend is the most infallible model for Land vehicles other than railway rolling stock Insurance's losses.

## TURINYS

|  |    |
|--|----|
| Įvadas.....  | 9  |
| 1. Teorinė dalis.....  | 11 |
| 1.1 Būtinieji mokumo atsarga ne gyvybės draudimo veiklai.....                                  | 11 |
| 1.2 Turimoji mokumo atsarga ne gyvybės draudimo veiklai.....                                   | 12 |
| 1.3 Laiko eilutės .....  | 13 |
| 1.3.1 Pagrindinės sąvokos .....  | 13 |
| 1.3.2 Bendra tiesinio prognozavimo teorija ir statistinių modelių panaudojimas prognozei... 14 | 14 |
| 1.3.3 Trendas .....  | 15 |
| 1.3.3.1 Determinacijos ir koreliacijos koeficientai .....                                      | 15 |
| 1.3.4 Sezoniniai svyravimai .....  | 16 |
| 1.4 Prognozavimo metodai. ....   | 17 |
| 1.4.1 Stacionarių sekų sąvokos.....  | 17 |
| 1.4.2 Stacionarūs tiesiniai modeliai .....   | 18 |
| 1.4.2.1 Autoregresijos ir slenkamųjų vidurkių modeliai.....                                    | 18 |
| 1.4.2.2 Paprastas ir svertinis slenkamųjų vidurkių metodai .....                               | 19 |
| 1.4.2.3 Paprastojo eksponentinio glodinimo metodas .....                                       | 20 |
| 1.4.2.4 Stacionarus tiesinis procesas.....   | 20 |
| 1.4.3 Nestacionarūs tiesiniai modeliai .....   | 20 |
| 1.4.3.1 Nestacionarus tiesinis procesas.....   | 21 |
| 1.4.4 Modelio eilės nustatymo būdai .....  | 22 |
| 1.4.4.1 Autokoreliacijos ir dalinės autokoreliacijos funkcijos.....                            | 22 |
| 1.5 Programinė įranga.....   | 22 |
| 2. Tiriamoji dalis ir rezultatai.....  | 24 |
| 2.1 Lietuvos ne gyvybės draudimo rinkos raida .....  | 24 |
| 2.2 Ne gyvybės draudimo kompanijų mokumas .....  | 26 |
| 2.3 Pagrindinių ne gyvybės draudimo rūšių sutarčių skaičiaus prognozavimas .....               | 28 |
| 2.3.1 TPCAD sutarčių prognozavimas .....   | 28 |
| 2.3.1.1 TPCAD sutarčių prognozavimas pagal 1998-2005 metų duomenis.....                        | 28 |
| 2.3.1.1.1 TPCAD sutarčių skaičiaus prognozavimas regresinių kreivių metodais....               | 28 |
| 2.3.1.1.2 TPCAD sutarčių skaičiaus prognozavimas paprastuoju ir svertiniu                      |    |
| slenkamųjų vidurkių metodais .....   | 29 |
| 2.3.1.1.3 TPCAD sutarčių skaičiaus prognozavimas paprastojo eksponentinio                      |    |
| glodinimo metodu .....   | 30 |
| 2.3.1.1.4 TPCAD sutarčių skaičiaus prognozavimas taikant autoregresinį modelį... 31            | 31 |

|  |    |
|--|----|
| 2.3.1.2 TPCAD sutarčių skaičiaus prognozavimas pagal 2002-2005 metų duomenis .....   | 33 |
| 2.3.1.3 TPCAD sutarčių skaičiaus prognozavimo rezultatai.....  | 34 |
| 2.3.3 Sausumos transporto priemonių, išskyrus geležinkelio transporto priemones, draudimo sutarčių skaičiaus prognozavimas ..... | 35 |
| 2.3.4 Turto draudimo sutarčių skaičiaus prognozavimas.....   | 37 |
| 2.4 Nuostolių sumos prognozavimas .....  | 39 |
| 3. Programinė realizacija ir instrukcija vartotojui.....   | 42 |
| 4. Diskusijos.....   | 45 |
| Išvados .....  | 47 |
| Rekomendacijos .....   | 48 |
| Literatūros sąrašas .....  | 49 |
| 1 priedas. Draudimo veikla užsiimančių kompanijų skaičiaus palyginimas .....   | 50 |
| 2 priedas. Duomenys BMA ir TMA skaičiuoti.....   | 52 |
| 3 priedas. TPCAD sutarčių skaičiaus prognozavimo modeliai .....  | 53 |
| 4 priedas. Sausumos TP, išskyrus geležinkelio TP, draudimo sutarčių skaičiaus prognozavimo modeliai .....                        | 56 |
| 5 priedas. Turto draudimo sutarčių skaičiaus prognozavimo modeliai .....   | 59 |
| 6 priedas. Sutarčių skaičiaus autokoreliacijos ir dalinės autokoreliacijos diagramos.....  | 62 |
| 7 priedas. Nuostolių autokoreliacijos ir dalinės autokoreliacijos diagramos.....   | 64 |
| 8 priedas. Baltojo triukšmo hipotezės tikrinimas sudarytų autoregresinių modelių liekanoms .....                                 | 67 |
| 9 priedas. TPCAD nuostolių sumos prognozavimo modeliai.....  | 74 |
| 10 priedas. Sausumos TP, išskyrus geležinkelio TP, draudimo nuostolių sumos prognozavimo modeliai .....                          | 77 |
| 11 priedas. Turto draudimo nuostolių sumos prognozavimo modeliai .....   | 80 |
| 12 priedas. Prognozavimo rezultatų lentelės .....  | 83 |

## LENTELIŲ SĄRAŠAS

|   |    |
|---|----|
| 2.2.1 lentelė. BMA skaičiavimo rezultatai .....   | 27 |
| 2.3.1.1.2.1 lentelė. Prognozavimas paprastuoju ir svertiniu slenkamųjų vidurkių metodu.....         | 30 |
| 2.3.1.3.1 lentelė. TPCAD sutarčių prognozavimo rezultatai .....                                     | 33 |
| 2.3.1.1.4.1 lentelė. Baltojo triukšmo hipotezės tikrinimas liekanoms.....                           | 33 |
| 2.3.3.1 lentelė. Sausumos TP, išskyrus geležinkelio TP, draudimo sutarčių prognozavimo rezultatai . | 36 |
| 2.3.4.1 lentelė. Turto draudimo sutarčių prognozavimo rezultatai .....                              | 38 |
| 2.4.1 lentelė. Skirtumų tarp turimų ir prognozuotų nuostolių lentelė .....                          | 39 |

## PAVEIKSLŲ SĄRAŠAS

|  |    |
|--|----|
| 2.1.1 pav. Ne gyvybės draudimo kompanijų skaičiaus kitimas.....  | 24 |
| 2.1.2 pav. Pasirašytų ne gyvybės draudimo įmokų kitimas.....   | 25 |
| 2.1.3 pav. Ne gyvybės draudimo užimama dalis draudimo rinkoje.....   | 25 |
| 2.1.4 pav. Apmokėtų ne gyvybės draudimo žalų kitimas.....  | 26 |
| 2.1.5 pav. Ne gyvybės draudimo įmokų struktūra 2005m.....  | 26 |
| 2.2.1 pav. TMA ir BMA palyginimas .....  | 27 |
| 2.3.1.1.1.1 pav. TPCAD sutarčių skaičiaus ir jo prognozių palyginimas.....   | 29 |
| 2.3.1.1.3.1 pav. TPCAD sutarčių skaičiaus prognozavimas paprastojo eksponentinio glodinimo metodu<br>.....                             | 31 |
| 2.3.1.1.4.1 pav. Autokoreliacijos funkcija.....  | 31 |
| 2.3.1.1.4.2 pav. TPCAD sutarčių skaičiaus prognozavimas taikant autoregresinį modelį.....  | 32 |
| 2.3.1.1.4.3 pav. Autoregresinio modelio liekanų autokoreliacijos funkcija .....  | 32 |
| 2.3.1.1.4.4 pav. Autoregresinio modelio liekanų dalinės autokoreliacijos funkcija .....  | 33 |
| 2.3.2.1 pav. TPCAD sutarčių skaičiaus prognozių palyginimas.....   | 34 |
| 2.3.3.1 pav. Prognozavimo rezultatų palyginimas, duomenų aproksimacijai naudojant, tiesinį,<br>eksponentinį ir logaritmą trendus ..... | 35 |
| 2.3.3.2 pav. Prognozavimo rezultatų palyginimas duomenų aproksimacijai .....   | 36 |
| 2.3.4.1 pav. Turto draudimo sutarčių prognozių palyginimas .....   | 37 |
| 2.4.1 pav. Nuostolių prognozių palyginimas .....   | 39 |
| 3.1 pav. Modulio Time Series Analysis langas.....  | 41 |
| 3.2 pav. Modulio Nonlinear Estimations duomenų langas.....   | 42 |
| 3.3 pav. Modulio <i>Nonlinear Estimations</i> regresinės lygties koeficientų radimo langas.....  | 42 |
| 3.4 pav. Modulio <i>2D Scatterplots</i> regresinės kreivei nustatyti parametru parinkimo langas.....                                   | 43 |



## IVADAS

1990-ųjų metų kovo 11-ąją Lietuva atkūrė nepriklausomybę. Nuo tada šalyje vykdoma liberali ekonominė politika. Nors palyginti jauna Lietuvos draudimo rinka dar tik vystosi, tačiau procesas yra labai spartus, palyginti su kitomis ekonomikos sritimis.

Pastaruoju metu labai aktualus ne gyvybės draudimo, ypač transporto privalomosios civilinės atsakomybės draudimo, įmokų klausimas. Verslo atstovus šokiruoja ne procentais, o kartais brangstančios draudimo įmokos. Draudimo bendrovės draudimo brangimą motyvuoja didėjančiomis žalų išmokomis, kadangi pernai buvo patirta 40 milijonų litų nuostolių, ir šis nuostolingumas vis didėja. Kad nustatyti, ar tikrai arba kiek daug reikia didinti įmokas, svarbu prognozuoti tuos dydžius, nuo kurių priklauso pati įmoka.

Šio darbo tyrimo tikslas – ne gyvybės draudimo rinkos raidos analizė, kurią atliksime interpretuodami ne gyvybės draudimo statistinius duomenis, tirdami kompanijų mokumą, ieškodami įmokų didumą lemiančių charakteristikų – sutarčių skaičiaus ir nuostolių patikimų prognozavimo modelių.

Pirmiausiai apžvelgsime Lietuvos ne gyvybės draudimo rinkos situaciją. Nagrinėsime ne gyvybės draudimo kompanijų, jų apmokėtų žalų, pasirašytų įmokų, sudarytų sutarčių skaičių kitimą. Taip pat analizuosime ne gyvybės draudimo įmokų ir išmokų struktūrą, t.y. išsiaiškinsime, kokioms ne gyvybės draudimo rūšims minėti rodikliai yra didžiausi.

Vienas iš darbo tikslų yra ir ne gyvybės draudimo kompanijų mokumo analizė, kadangi draudimo kompanijų finansinės padėties stabilumo klausimas yra aktualus ne tik draudimo įmonėms, bet ir pavieniams draudėjams. Lietuvos draudimo įmonių mokumas vertinamas taikant modelį, pagal kurį draudimo kompanijos finansinė padėtis laikoma stabilia, jei apskaičiuota turima mokumo atsarga yra didesnė už būtiną mokumo atsargą. Tokį mokumo atsargų palyginimą atliksime kelioms ne gyvybės draudimo kompanijoms.

Tačiau kyla abejonė, ar toks taikomas modelis yra pakankamai geras. Ar Lietuvoje draudimo kompanijų mokumas vertinamas teisingai suabejoti verčia ir draudimo kompanijos „Ingo Balt“ bankrotas. Todėl manome, kad taip pat reiktų atlikti ir tokių draudimo rodiklių kaip draudimo sutarčių skaičiaus ir ypač apmokėtų žalų prognozavimą.

Pasinaudosime paketo STATISTIKA galimybėmis ir taikydami keletą prognozavimo modelių ieškosime patikimiausių ir labiausiai tikrovę atitinkančių apmokėtų ne gyvybės draudimo kompanijų žalų ir sudarytų sutarčių skaičių prognozių. Sutarčių skaičių ir nuostolius prognozuosime kiekvienai iš trijų pagrindinių ne gyvybės draudimo rūšių: transporto savininkų ir valdytojų privalomosios civilinės atsakomybės draudimui, sausumos transporto priemonių, išskyrus geležinkelio transporto priemones, draudimui ir turto draudimui. Priklausomai nuo to, kaip sutarčių ar nuostolių duomenys išsibarstę,

pasirinksime duomenų aproksimavimą tiesėmis, eksponentinėmis, logaritminėmis ar parabolinėmis kreivėmis. Taip pat prognozuosime to paties pločio lygaus 3 paprastuoju ir svertiniu slenkamųjų vidurkių metodais, paprastojo eksponentinio glodinimo metodu, taikysime antros eilės autoregresinį prognozavimo modelį, be to tirsime ir sezoniškumo įtaką turimiems duomenims.

Gautus prognozavimo ir draudimo rodiklių kitimo rezultatus analizuosime ir apibendrinsime šio darbo diskusijų dalyje.

Dalis gautų rezultatų pateikti konferencijoje „Matematika ir matematikos dėstymas – 2006“ ir VI-oje studentų konferencijoje „Taikomoji matematika“ (2006 m.).

## 1. TEORINĖ DALIS

### 1.1 BŪTINOJI MOKUMO ATSARGA NE GYVYBĖS DRAUDIMO VEIKLAI

Viena pagrindinių problemų yra draudimo kompanijų mokumo vertinimas. Draudimo kompanijų mokumą būtina vertinti todėl, kad laiku būtų pastebėta finansinė krizė. Draudimo kompanijos mokumą svarbu stebėti pačiai draudimo kompanijai, besidraudžiantiems ir ypatingai priežiūros komisijai. Kilusios problemos dėl „Ingo Balt“ bankroto leido suabejoti, ar Lietuvoje teisingai vertinamas mokumas. Užsienyje mokumo nustatymui yra siūlomi įvairūs modeliai. Lietuvoje buvo nuspręsta taikyti apytikslius mokumo nustatymo metodus, t.y. skaičiuoti būtinąją ir turimąją mokumo atsargą. Mokumą buvo nutarta vertinti vienu skaičiumi, t.y. turimų ir būtinų mokumo atsargų santykiu.

Būtinąją mokumo atsargą ne gyvybės draudimo veiklai yra didesnė suma iš įmokų ir išmokų rodiklių, pakoreguotų atsižvelgiant į perdraudimo rodiklį:

$$BMA = \max \{ \text{įmokų rodiklis}; \text{išmokų rodiklis} \} \times \text{perdraudimo rodiklis.}$$

Skaičiuojant įmokų ir išmokų rodiklius, turi būti naudojamos sumos, apimančios tiek tiesioginio draudimo, neišskaičiavus perdraudikų dalies, tiek ir prisiimto perdraudimo veiklą. Taip pat turi būti įskaitomos papildomo ne gyvybės draudimo sumos. Įmokų rodiklio skaičiavime turi būti naudojami 4 paskutinių ketvirčių duomenys, o išmokų rodiklio skaičiavime – 12 paskutinių ketvirčių duomenys. Draudimo įmonės, vykdančios kreditų rizikos draudimą, draudimą nuo audrų, sausros ar šalnos rizikų, išmokų rodiklį privalo skaičiuoti atsižvelgdamos į 28 paskutinių ketvirčių duomenis.

Įmokų rodiklis apskaičiuojamas šia tvarka: nustatoma įmokų bazė, lygi per 4 paskutinių ketvirčių laikotarpį pasirašytų įmokų sumai arba uždirbtų įmokų sumai, jei ji didesnė už pasirašytų įmokų sumą. Įmokų bazė skraidymo aparatų civilinės atsakomybės, laivų civilinės atsakomybės ar bendros civilinės atsakomybės draudimo atveju yra didinama 50%.

Įmokų bazė koreguojama atimant sumas, išmokėtas ir mokėtinas per 4 paskutinius ketvirčius dėl nutrauktų draudimo sutarčių, taip pat atimant į draudimo įmokas įtrauktus mokesčius ir atskaitymus (kelių mokesčių, atskaitymai Valstybinės draudimo priežiūros tarnybos prie Finansų ministerijos išlaikymui ir Transporto priemonių savininkų ir valdytojų civilinės atsakomybės draudimo biurui), jeigu tokie atskaitymai nebuvo atlikti nustatant įmokų bazę.

Įmokų rodiklis apskaičiuojamas pagal formulę:

$$\begin{aligned} \text{įmokų rodiklis} = & \min \{ \text{koreguota įmokų bazė}; 50 \text{ mln. eurų atitinkanti suma litais} \} \times 18\% + \\ & + [ \text{koreguota įmokų bazė} - \min \{ \text{koreguota įmokų bazė}; 50 \text{ mln. eurų atitinkanti suma litais} \} ] \times \\ & 16\%. \end{aligned}$$

Išmokų rodiklis apskaičiuojamas šia tvarka: nustatoma išmokų bazė, lygi 12 paskutinių ketvirčių laikotarpio išmokų sąnaudoms sumažintoms regresu tvarka išieškotomis sumomis ir pajamomis,

gautomis ir gautinomis realizavus po draudiminių įvykių draudimo įmonės nuosavybėn perėjusį turtą (pagalbos draudimo atveju, draudimo išmokų suma naudojama skaičiuojant išmokų bazę privalo būti įvertinta pagal patirtas draudimo įmonės išlaidas, susijusias su suteikta pagalba), jeigu tokie sumažinimai nebuvo atlikti nustatant išmokų bazę; išmokų bazė koreguojama, ją dauginant iš koeficiento 1/3 (jeigu naudojami 12 ketvirčių duomenys) arba 1/7 (jei naudojami 28 ketvirčių duomenys).

Išmokų rodiklis apskaičiuojamas pagal formulę:

$$\text{išmokų rodiklis} = \min \{ \text{koreguota išmokų bazė; 35 mln. eurų atitinkanti suma litais} \} \times 26\% +$$

$$+ [ \text{koreguota išmokų bazė} - \min \{ \text{koreguota išmokų bazė; 35 mln. eurų atitinkanti suma litais} \} ] \times 23\%.$$

Perdraudimo rodiklis apskaičiuojamas naudojant paskutinių 4 ketvirčių duomenis pagal žemiau pateiktą formulę:

$$\text{perdraudimo rodiklis} = \max \{ 0,5; 1 - \text{perdraudikų dalis išmokų sąnaudose} / \text{išmokų sąnaudos} \}.$$

## **1.2 TURIMOJI MOKUMO ATSARGA NE GYVYBĖS DRAUDIMO VEIKLAI**

Turimą mokumo atsargą sudaro šie elementai (toliau skliaustuose pateikiama prieduose pateiktų lentelių eilutė, kurioje žemiau nurodyti dydžiai turi būti atskleisti):

- apmokėtas įstatinis kapitalas, atėmus kapitalo dalį, kuri yra lygi kaupiamojo dividendo privilegijuotųjų akcijų nominalių verčių sumai;
  - akcijų priedai;
  - perkainojimo rezervas;
  - rezervai, sudaryti iš paskirstytinojo pelno (rezervai ar jų dalis, kurie bus panaudoti tais kalendoriniais metais, kuriais buvo suformuoti, neįtraukiami):
    - privalomasis rezervas;
    - rezervas savoms akcijoms įsigyti;
    - kiti rezervai;
  - ataskaitinių ir ankstesnių ataskaitinių metų nepaskirstytasis pelnas (nuostoliai), atėmus iš jo mokėtinus dividendus;
    - kaupiamojo dividendo privilegijuotosios akcijos ir subordinuotos paskolos gali būti įtrauktos apskaičiuojant turimą mokumo atsargą, tačiau pastarieji elementai negali viršyti 50% dydžio, mažesnio iš turimos ir būtinosios mokumo atsargos, be to, ne daugiau kaip 25% šio dydžio (mažesnio iš turimos ir būtinosios mokumo atsargos) gali sudaryti

nustatyto termino kaupiamojo dividendo privilegijuotosios akcijos ir nustatyto termino subordinuotos paskolos.

- neturintys nustatyto išpirkimo termino draudimo įmonės išleisti vertybiniai popieriai ir kitos finansinės priemonės,

Į turimą mokumo atsargą gali būti įtraukti tik tie turimos mokumo atsargos elementai, kurie nėra skirti ateityje numatomiems įsipareigojimams vykdyti. Turimos mokumo atsargos elementų suma turi būti sumažinama sumomis, kurias sudaro:

- nematerialusis turtas;
- ateinančių laikotarpių sąnaudos.
- savos akcijos, įsigytos draudimo įmonės;
- uždelsti debitoriniai įsipareigojimai;
- kitas, nepaminėtas riboto patikimumo turtas, kurio susigrąžinimas apribotas dėl to, kad skolininkas yra likviduojamas arba skolininkui iškelta bankroto byla;
- teigiami skirtumai tarp atskirų turtui priskiriamų finansinių priemonių balansinės ir tikrosios vertės bei teigiami skirtumai tarp nekilnojamojo turto balansinės ir rinkos vertės (1 priedo 2.6 eilutė), įvertintos nepriklausomų turto vertintojų (tokie skirtumai gali būti nevertinami, jei jie sudaro ne daugiau kaip 5% vertinamo turto objekto balansinės vertės);
- nebalansiniai įsipareigojimai.

## 1.3 LAIKO EILUTĖS

### 1.3.1 PAGRINDINĖS SĄVOKOS

Labai dažnai kintamam reiškiniui aprašyti stebimos kokio nors kintamojo dydžio reikšmės, įgyjamos laikui bėgant ar skirtingose vietose. Visais atvejais turime kintančią sistemą, kurią veikia atsitiktiniai veiksniai. Jos praeitis, vienu ar kitu būdu užrašyta renkant duomenis, laikui bėgant, suteikia tam tikros informacijos apie nagrinėjamą reiškinį. Įvairiems stebėjimams būdingi svyravimai, kurie neišreiškiami paprasta matematine formule dėl neišvengiamų matavimo paklaidų, turi atsitiktinę komponentę.

Tegul  $T$  yra skaičių seka arba intervalas. Visuma atsitiktinių dydžių  $\{\xi_t, t \in T\}$ , apibrėžtų vienoje tikimybinėje erdvėje  $(\Omega, F, P)$ , vadinama *atsitiktiniu procesu*. Parametro  $t$  kitimo aibė  $T$  kartais vadinama indeksų aibe. Aibės  $T$  pavyzdžiai:

$$Z = \{0, \pm 1, \pm 2, \dots\}, N = \{0, 1, 2, \dots\}, \{-\infty, \infty\}, [0, \infty). \quad (1.3.1.1)$$

Atsitiktinis procesas, kurio  $T \subset Z$ , dažniausiai vadinamas *laiko eilute*. Gali būti atveju, kai  $t$  yra bet koks parametras. Tačiau tradiciškai atsitiktinių sekų stebėjimai siejami su reguliariais laiko intervalais vadinami laiko eilutėmis.

Vienu iš pagrindinių laiko eilučių analizės tikslų yra atrasti duomenų kaitos dėsningumus ir pritaikyti matematinius modelius, aprašančius šiuos dėsningumus. Šie matematiniai modeliai leidžia prognozuoti būsimas laiko eilutės reikšmes, kas yra labai svarbu versle ar moksle.

### 1.3.2 BENDRA TIESINIO PROGNOZAVIMO TEORIJA IR STATISTINIŲ MODELIŲ PANAUDOJIMAS PROGNOZEI

Statistinio modelio sukūrimas nagrinėjamiems duomenims nėra savitiksliis uždavinys. Kiekvienas modelis yra tam tikra tikrovės idealizacija, todėl galimą modelį panaudot sprendžiant tokius uždavinius:

1. prognozuoti būsimas sekos reikšmes;
2. modeliuoti daugiau panašių realizacijų;
3. atkurti trūkstamas reikšmes stebėjimų sekoje;
4. išgryninti stebėjimus, atmetant reikšmes, atsiradusias sekoje dėl pašalinio poveikio.

*Prognozė* suprantama kaip būsimų proceso reikšmių įvertinimas remiantis turimomis proceso reikšmėmis.

Tarkime, stebime atsitiktinį vektorių  $X = (X_1, \dots, X_n)^T$ . Atsitiktinio dydžio  $Y$  tiesinė prognozė:

$$\hat{Y} = a + b_1 X_1 + \dots + b_n X_n = a + b^T X. \quad (1.3.2.1)$$

Prognozės tikslumo matas – vidutinė kvadratinė paklaida:

$$\Delta = \Delta(a, b) = E\varepsilon^2, \quad \varepsilon = Y - \hat{Y}. \quad (1.3.2.2)$$

Vidutinė kvadratinė paklaida gaunama mažiausia, kai koeficientai parenkami taip, kad

$$E\varepsilon = 0, \quad \text{cov}(\varepsilon, X) = 0.$$

Optimalūs koeficientai randami iš lygčių

$$\text{cov}(\varepsilon, X) = \text{cov}(Y, X) - \text{cov}(b^T X, X) = R_{YX} - b^T R_{XX} = 0,$$

$$E\varepsilon = EY - a - b^T EX = 0.$$

Jei kovariacinė matrica  $R_{XX}$  neišsigimusi, tai sprendinys vienas:

$$b^* = R_{XX}^{-1} R_{XY}, \quad a^* = EY - b^{*T} EX.$$

### 1.3.3 TRENDAS

Laiko eilučių trendas, išreiškiantis bendrą didėjimo ar mažėjimo tendenciją, dažniausiai yra surandamas naudojant mažiausiųjų kvadratų metodą ir regresinę analizę. Trendas yra nusakomas algebrine funkcija. Ji gali būti parinkta įvairiausių pavidalų. Trendo lygties koeficientams ir tikslumo įverčiams nustatyti naudojami koreliacinės ir regresinės analizės metodai.

Aptarsime keletą labiausiai paplitusių trendo formų.

Tiesinis trendas taikomas, kai matavimo gretimų reikšmių skirtumai (pirmieji skirtumai) yra artimi vienas kitam. Tiesinio trendo lygtis:

$$Y = b_0 + b_1 \cdot t.$$

Antrosios eilės parabolinis trendas yra tinkamas laiko eilučių, kurių duomenų antrieji skirtumai (gretimų pirmųjų skirtumų reikšmės) vienas nuo kito nedaug skiriasi, aproksimavimo modelis. Antros eilės parabolės regresijos (parabolinio trendo) lygtis:

$$Y = b_0 + b_1 \cdot t + b_2 \cdot t^2.$$

Labai dažnai laiko eilutės turi eksponentinį trendą. Jis stebimas, kai duomenys keičiasi beveik vienodu procentu.

Eksponentinio trendo lygtis:

$$Y = b_0 \cdot e^{b_1 t}.$$

Čia užrašytose lygtyse  $b_0$ ,  $b_1$  ir  $b_2$  - nežinomieji trendo koeficientai, o trendo kintamasis laiko eilutėse reiškia sunumeruotus matavimo momentus.

Nežinomieji trendo koeficientai parenkami mažiausių kvadratų metodu, t.y. minimizuojant skirtumų tarp stebimų ir prognozuojamų reikšmių kvadratų sumą. Taigi parametrai  $b_0$  ir  $b_1$  randami pagal formules:

$$b_1 = \frac{\overline{xy} - \bar{x} \cdot \bar{y}}{\overline{x^2} - \bar{x}^2},$$

$$b_0 = \bar{y} - b_1 \bar{x}.$$

Čia brūkšnelis virš kintamojo žymi jo vidurkį.

#### 1.3.3.1 DETERMINACIJOS IR KORELIACIJOS KOEFICIENTAI

Turint regresinę kreivę kyla natūralus klausimas, ar gerai regresinė kreivė atitinka eksperimentinius duomenis. Vienas iš svarbiausių tinkamumo matų yra *determinacijos koeficientas*. Determinacijos koeficientas žymimas  $r^2$  ir apibrėžiamas santykiu:

$$r^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2},$$

tai yra regresinio nuokrypio kvadratų sumos ir bendro nuokrypio kvadratų sumos santykis. Aišku, kad  $0 \leq r^2 \leq 1$ . Kuo  $r^2$  arčiau vieneto, tuo regresinė kreivė geriau tinka eksperimentiniams duomenims.

Kada domina priklausomybės stiprumas tarp nagrinėjamų kintamųjų, naudojamas *koreliacijos koeficientas*. Tai koreliacijos tarp kintamųjų stiprumo matas. Jis žymimas raide  $r$  ir apibrėžiamas kaip kvadratinė šaknis iš determinacijos koeficiento. Turi neigiamą reikšmę neigiamos regresijos atveju ir teigiamą – teigiamos regresijos atveju. Kuo arčiau 1 ar -1 yra  $r$ , tuo stipresnis koreliacinis ryšys sieja nagrinėjamus kintamuosius.

### 1.3.4 SEZONINIAI SVYRAVIMAI

Laiko eilučių sezoniniai svyravimai pasireiškia kaip reguliarūs, sisteminiai nuokrypiai nuo trendo lygties. Labai dažnai tie svyravimai yra sąlygojami sezoniškumo. Šis faktas atsispindi net šių svyravimų pavadinime.

Vienas populiariausių ir vaizdžiausių būdų nustatyti, kad duotoji eilutė yra veikiama sezoniškumo, yra skirtumų tarp trendo ir laiko eilutės reikšmių nagrinėjimas. Jei tų skirtumų svyravimai yra reguliarūs, galima teigti, kad laiko eilutė yra veikiama sezoniškumo.

Kuomet duomenų kreivės viršūnės išsidėsčiusios beveik pagal horizontalią liniją, sakoma, kad turime adityvųjį sezoniškumo modelį. Jei viršūnių taškai turi tendenciją didėti arba mažėti, turimas vadinamas multiplikatyvusis sezoniškumo modelis.

Laiko eilučių teorijoje sezoniškumui aprašyti dažniausiai naudojami įvairūs sezoniškumo indeksai, leidžiantys iš turimos eilutės išskirti sezoniškumo komponentę. Sezoniškumo indeksas rodo vidutinį sezoninį duomenų nuokrypį nuo slenkamųjų vidurkių kreivės.

Sezoninių svyravimų aprašymas gali remtis regresinės analizės metodais. Šio aprašymo esmė – regresinės kreivės, gerai atspindinčios sezoninius svyravimus, suradimas. Regresinės kreivės pavidalas:

$$Y = b_0 + b_1 \cdot t + b_2 \cdot t_1 + \dots + b_n \cdot t_{n-1},$$

kur  $b_0, b_2, \dots, b_n$  - nežinomi koeficientai,  $t$  – trendo kintamasis,  $t_1$  - kintamasis, įgyjantis vienetus reikšmėms tik iš pirmo laiko intervalo ir nulius iš kitų,  $t_2, \dots, t_n$  - analogiški kintamieji.



## 1.4 PROGNOZAVIMO METODAI

Kai turimi duomenys išsidėstę visiškai atsitiktinai ir iš jų sunku išskirti tendą bei sezoniškumo komponentę, reikalingi kiti prognozavimo metodai. Panagrinėsime keletą laiko eilučių prognozavimo metodų, kai duomenis generuojantysis procesas yra stacionarusis.

Norint taikyti tokius prognozavimo metodus nestacionariesiems procesams, nestacionarieji procesai transformuojami, gaunant stacionarijį minėtų procesų pavidalą, t.y. panaikinant tendą. Ši procedūra vadinama diferencijavimu. Tendą galima panaikinti ir paprasčiausiai iš kiekvieno nagrinėjamos sekos nario atimant atitinkamą trendo reikšmę. Tačiau labiausiai paplitęs transformacijos metodas – proceso diferencijavimas, kada kiekviena eilutės reikšmė yra pakeičiama šios reikšmės ir ankstesnės reikšmės skirtumu.

Taip pat naudojant laiko eilučių prognozavimo metodus reikia visada žiūrėti, ar parinktas metodas leidžia pakankamai tiksliai prognozuoti. Prognozavimo klaida apibrėžiama kaip skirtumas tarp stebimos laiko eilutės reikšmės ir prognozuotos. Tų skirtumų kvadratų suma vadinama prognozavimo tikslumu.

### 1.4.1 STACIONARIŲ SEKŲ SAŲVOKOS

Seka  $\{\xi_t\}$  vadinama *stacionariąja*, jeigu jos savybės nekinta laikui bėgant. Griežtai formuluojant, skiriamas stacionarumas plačiąja ir siaurąja prasme.

Procesas  $\xi_t$  vadinamas *stacionariu siaurąja prasme*, jei jo daugiamačiai pasiskirstymai nepriklauso nuo postūmio laike, t. y. :

$$t_1, \dots, t_k \in T, k = 1, 2, \dots, F_{t_1, \dots, t_k}(\bullet) = F_{t_1 + \tau, \dots, t_k + \tau}(\bullet), t_i + \tau \in T \quad (1.4.1.1)$$

Laiko eilučių analizėje dažniausiai naudojama kita sąvoka.

Procesas  $\xi_t$  vadinamas *stacionariu plačiąja prasme*, jei jo matematinis vidurkis ir kovariacinė funkcija nepriklauso nuo poslinkio laike, t. y. jei

$$\forall t, s \in T \quad \mu(t) = \mu(0), \quad (1.4.1.2)$$

$$R(t, s) = R(t - s, 0). \quad (1.4.1.3)$$

Akivaizdu, kad jei procesas  $\xi_t$  yra stacionarus siaurąja prasme ir turi dispersiją, tai jis yra ir stacionarus plačiąja prasme, bet ne atvirkščiai. Tačiau, jei procesas  $\xi_t$  yra Gauso (jei jo daugiamačiai pasiskirstymai yra Gauso pasiskirstymo funkcijų rinkinys), jam abu apibrėžimai sutampa.

Taigi stacionaraus proceso  $\xi_t$  matematinis vidurkis nekinta laike  $E\xi_t = \mu$ , o kovariacinė funkcija yra vieno argumento funkcija:

$$\text{cov}(\xi_{t+\tau}, \xi_t) = E[(\xi_{t+\tau} - \mu)(\xi_t - \mu)] = R(\tau), \forall t \in T. \quad (1.4.1.4)$$

Ši funkcija yra neneigiamai apibrėžta:

$$\forall t_1, \dots, t_k \in T, x_1, \dots, x_k: \sum_{i,j=1}^k R(t_i - t_j) x_i x_j \geq 0. \quad (1.4.1.5)$$

Akivaizdu, kad  $R(\bullet)$  yra lyginė funkcija,  $R(-\tau) = R(\tau)$ .

Kiekvienam  $\tau$  funkciją  $R(\tau)$  padalijus iš  $R(0) \equiv \sigma^2$ , turime *normuotą koreliacinę funkciją*

$$r(\tau) = \text{cor}(\xi_{t+\tau}, \xi_t) = \frac{R(\tau)}{R(0)}. \quad (1.4.1.6)$$

Ši funkcija taip pat lyginė, neneigiamai apibrėžta ir  $|r(\tau)| \leq 1$ . Reikšmė  $r(\tau)$  parodo kiek stipriai proceso reikšmės dabartyje tiesiškai priklauso nuo reikšmės prieš  $\tau$  laiko vienetų. Koreliacinių ryšių žinojimas palengvina laiko eilučių modelio parinkimą ir identifikavimą.

## 1.4.2 STACIONARŪS TIESINIAI MODELIAI

### 1.4.2.1 AUTOREGRESIJOS IR SLENKAMŪJŲ VIDURKIŲ MODELIAI

Jei laiko eilutės stebimos reikšmės stipriai koreliuotos tarpusavyje, tai ateities reikšmę galima prognozuoti naudojantis praeityje stebėtomis reikšmėmis, dažniausiai turinčiomis didžiausią įtaką.

Stacionarus procesas  $\xi_t$  vadinamas *p eilės autoregresijos procesu (AR(p))*, jei jis išreiškiamas:

$$\xi_t = \mu + a_1 \xi_{t-1} + \dots + a_p \xi_{t-p} + \varepsilon_t, \quad t \in Z, \quad (1.4.2.1.1)$$

čia  $\varepsilon_t$  - baltas triukšmas.

Atsitiktinis procesas  $\varepsilon_t$  vadinamas baltu triukšmu, jei jis tenkina  $E\varepsilon_t = 0$  ir  $\text{cov}(\varepsilon_t, \varepsilon_s) = 0$ , jei  $t \neq s$  savybes ir yra stacionarus, t. y.  $D\varepsilon_t \stackrel{\text{def}}{=} \text{const} = \sigma_\varepsilon^2$ .

Pagal šį metodą kiekviena laiko eilutės reikšmė yra tiesinė prieš tai buvusios reikšmės ar reikšmių funkcija. Pirmos eilės autoregresinėje lygtyje yra naudojama tik viena prieš tai buvusi reikšmė, antros eilės – dvi prieš tai esančios reikšmės ir t.t. Prieš tas reikšmes esantys koeficientai nusako, kaip stipriai kiekviena laiko eilutės reikšmė priklauso nuo prieš tai buvusių reikšmių.

Pažymėję  $P(z) = 1 - a_1 z - \dots - a_p z^p$ , lygybę (1.3.23) galima užrašyti:

$$P(L) \widehat{\xi}_t = \varepsilon_t, \quad \widehat{\xi}_t = \xi_t - E\xi_t. \quad (1.4.2.1.2)$$

Be to,  $\mu = P(1) E\xi_t$ .

Stacionarus procesas  $\xi_t$  vadinamas *q eilės slenkamojo vidurkio* (angl. – moving average) procesu (*MA(q)*), jei jis išreiškiamas:

$$\xi_t = \mu + \varepsilon_t + b_1 \varepsilon_{t-1} + \dots + b_q \varepsilon_{t-q}, \quad t \in Z, \quad (1.4.2.1.3)$$

čia  $\varepsilon_t$  - balto triukšmo procesas.

Pažymėję  $Q(z) = 1 + b_1z + \dots + b_qz^q$ , gauname  $\mu = E\xi_t$  ir

$$\widehat{\xi}_t = Q(L)\varepsilon_t. \quad (1.4.2.1.4)$$

Pagal šį metodą kiekviena laiko eilutės reikšmė yra apsprendžiama dabartinės triukšmo reikšmės bei vienos ar kelių prieš tai stebėtų triukšmo reikšmių vidurkiu. Slenkamųjų vidurkių metodo eilė nusako prieš tai buvusių triukšmo reikšmių, kurių pagrindu yra skaičiuojamas vidurkis, skaičių.

Stacionarus procesas  $\xi_t$  vadinamas  $ARMA(p, q)$  procesu, jei

$$\xi_t = \mu + a_1\xi_{t-1} + \dots + a_p\xi_{t-p} + \varepsilon_t + b_1\varepsilon_{t-1} + \dots + b_q\varepsilon_{t-q}, \quad t \in Z, \quad (1.4.2.1.5)$$

čia  $\varepsilon_t$  - balto triukšmo procesas.

### 1.4.2.2 PAPRASTASIS IR SVERTINIS SLENKAMŪJŲ VIDURKIŲ METODAI

Prognozuodami pagal slenkamųjų vidurkių metodą, tariame, kad prognozuojama reikšmė geriausiai reprezentuojama  $n$  prieš tai stebėtų reikšmių aritmetiniu vidurkiu. Simboliškai tai galima užrašyti formule:

$$\hat{y} = \frac{y_{t-1} + y_{t-2} + \dots + y_{t-n}}{n}. \quad (1.4.2.2.1)$$

Šis prognozavimo metodas vadinamas paprastuoju slenkamųjų vidurkių prognozavimo metodu. Jei laukiamas nedidelis duomenų pasikeitimas, reikėtų naudoti didesnę dėmenų  $n$  skaičių. Laukiant didesnio pasikeitimo, reikėtų prognozuoti su mažesniu  $n$ .

Dažnai naudojamas patobulintas paprastasis slenkamųjų vidurkių metodas. Jo esmė remiasi faktu, kad dažniausiai paskutiniosios laiko eilutės reikšmės turi didesnę įtaką prognozuojamam rezultatui nei ankstesnės. Todėl yra imamas svertinis prieš tai stebėtų reikšmių vidurkis:

$$\hat{y} = d_1 \cdot y_{t-1} + d_2 \cdot y_{t-2} + \dots + d_n \cdot y_t, \quad (1.4.2.2.2)$$

kur koeficientai (svoriai) tenkina lygybę  $d_1 + d_2 + \dots + d_n = 1$ . Šis prognozavimo metodas vadinamas svertiniu slenkamųjų vidurkių metodu.

Koeficiento  $d_i$  reikšmė parenkama didesnė prieš kintamąjį, turintį didesnę įtaką. Kokias  $n$  ir  $d_i$  reikšmes parinkti, kad gautume tiksliausią prognozę, priklauso nuo tyrimus atliekančio statistiko.

### 1.4.2.3 PASTASOJO EKSPONENTINIO GLODINIMO METODAS

Paprastojo eksponentinio glodinimo metodas šiandien yra plačiausiai naudojama prognozavimo technika. Šis metodas skiriasi nuo slenkamųjų vidurkių metodo tik svorių suteikimo ankstesnėms reikšmėms metodika. Prognozuojama reikšmė yra apskaičiuojama pagal formulę:

$$\hat{y}_t = \alpha(y_{t-1} - \hat{y}_{t-1}) + \hat{y}_{t-1}, \quad (1.4.2.3.1)$$

kur  $\alpha$  ( $0 \leq \alpha \leq 1$ ) vadinama glodinimo konstanta. Ji susijusi su slenkamųjų vidurkių metodo narių skaičiumi  $n$  apytiksliai tokia pereinamąbe:  $\alpha = \frac{2}{n+1}$ . Todėl, kai  $\alpha$  artimas vienetui, turime nedidelį duomenų glodinimą, o kai  $\alpha$  mažas – gana smarkų glodinimą.

### 1.4.2.4 STACIONARUS TIESINIS PROCESAS

Tarkime,  $\xi_t$  yra stacionarus procesas su vidurkiu  $E\xi_t = \mu$  ir kovariacine funkcija  $R(\tau) = \text{cov}(\xi_t, \xi_{t+\tau})$ .

Stebima imtis  $(\xi_1, \dots, \xi_n)$ , o reikia prognozuoti  $\xi_s$ , kur  $s > n$ . Optimali tiesinė prognozė

$$\hat{\xi}_s = \alpha + \beta_1 \xi_1 + \dots + \beta_n \xi_n$$

gaunama, kai:

$$\beta = R_{XX}^{-1} R_{X\xi_s}, \quad \alpha = \mu - \beta^T EX = \mu(1 - \beta_1 - \dots - \beta_n),$$

Čia  $X = (\xi_1, \dots, \xi_n)^T$ .

$$\text{Todėl } R_{XX} = [R(i-j)]_{i=1, \dots, n}^{j=1, \dots, n}, \quad R_{X\xi_s} = (R(s-1), R(s-2), \dots, R(s-n))^T.$$

### 1.4.3 NESTACIONARŪS TIESINIAI MODELIAI

Tarp ekonominių kintamųjų nesunku rasti tokius, kurie akivaizdžiai nėra stacionarūs. Tai gali būti santaupos, šalies BVP ir pan. Taip yra, nes normaliomis sąlygomis šie rodikliai auga. Tačiau jų pokyčiai (pvz. per metus) dažnai elgiasi kaip stacionarūs procesai.

Atsitiktinis procesas  $\xi_t$  vadinamas  $d$  – eilės *integrutu* (žymima  $\xi \in I(d)$ ), jei jo  $d$  eilės pokyčių procesas yra stacionarus, o  $d - 1$  eilės pokyčiai nėra stacionarūs.

Pažymėkime:

$$\Delta \xi_t = \xi_t - \xi_{t-1} = (1-L)\xi_t.$$

Tada:

$$\Delta^2 \xi_t = \Delta \xi_t - \Delta \xi_{t-1} = (1-L)^2 \xi_t = \xi_t - 2\xi_{t-1} + \xi_{t-2}.$$

Bendru atveju:

$$\Delta^d \xi_t = \Delta^{d-1} \xi_t - \Delta^{d-1} \xi_{t-1} = (1-L)^d \xi_t. \quad (1.4.3.1)$$

Taigi  $\xi \in I(d) \Rightarrow \eta_t = \Delta^d \xi_t$  yra stacionarus procesas. Jei pats  $\xi_t$  yra stacionarus, žymima  $\xi \in I(0)$ .

Tuo atveju, kai  $\xi \in I(1)$ , galioja lygybė

$$\xi_t = \xi_0 + \sum_{\tau=1}^t \eta_\tau, \quad t = 1, 2, \dots \quad (1.4.3.2)$$

čia  $\eta_\tau$  - stacionarus procesas. Taigi  $\xi_t$  gaunamas sumuojant stacionaraus proceso reikšmes. Iš čia ir pavadinimas – integruoti procesai.

ARIMA – autoregresinis integruotas slenkamųjų vidurkių metodas yra plačiai naudojamas laiko eilučių analizei. Jo esmė – sujungti autoregresijos, diferencijavimo ir slenkamųjų vidurkių metodo galimybes. Visos trys sudėtinės dalys yra pagrįstos atsitiktinio triukšmo (nepaaiškinamo išsibarstymo), iškreipiančio laiko eilutės sisteminę komponentę, koncepcija ir turi savo būdingą reakcijos į šį atsitiktinį triukšmą aprašymo būdą.

Atsitiktinis procesas  $\xi_t \in I(d)$  vadinamas *ARIMA*( $p, d, q$ ) procesu, jei jo  $d$  eilės pokyčiai  $\eta_t = (1-L)^d \xi_t$  yra *ARMA*( $p, q$ ) stacionarus procesas. Taigi, galioja lygybė:

$$P(L) \cdot (1-L)^d \hat{\xi}_t = Q(L) \varepsilon_t, \quad (1.4.3.3)$$

čia  $P(z)$  ir  $Q(z)$  -  $p$  ir  $q$  eilės polinomai atitinkamai, o  $\varepsilon_t$  - balto triukšmo procesas.

### 1.4.3.1 NESTACIONARUS TIESINIS PROCESAS

Jei stebime  $\xi_0, \xi_1, \dots, \xi_n$ , kur  $\xi_t$  yra *ARIMA*( $p, d, q$ ) procesas, tai pažymėję

$$\eta_t = (1-L)^d \xi_t$$

randame  $\eta_d, \eta_{d+1}, \dots, \eta_n$ . Iš šios imties įvertiname nežinomus polinomų  $P(z)$  ir  $Q(z)$  koeficientus, apskaičiuojame proceso  $\eta_t$  koreliacinę funkciją  $r(\tau)$  ir  $\eta$  taikome bendrą tiesinio prognozavimo teoriją.

Gavus prognozes  $\hat{\eta}_t, t = n+1, n+2, \dots$ , atitinkamas prognozes  $\hat{\xi}_t$  galima rasti iš išraiškos:

$$\eta_t = (1-L)^d \xi_t = \sum_{k=0}^d (-1)^k \binom{d}{k} \xi_{t-k},$$

$$\text{čia } \binom{d}{k} = \frac{d!}{k!(d-k)!}.$$

Žinodami  $\eta_t$  ir  $\xi_1, \dots, \xi_n$  reikšmes  $\xi_t$ , rekurentiniu būdu galime surasti

$$\xi_t = \eta_t - \sum_{k=1}^d (-1)^k \binom{d}{k} \xi_{t-k}, \quad t = n+1, n+2, \dots$$

#### 1.4.4 MODELIO EILĖS NUSTATYMO BŪDAI

Pirmas žingsnis taikant ARIMA modelį, yra procesų, apsprendžiančių laiko eilučių pobūdį, identifikacija. Turi būti nustatytas modelio ARIMA( $p, d, q$ ) parametų  $p, d, q$  reikšmės.

Paprastai  $d$  lygus 0 arba 1,  $d$  reikšmė lygi pritaikytų diferencijavimo procedūrų skaičiui. Parametrai  $p$  ir  $q$  parenkami naudojantis autokoreliacijos ir dalinės autokoreliacijos funkcijomis. Parametų  $p$  ir  $q$  reikšmės paprastai būna 0, 1 arba 2.

Autoregresiniai modeliai ARIMA( $p, 0, 0$ ) turi eksponentiškai mažėjančias autokoreliacijos funkcijos reikšmes ir aiškiai išsiskiriančias pirmąsias dalinės autokoreliacijos funkcijos reikšmes.

Slenkamųjų vidurkių modeliai ARIMA( $0, 0, q$ ) turi aiškiai išsiskiriančias pirmąsias autokoreliacijos funkcijos reikšmes ir eksponentiškai mažėjančias dalinės autokoreliacijos funkcijos reikšmes.

Kai autokoreliacijos ir dalinės autokoreliacijos funkcijos reikšmės mažėja eksponentiškai, geriausiai tinka ARIMA( $p, 0, q$ ) modelis.

##### 1.4.4.1 AUTOKORELIACIJOS IR DALINĖS AUTOKORELIACIJOS FUNKCIJOS

Autokoreliacijos funkcija pateikia pradinių duomenų ir pastumtų per tam tikrą narių skaičių (1, 2, 3 ir t.t.) duomenų koreliacijos koeficiento reikšmių seką. Autokoreliacijos funkcijos reikšmė postūmiui  $k$  yra skaičiuojama pagal formulę:

$$r_k = \frac{\sum_{i=1}^{n-k} (y_i - \bar{y})(y_{i+k} - \bar{y})}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (1.4.4.1.1)$$

čia  $\bar{y}$  - vidurkis,  $n$  - stebėjimų skaičius.

Dalinės autokoreliacijos funkcija prie postūmio  $k$  yra skaičiuojama pašalinant tarpinių postūmių (1, 2, ...,  $k-1$ ) įtaką. Dalinės autokoreliacijos funkcijos reikšmė postūmiui  $k$  yra apibrėžiama kaip regresijos lygties

$$y_t = a_{k1} \cdot y_{t-1} + a_{k2} \cdot y_{t-2} + \dots + a_{kk} \cdot y_{t-k} + \varepsilon_t,$$

koeficientas  $a_{kk}$ .

## 1.5 PROGRAMINĖ ĮRANGA


Šio darbo tikslams įgyvendinti, konkrečiau sutarčių skaičiaus ir nuostolių laiko eilučių analizei pasirinktas statistinis paketas STATISTICA. Tokį pasirinkimą nulėmė daugybė paketo sprendžiamų problemų, puikios grafinio rezultatų pateikimo galimybės, patogi vartotojo aplinka ir geras paketo aprašymas. Taip pat labai svarbu skaičiavimų tikslumas ir greitis, nagrinėjamų statistinių metodų gausa, vidinės komandinės programavimo kalbos egzistavimas, leidžiantis atlikti reikalingą duomenų analizę.

Kitaip tariant STATISTICA – tai kompleksinė integruota sistema, skirta duomenų masyvų statistinei analizei, grafikų ir diagramų braižymui, informacijos masyvų valdymui bei turinti platų pasirinkimą bazinių analitinių procedūrų, skirtų moksliniams, verslo ar inžineriniams skaičiavimams.

## 2. TIRIAMOJI DALIS IR REZULTATAI

### 2.1 LIETUVOS NE GYVYBĖS DRAUDIMO RINKOS RAIDA

Privati Lietuvos draudimo rinka pradėjo formuotis 1991-aisiais metais. Įsteigtos naujos draudimo kompanijos, kapitalą pradėjo investuoti ir užsienio draudimo įmonės. 1991-aisiais metais Lietuvoje licencijas turėjo 6 draudimo (visos ne gyvybės draudimo) kompanijos. 1998-ųjų metų pabaigoje licencijas turėjo 32 draudimo įmonės: 26 iš jų – ne gyvybės draudimo, 4 – gyvybės draudimo ir 2 kredito draudimo įmonės. Šiandien Lietuvoje užsiimti draudimine veikla licencijas turi 25 draudimo įmonės, 8 iš kurių yra gyvybės draudimo įmonės ir 17 – ne gyvybės draudimo įmonių. Ne gyvybės draudimo kompanijų skaičiaus kitimas 1991-2005 metų laikotarpiu pavaizduotas 2.1 paveiksle. Gyvybės draudimo ir ne gyvybės draudimo kompanijų skaičiaus palyginimas pateiktas 1 priede (1.1 pav.).




2.1.1 pav. Ne gyvybės draudimo kompanijų skaičiaus kitimas

Per 2005-ųjų metų 11 mėnesių sudaryta 3232100 ne gyvybės draudimo sutarčių. Palyginus su 2004-ųjų metų atitinkamo laikotarpio duomenimis, sudarytų ne gyvybės draudimo sutarčių skaičius sumažėjo apytiksliai 15 procentų. Prieš metus, t.y. 2004-aisiais metais sudarytų ne gyvybės draudimo sutarčių skaičius, lyginant su 2003-aisiais, buvo išaugęs iki 3,8 mln. litų (maždaug 3,5 procentais). 2.3 darbo dalyje prognozuosime sutarčių skaičių 2005-ųjų metų antram ketvirčiui (ketvirčių duomenis turime būtent nuo 1998-ųjų metų pirmo ketvirčio iki 2005-ųjų metų antro ketvirčio imtinai).


2005-aisiais metais ne gyvybės draudimo rinkoje pasirašyta 694,9 mln. litų draudimo įmokų. Palyginus su 2004-ųjų metų atitinkamo laikotarpio duomenimis, pasirašyta 8,3 procentais daugiau draudimo įmokų. Ne gyvybės draudimo rinka per 2004-uosius metus, lyginant su 2003-aisiais metais, paaugo 12,1 procentą. Ne gyvybės draudimo rinkos padidėjimą nulėmė 18,9 procentus padidėjusios transporto priemonių valdytojų civilinės atsakomybės privalomojo draudimo įmokos ir 26,6 procentais padidėjusios sausumos transporto priemonių, išskyrus geležinkelio transporto priemones, draudimo įmokos. 2.1.2 paveiksle pavaizduotas draudimo įmokų kitimas 1998-2005 metų laikotarpiu.






**2.1.2 pav. Pasirašytų ne gyvybės draudimo įmokų kitimas**

Išsivysčiusiose pasaulio šalyse didžiąją draudimo rinkos dalį sudaro gyvybės draudimas. Lietuvoje taip dar nėra. Čia populiaresnis ne gyvybės draudimas, tačiau gyvybės draudimo užimama dalis draudimo rinkoje pamažu didėja. Tai matyti ir iš 2.1.3 paveikslo. Sprendžiant pagal per 2005-ųjų metų sausio-lapkričio mėnesiais pasirašytas draudimo įmokas, ne gyvybės draudimo rinkos dalis sudarė 73,9 procentus draudimo rinkos. Prieš metus pasiskirstymas buvo: 76 procentai – ne gyvybės draudimas, 24 procentai – gyvybės draudimas.




**2.1.3 pav. Ne gyvybės draudimo užimama dalis draudimo rinkoje**

Svarbi draudimo charakteristika yra ir apmokėtos draudimo kompanijų žalos. 2005-aisiais metais apmokėta 310,7 mln. litų ne gyvybės draudimo žalų. Palyginus su 2004-ųjų metų atitinkamo laikotarpio duomenimis, žalų apmokėta 28,2 procentais daugiau. 2004-aisiais metais draudimo išmokų pagal draudiminius įvykius išmokėta 281,0 mln. litų, tai yra 6,8 procentais mažiau nei per 2003-uosius metus. Ne gyvybės draudimo kompanijų išmokos 1998-2005 metų laikotarpiu:



**2.1.4 pav. Apmokėtų ne gyvybės draudimo žalų kitimas**

Didžiąją dalį ne gyvybės draudimo rinkos užima transporto priemonių savininkų ir valdytojų civilinės atsakomybės draudimas (36,08 proc.), sausumos transporto priemonių, išskyrus geležinkelio transporto priemones, draudimas (28,31 proc.) ir turto draudimas (15,46 proc.) (2.1.5 pav.). 2004-aisiais metais dominavo tos pačios draudimo grupės ir užėmė atitinkamai 35,2 proc., 27,1 proc. ir 15,5 proc. rinkos dalies.



**2.1.4 pav. Ne gyvybės draudimo įmokų struktūra 2005m.**

Ne gyvybės draudimo įmokų ir išmokų struktūros kitimas grafikų pavidalu pavaizduotas 1 priedo 1.2-1.5 paveiksluose.

## 2.2 NE GYVYBĖS DRAUDIMO KOMPANIJŲ MOKUMAS

Draudimo priežiūros komisijos internetiniame puslapyje dar neskelbiamos atskiros Lietuvos draudimo kompanijų finansinės atskaitos. Be to ne visos draudimo kompanijos ir skelbia savo finansines ataskaitas, nes net ir pačių didžiausių draudimo kompanijų internetiniuose puslapiuose nerasime balanso ar pelno (nuostolio) ataskaitų. Dėl minėtų priežasčių nagrinėsime tik dalies ne gyvybės draudimo kompanijų mokumą ir tik 2004-aisiais metais.

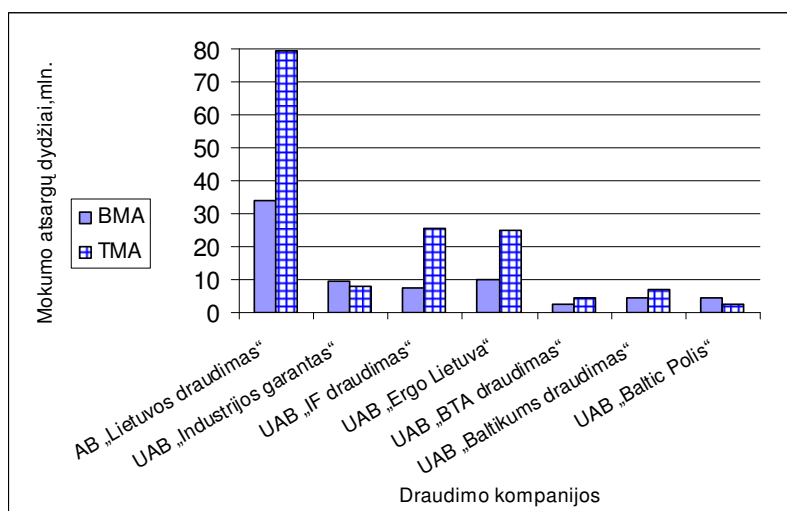
Nustatome įmokų, išmokų ir persidraudimo rodiklius, nuo kurių priklauso būtinoji mokumo atsarga (BMA). Šių rodiklių ir BMA reikšmes pateikiame 2.2.1 lentelėje. Kitus duomenis, kuriuos naudojome minėtiems rodikliams apskaičiuoti, galima rasti 2 priedo 2.1 lentelėje.

**2.2.1 lentelė**

### BMA skaičiavimo rezultatai

| Draudimo kompanija         | Įmokų rodiklis | Išmokų rodiklis | Persidraudimo rodiklis | BMA      |
|----------------------------|----------------|-----------------|------------------------|----------|
| AB „Lietuvos draudimas“    | 36790480,02    | 22519134,9      | 0,918440253            | 33789858 |
| UAB „Industrijos garantas“ | 9800708,58     | 3077745,362     | 0,962585794            | 9434023  |
| UAB „IF draudimas“         | 9813216,24     | 4259063,075     | 0,781400724            | 7668054  |
| UAB „Ergo Lietuva“         | 17184027,96    | 7879585,393     | 0,574873013            | 9878634  |
| UAB „BTA draudimas“        | 2984211,54     | 862144,4        | 0,78808935             | 2351825  |
| UAB „Baltikums draudimas“  | 8744584,5      | 2089717,153     | 0,5                    | 4372292  |
| UAB „Baltic Polis“         | 4689042,66     | 1275553,76      | 0,932558238            | 4372805  |

Apskaičiuojame draudimo kompanijų turimąsias mokumo atsargas (TMA) ir jas palyginame su būtinosiomis mokumo atsargomis (2.2.1 pav.). Dydžiai, mažinantys ir didinantys turimąją mokumo atsargą, lentelės pavidalu pateikti 2 priedo 2.2 lentelėje.



**2.2.1 pav. TMA ir BMA palyginimas**

## **2.3 PAGRINDINIŲ NE GYVYBĖS DRAUDIMO RŪŠIŲ SUTARČIŲ SKAIČIAUS PROGNOZAVIMAS**

### **2.3.1 TPCAD SUTARČIŲ SKAIČIAUS PROGNOZAVIMAS**

Transporto priemonių savininkų ir valdytojų civilinės atsakomybės privalomasis draudimas užima didžiąją ne gyvybės draudimo rinkos dalį. Todėl pirmiausiai prognozuosime šios draudimo rūšies sutarčių skaičių.

#### **2.3.1.1 TPCAD SUTARČIŲ PROGNOZAVIMAS PAGAL 1998-2005 METŲ DUOMENIS**

Draudimo priežiūros komisijos internetiniame puslapyje radome nuo 1998-ųjų iki 2005-ųjų metų antrojo ketvirčio sutarčių skaičių statistinius duomenis, todėl prognozavimą atliksime naudodami būtent šio laikotarpio duomenis.

##### **2.3.1.1.1 TPCAD SUTARČIŲ SKAIČIAUS PROGNOZAVIMAS REGRESINIŲ KREIVIŲ METODAIS**

Nagrinėsime sausumos transporto privalomosios civilinės atsakomybės draudimo sutartis 1998-2005 metų laikotarpiu.

Tarkime, kad turimus duomenis galima aproksimuoti tiesine funkcija. Norime gauti tokią funkciją, kuri geriausiai atspindėtų turimus duomenis. Taikydami mažiausių kvadratų metodą, randame tiesinės regresijos lygtį:

$$\text{Sutartys} = -139320 + 42425,65 \cdot x.$$

Taip pat randame determinacijos ir koreliacijos koeficientus nagrinėtam atvejui. Mūsų atveju determinacijos koeficientas artimas vienetui, t.y.  $r^2=0,8267$ , todėl tiesinis trendas yra tinkama turimų duomenų aproksimacija. Koreliacijos koeficientas  $r=0,9092$  parodo stiprią koreliacinę priklausomybę tarp laiko ir sudarytų sutarčių skaičiaus. Tokiu būdu gauta 2005-ųjų metų antro ketvirčio sutarčių prognozė yra 1133449 sutartys. Nuo tikrojo sudarytų tą ketvirtį sutarčių skaičiaus prognozė skiriasi 121942 sutartimis (arba apytiksliai 12% sutarčių). Rezultatas pakankamai tikslus. Tačiau pabandydysime paieškoti kitų regresinių metodų turimo sutarčių skaičiaus kreivei aproksimuoti.

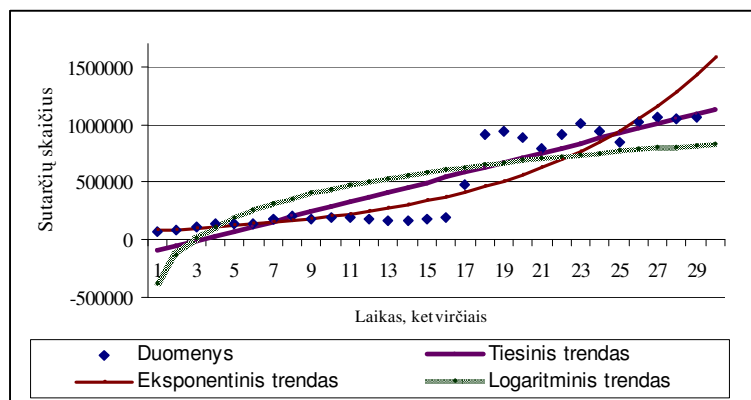
Iš duomenų grafiko (2.3.1.1.1 pav.) sunku pasakyti, kokia regresinė kreivė būtų tinkama išsibarsčiusių duomenų aproksimacija, todėl tiesiog pasinaudojame statistinio paketo suteikiama galimybe – rasti logaritminio ir eksponentinio trendų lygčių koeficientus. Logaritminio trendo lygtis:

$$\text{Sutartys} = -382970 + 824680 \cdot \lg(x),$$

EkspONENTINIO TRENDO LYGTIS:

$$\text{Sutarčys} = 72179,8 \cdot e^{0,1028 \cdot x}$$

Gautas prognozės (2.3.1.1.1.1 pav.) lyginame su turimu tikroju sutarčių skaičiumi. Nuo 2005-ųjų antrą ketvirtį sudarytų sutarčių skaičiaus prognozė skiriasi: 17% sutarčių, taikant logaritminį trendą ir net 55%, taikant eksponentinį trendą.



**2.3.1.1.1 pav. TPCAD sutarčių skaičiaus ir jo prognozių palyginimas**

### **2.3.1.1.2 TPCAD SUTARČIŲ SKAIČIAUS PROGNOZAVIMAS PAPRASTUOJU IR SVERTINIŲ SLENKAMŲJŲ VIDURKIŲ METODU**

Iš 2.3.1.1.1.1 paveikslo matyti, kad tai nėra tos kreivės, kurios tiksliai aproksimuotų duomenis, nes sutarčių skaičius nėra išsibarstęs arti tiesės, logaritminės ar eksponentinės kreivės. Todėl prognozavimui taikysim ir kitus metodus, ieškodami tokių modelių, kuriuos taikant prognozavimo rezultatų kreivės būtų mažiau nutolusios nuo duomenų kreivės.

Prognozę atliekame pločio lygaus 3 paprastuoju ir svertiniu slenkamųjų vidurkių metodais. Kitaip sakant, tariame, kad prognozuojama reikšmė geriausiai reprezentuojama trijų prieš tai stebėtų reikšmių aritmetiniu vidurkiu. Taikant svertinį metodą bandėme parinkti įvairius svorius, įtakančius ieškomos tiksliausios prognozės galutinį rezultatą. Svorius imame lygius 0,1, 0,5 ir 0,4. Toks svorių parinkimas rodo, kad didžiausią įtaką prognozei turi paskutiniai du dėmenys.

Prognozuodami pagal slenkamųjų vidurkių metodą, antrąjį ketvirtį sutarčių skaičių gausime 1054649, o pagal svertinį – 1050898. Prognozės tikslumą įvertinanti vidutinė kvadratinė paklaida mažesnė svertinių slenkamojo vidurkių metodo  $25254278518 < 29132594930,74$ , vadinasi svertinių slenkamojo vidurkių metodo prognozė turėtų būti tikslesnė. Taip ir gauname, nes 2005 m. 2-ąjį ketvirtį buvo sudaryta 1011507 sutarčių, taigi tikrajai reikšmei artimesnė prognozė – svertinių slenkamojo vidurkių metodo. Prognozavimo rezultatai pateikti 2.3.1.1.2.1 lentelėje.

## 2.3.1.1.2.1 lentelė


## Prognozavimas paprastuoju ir svertiniu slenkamųjų vidurkių metodu

| Data                      | Sutarčių sk. | Paprastasis slenkamųjų vidurkių metodas | Vidutinė kvadratinė paklaida | Svertinis slenkamųjų vidurkių metodas | Vidutinė kvadratinė paklaida |
|---------------------------|--------------|---|------------------------------|---------------------------------------|------------------------------|
| 1998 1 ketvirtis          | 75710        |   |                              |                                       |                              |
| 1998 2 ketvirtis          | 90666        |   |                              |                                       |                              |
| 1998 3 ketvirtis          | 104632       |   |                              |                                       |                              |
| 1998 4 ketvirtis          | 133189       | 90336                                   | 1836379609                   | 96153                                 | 1371635667                   |
| 1999 1 ketvirtis          | 131611       | 109496                                  | 489087968                    | 114658                                | 287397428                    |
| 1999 2 ketvirtis          | 143252       | 123144                                  | 404331664                    | 129702                                | 183599790                    |
| 1999 3 ketvirtis          | 172285       | 136017                                  | 1315343645                   | 136425                                | 1285925256                   |
| 1999 4 ketvirtis          | 206480       | 149049                                  | 3298281474                   | 153701                                | 2785612285                   |
| 2000 1 ketvirtis          | 181672       | 174006                                  | 58772667                     | 183060                                | 1925711                      |
| 2000 2 ketvirtis          | 194586       | 186812                                  | 60429893                     | 193137                                | 2098732                      |
| 2000 3 ketvirtis          | 189949       | 194246                                  | 18464209                     | 189318                                | 397656                       |
| 2000 4 ketvirtis          | 185729       | 188736                                  | 9040044                      | 191440                                | 32613237                     |
| 2001 1 ketvirtis          | 167591       | 190088                                  | 506115009                    | 188725                                | 446633276                    |
| 2001 2 ketvirtis          | 171540       | 181090                                  | 91196133                     | 178896                                | 54107794                     |
| 2001 3 ketvirtis          | 180405       | 174953                                  | 29720669                     | 170984                                | 88747704                     |
| 2001 4 ketvirtis          | 196918       | 173179                                  | 563555947                    | 174691                                | 494035084                    |
| 2002 1 ketvirtis          | 479451       | 182954                                  | 87910273344                  | 186124                                | 86040904925                  |
| 2002 2 ketvirtis          | 917989       | 285591                                  | 399926808805                 | 308280                                | 371745186623                 |
| 2002 3 ketvirtis          | 941455       | 531453                                  | 168101913339                 | 626613                                | 99125547932                  |
| 2002 4 ketvirtis          | 891307       | 779632                                  | 12471380075                  | 883522                                | 60612453                     |
| 2003 1 ketvirtis          | 787879       | 916917                                  | 16650805444                  | 919049                                | 17205621368                  |
| 2003 2 ketvirtis          | 909220       | 873547                                  | 1272562929                   | 854951                                | 2945167776                   |
| 2003 3 ketvirtis          | 1001518      | 862802                                  | 19242128656                  | 846758                                | 23950595696                  |
| 2003 4 ketvirtis          | 937321       | 899539                                  | 1427479524                   | 934005                                | 10995193                     |
| 2004 1 ketvirtis          | 842489       | 949353                                  | 11419914496                  | 966609                                | 15405873696                  |
| 2004 2 ketvirtis          | 1016164      | 927109                                  | 7930733655                   | 905808                                | 12178468807                  |
| 2004 3 ketvirtis          | 1063552      | 931991                                  | 17308209014                  | 921442                                | 20195195256                  |
| 2004 4 ketvirtis          | 1043842      | 974068                                  | 4868364560                   | 1017752                               | 680703754                    |
| 2005 1 ketvirtis          | 1056554      | 1041186                                 | 236175424                    | 1050929                               | 31638375                     |
| Prognozė 2-ajam ketvičiui | 1011507      | 1054649                                 |                              | 1050898                               |                              |
| Prognozės tikslumas       |              |   | 29132594931                  |                                       | 25254278518                  |

### 2.3.1.1.3 TPCAD SUTARČIŲ SKAIČIAUS PROGNOZAVIMAS PAPRASTOJO EKSPONENTINIO GLODINIMO METODU

Prognozavimą atliksime STATISTICA moduliu *Times Series*. Sudarę duomenų lentelę pagrindiniame laiko eilučių analizės lange, parenkame mūsų duomenų kintamąjį ir nurodome reikalingą glodinimo konstantos  $\alpha$  reikšmę. Rezultatus palyginus įvairiems  $\alpha$ , gavome, kad skirtumų


tarp duomenų ir prognozės kvadratų vidurkis yra mažiausias, kuomet  $\alpha$  lygus 0,65. Grafinis prognozės rezultatų vaizdas 2.3.1.1.3.1 paveiksle.



2.3.1.1.3.1 pav. TPCAD sutarčių skaičiaus prognozavimas paprastojo eksponentinio glodinimo metodu

### 2.3.1.1.4 TPCAD SUTARČIŲ SKAIČIAUS PROGNOZAVIMAS TAIKANT AUTOREGRESINĮ MODELĮ

Turėdami tikslą nustatyti sutarčių skaičiaus autoregresinės priklausomybės pobūdį, pirmiausiai nustatome, nuo kurių praeities duomenų yra ženkliausia mūsų laiko eilutės priklausomybė. Tam pasinaudosime autokoreliaciniais priklausomybės koeficientų skaičiavimais, atliekamais STATISTICA *Times Series* modulyje.



2.3.1.1.4.1 pav. Autokoreliacijos funkcija

Reikšmingiausia prognozuojamos reikšmės laiko momentu  $t$  autokoreliacinė priklausomybė nuo reikšmių, gautų laiko momentais  $t-1$  ir  $t-2$ . Kitaip tariant, pirmam ir antram postūmiams esant gauname didžiausias koreliacinės funkcijos reikšmes, kurios parodo duomenų eilutės narius (laiko momentais  $t-1$  ir  $t-2$ ), turinčius didžiausią įtaką prognozuojamam rezultatui. Autokoreliacinės funkcijos grafikas pateiktas 2.3.1.1.4.1 paveiksle.

Todėl autoregresinės prognozės lygtį galėtume užrašyti taip:


$$\hat{y}_t = b_0 + b_1 y_{t-1} + b_2 y_{t-2} .$$

Ieškosime nežinomų koeficientų  $b_0, b_1, b_2$ . Tam naudosime STATISTICA modulį *Nonlinear Estimations*. Gautus koeficientus surašome į lygtį, ir norint apskaičiuoti 30-tojo ketvirčio sutarčių skaičių, tereikia atitinkamas 29-to ir 28-to ketvirčių reikšmes įrašyti į surastą lygtį:

$$\hat{y}_t = 46708,19 + 1,291296 \cdot y_{t-1} - 0,338171 \cdot y_{t-2} .$$


Gauta prognozė yra 1058035 sutartys.

Taikant aprašytą autoregresinį modelį, gautos prognozės kreivė pavaizduota 2.3.1.1.4.2 paveiksle:



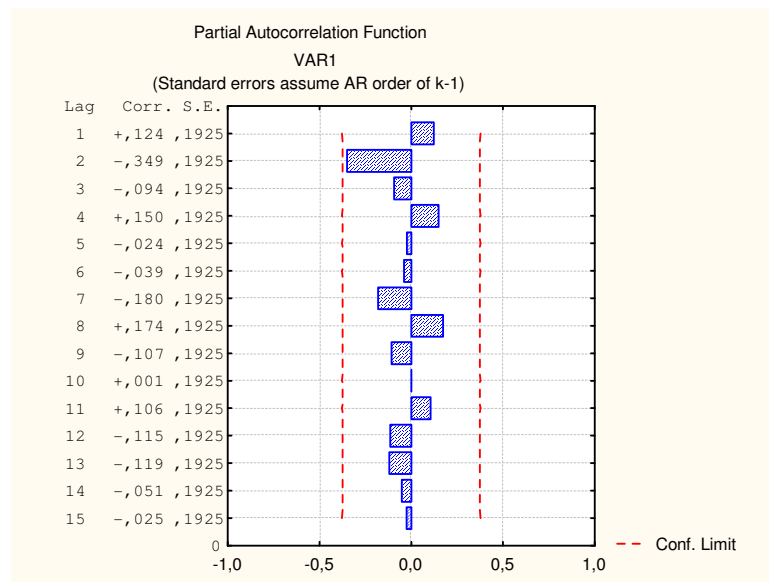
2.3.1.1.4.2 pav. TPCAD sutarčių skaičiaus prognozavimas taikant autoregresinį modelį

Aprašyto modelio liekanų eilutės autokoreliacijos ir dalinės autokoreliacijos funkcijos neturi reikšmingai skirtis nuo nulio ir liekanų reikšmės turi atitikti baltajam triukšmui, t. y. turi būti atsitiktinės. Šią prielaidą tikriname Box‘o-Ljung‘o kriterijumi.



2.3.1.1.4.3 pav. Autoregresinio modelio liekanų autokoreliacijos funkcija





#### 2.3.1.1.4.4 pav. Autoregresinio modelio liekanų dalinės autokoreliacijos funkcija

Kaip matyti iš 2.3.1.1.4.3 ir 2.3.1.1.4.4 paveikslų autokoreliacijos ir dalinės autokoreliacijos funkcijų reikšmės pasiskirsčiusios atsitiktinai, o iš 2.3.1.1.4.1 lentelės – kad Box'o-Ljung'o kriterijus yra statistiškai nereikšmingas visiems postūmiams. Taigi antros eilės autoregresinį modelį galime laikyti priimtinu.

#### 2.3.1.1.4.1 lentelė

Baltojo triukšmo hipotezės tikrinimas liekanoms

|          | Box & Ljung | p        |           | Box & Ljung | p        |
|----------|-------------|----------|-----------|-------------|----------|
| <b>1</b> | 0,46194     | 0,496723 | <b>9</b>  | 10,85442    | 0,285866 |
| <b>2</b> | 3,83241     | 0,147181 | <b>10</b> | 10,94456    | 0,361893 |
| <b>3</b> | 4,88044     | 0,180787 | <b>11</b> | 10,99363    | 0,443825 |
| <b>4</b> | 6,26871     | 0,179988 | <b>12</b> | 11,02055    | 0,527174 |
| <b>5</b> | 6,75499     | 0,239541 | <b>13</b> | 11,56059    | 0,563970 |
| <b>6</b> | 7,15986     | 0,306348 | <b>14</b> | 11,65947    | 0,633624 |
| <b>7</b> | 9,58203     | 0,213565 | <b>15</b> | 11,67853    | 0,703163 |
| <b>8</b> | 10,39497    | 0,238437 |           |             |          |

### 2.3.1.2 TPCAD SUTARČIŲ PROGNOZAVIMAS PAGAL 2002-2005 METŲ DUOMENIS

Lietuvos Respublikos Transporto priemonių savininkų ir valdytojų civilinės atsakomybės privalomojo draudimo įstatymas (TPCAD) priimtas 2001 m. birželio 14 d. TPCAD pradėjo galioti 2002 m. sausio 1 d., o reikalavimas apdrausti juo transporto priemonę įsigaliojo dar po 3 mėnesių, nuo

balandžio mėn. 1 dienos, Ryškus sutarčių skaičiaus šuolis gali įtakoti prognozavimo rezultatus, todėl pabandydysime ieškoti patikimų ir tikslių prognozių naudodami trumpesnio laikotarpio duomenis.

Atliksime visų Lietuvos draudimo kompanijų transporto priemonių privalomosios civilinės atsakomybės draudimo sutarčių skaičiaus prognozavimą naudodami statistinius duomenis nuo 2002-ųjų metų II-ojo ketvirčio iki 2005-ųjų metų II-ojo ketvirčio. Prognozuosime tais pačiais anksčiau aptartais sutarčių prognozavimui taikytais metodais, kai naudojome 1998-2005-ųjų metų duomenis. Prognozuojant taikydami antros eilės autoregresinį modelį, reikšmingiausią prognozuojamos reikšmės laiko momentu  $t$  autokoreliacinę priklausomybę gavome nuo reikšmių laiko momentais  $t-1$  ir  $t-4$ . Autoregresinės prognozės lygtis:

$$\hat{y}_t = -33063,5 + 0,373252 \cdot y_{t-1} + 0,732824 \cdot y_{t-4}.$$


Analizuojant sezoniškumo įtaką turimiems duomenis radome tokią tiesinio trendo su sezoniniais svyravimais lygtį:

$$\hat{y}_t = 735270,1 + 20046,32 \cdot t + 112289,3 \cdot t_1 + 146627 \cdot t_2 + 81895,67 \cdot t_3$$

Tiriant šios regresinės kreivės tinkamumą turimiems sutarčių skaičiaus duomenims, determinacijos koeficientą gavome lygų 0,8144.

### 2.3.1.3 TPCAD SUTARČIŲ PROGNOZAVIMO REZULTATAI

Prognozavimo metodų paklaidas ir skirtumus tarp tikrojo sutarčių skaičiaus ir prognozių pateikiame dviems skirtingiems laikotarpiams 2.3.1.3.1 lentelėje. Šioje lentelėje naudojami žymenys *Absoliutinė ir santykinė paklaidos\_1* ir *Vidutinė kvadratinė paklaida\_1*, kuomet prognozavimui buvo naudojami duomenys nuo 1998-ųjų metų I-ojo ketvirčio iki 2005-ųjų metų II-ojo ketvirčio ir *Absoliutinė ir santykinė paklaidos\_2* bei *Vidutinė kvadratinė paklaida\_2*, kuomet prognozavimui buvo naudojami duomenys nuo 2002-ųjų metų II-ojo ketvirčio iki 2005-ųjų metų II-ojo ketvirčio.



2.3.2.1 pav. TPCAD sutarčių skaičiaus prognozių palyginimas

## 2.3.1.3.1 lentelė

## TPCAD sutarčių prognozavimo rezultatai

| Prognozavimo metodas                        | Absoliutinė ir santykinė paklaidos_1 | Absoliutinė ir santykinė paklaidos_2 | Vidutinė kvadratinė paklaida_1 | Vidutinė kvadratinė paklaida_2 |
|---|--------------------------------------|--------------------------------------|--------------------------------|--------------------------------|
| Tiesinis trendas                            | 121942<br>(12,06%)                   | 42182<br>(4,17%)                     | $26,408 \cdot 10^9$            | $4,036 \cdot 10^9$             |
| Tiesinis trendas su sezoniniais svyravimais | 162733<br>(16,09%)                   | 96655<br>(9,56%)                     | $25,479 \cdot 10^9$            | $1,306 \cdot 10^9$             |
| Logaritminis trendas                        | 176325<br>(17,43%)                   | 8571<br>(0,85%)                      | $63,439 \cdot 10^9$            | $5,263 \cdot 10^9$             |
| EkspONENTINIS trendas                       | 565305<br>(55,89%)                   | 42027<br>(4,15%)                     | $32,731 \cdot 10^9$            | $3,968 \cdot 10^9$             |
| Paprastais slenkamųjų vidurkių metodas      | 43142<br>(4,27%)                     | 43142<br>(4,27%)                     | $29,133 \cdot 10^9$            | $9,283 \cdot 10^9$             |
| Svertinis slenkamųjų vidurkių metodas       | 39391<br>(3,89%)                     | 39391<br>(3,89%)                     | $25,254 \cdot 10^9$            | $8,479 \cdot 10^9$             |
| Paprastojo eksponentinio glodinimo metodas  | 38911<br>(3,85%)                     | 20215<br>(2,00%)                     | $23,902 \cdot 10^9$            | $7,030 \cdot 10^9$             |
| Autoregresinis modelis                      | 46528<br>(4,4%)                      | 94459<br>(9,34%)                     | $10,641 \cdot 10^9$            | $2,293 \cdot 10^9$             |

2.3.1.3.1 paveiksle matome skirtumus tarp gautų prognozių naudojant 1998-2005-ųjų metų duomenis (1 prognozė) ir naudojant duomenis nuo 2002-ųjų metų II-ojo ketvirčio iki 2005-ųjų metų II-ojo ketvirčio (2 prognozė). Sutarčių skaičiaus prognozavimo modeliai pateikti 3 priede.

### 2.3.3 SAUSUMOS TRANSPORTO PRIEMONIŲ, IŠSKYRUS GELEŽINKELIO TRANSPORTO PRIEMONES DRAUDIMO SUTARČIŲ PROGNOZAVIMAS


Sausumos transporto priemonių (TP), išskyrus geležinkelio transporto priemones (TP), draudimo sutartis prognozuosime paprastuoju slenkamųjų vidurkių metodu, svertiniu slenkamųjų vidurkių metodu, paprastojo eksponentinio glodinimo metodu; taikysime autoregresinį modelį, duomenų apksimavimą tiesiniu, logaritminiu ir eksponentiniu trendais.

Randame determinacijos ir koreliacijos koeficientus. Mūsų atveju determinacijos koeficientas  $r^2=0,6893$ . Tiesiniu trendu sutarčių duomenis aproksimuoti galima. Koreliacijos koeficientas  $r=0,9092$  parodo stiprią koreliacinę priklausomybę tarp laiko ir sudarytų sutarčių skaičiaus. Tiesinio trendo lygtis:

$$\text{Sutartys} = 39318,0099 + 1345,9901 \cdot x ,$$

atitinkamai eksponentinio ir logaritminių trendų lygtys:

$$\text{Sutarčys} = 42103,3054 \cdot e^{0,0215 \cdot x}, \quad \text{Sutarčys} = 31837,0066 + 25930,3573 \cdot \lg x.$$



### 2.3.3.1 pav. Prognozavimo rezultatų palyginimas, duomenų aproksimacijai naudojant, tiesinį, eksponentinį ir logaritminį trendus

Prognozuodami Sausumos TP, išskyrus geležinkelio TP draudimo sutartis svertiniu pločio 3 slenkamųjų vidurkių metodu, svorius ėmėme lygius 0,1, 0,4 ir 0,5.

Taikant paprastojo slenkamųjų vidurkių ir svartinio slenkamųjų vidurkių metodus, antrąjį ketvirtį sutarčių skaičių atitinkamai gavome 90574 ir 91809. Prognozės tikslumą įvertinanti vidutinė kvadratinė paklaida mažesnė svertinių slenkamojo vidurkių metodo  $32909850,11 < 41809297,76$ . Tikrajai sutarčių reikšmei artimesnė prognozė - svertinių slenkamojo vidurkių metodo.


Prognozę atlikdami paprastojo eksponentinio glodinimo metodu, glodinimo koeficientą  $\alpha$  parenkame lygų 0,9.

Norėdami pritaikyti autoregresinį modelį, pastebėjome, kad reikšmingiausia prognozuojamos reikšmės laiko momentu  $t$  autokoreliacinė priklausomybė yra nuo reikšmių, gautų laiko momentais  $t-1$  ir  $t-2$ . Taigi apskaičiavę nežinomus koeficientus, gavome tokią autoregresinės prognozės lygtį:

$$\hat{y}_t = -1149,18 + 1,200093 \cdot y_{t-1} - 0,153586 \cdot y_{t-2}.$$

8 priede pateikti liekanų autokoreliacijos ir dalinės autokoreliacijos funkcijų grafikai ir tikrinamo Box'o-Ljung'o kriterijaus rezultatai. Sudarytą modelį galime laikyti priimtinu.

Palyginimui grafiškai pavaizduojame paprastojo slenkamųjų vidurkių metodo, svartinio slenkamųjų vidurkių metodo, paprastojo eksponentinio glodinimo metodo ir sudaryto autoregresinio modelio prognozių kreives (2.3.3.2 paveikslas).



2.3.3.2 pav. Prognozavimo rezultatų palyginimas duomenų aproksimacijai

Paklaidas ir prognozių tikslumus palyginsime žemiau pateiktoje lentelėje (2.3.3.1 lentelė).

2.3.3.1 lentelė

**Sausumos TP, išskyrus geležinkelio TP, draudimo sutarčių prognozavimo rezultatai**

| Prognozavimo metodas                       | Prognozuojamas sutarčių skaičius | Sudarytų sutarčių sk. | Absoliutinė ir santykinė paklaidos | Vidutinė kvadratinė paklaida |
|--|----------------------------------|-----------------------|------------------------------------|------------------------------|
| Tiesinis trendas                           | 79698                            | 99505                 | 19807<br>(19,91%)                  | $5,72 \cdot 10^7$            |
| Eksponentinis trendas                      | 80248                            |                       | 19257<br>(19,35%)                  | $4,89 \cdot 10^7$            |
| Logaritminis trendas                       | 70139                            |                       | 29366<br>(29,51%)                  | $9,60 \cdot 10^7$            |
| Paprastasis slenkamųjų vidurkių metodas    | 90574                            |                       | 8931<br>(8,98%)                    | $4,18 \cdot 10^7$            |
| Svertinis slenkamųjų vidurkių metodas      | 91809                            |                       | 7696<br>(7,73%)                    | $3,29 \cdot 10^7$            |
| Paprastojo eksponentinio glodinimo metodas | 941156                           |                       | 5389<br>(5,42%)                    | $3,69 \cdot 10^7$            |
| Autoregresinis modelis                     | 98398                            |                       | 1107<br>(1,11%)                    | $1,45 \cdot 10^7$            |

## 2.3.4 TURTO DRAUDIMO SUTARČIŲ SKAIČIAUS PROGNOZAVIMAS

Turto draudimo sutartis prognozuosime taip pat paprastuoju slenkamųjų vidurkių metodu, svertiniu slenkamųjų vidurkių metodu, paprastojo eksponentinio glodinimo metodu; taikysime autoregresinį modelį; duomenis aproksimuosime tiesiniu, logaritminiu ir eksponentiniu trendais.

Apskaičiavus determinacijos koeficientą paaiškėja, kad tiesinė kreivė ne itin gerai atitinka eksperimentinius duomenis, nes  $r^2=0,1972$  reikšmingai skiriasi nuo vieneto. Tačiau sudarytų sutarčių skaičius priklauso nuo laiko, nes koreliacijos koeficientas  $r$  lygus 0,4441. Gauta tiesinio trendo lygtis:

$$\text{Sutartys} = 325060 + 1457,0419 \cdot x,$$

atitinkamai eksponentinio ir logaritminių trendų lygtys:

$$\text{Sutartys} = 325420 \cdot e^{0,0041 \cdot x}, \quad \text{Sutartys} = 326290 + 19329,9288 \cdot \lg x.$$

Prognozuodami turto draudimo sutartis pločio lygaus 3 svertiniu slenkamųjų vidurkių metodu, svorius ėmėme lygius 0,1, 0,4 ir 0,5.

Palyginus paprastojo slenkamųjų vidurkių ir svertinio slenkamųjų vidurkių metodų prognozes, antrąjį ketvirtį sutarčių skaičių gausime 383893, o pagal svertinį – 387140. Prognozės tikslumą įvertinanti vidutinė kvadratinė paklaida mažesnė nei svertinių slenkamojo vidurkių metodo 578399577,4 < 627098032,71. 2005 m. 2-ąjį ketvirtį buvo sudaryta 403011 sutarčių, taigi tikrajai reikšmei artimesnė prognozė - svertinių slenkamojo vidurkių metodo.

Prognozę atlikdami paprastojo eksponentinio glodinimo metodu, glodinimo koeficientą  $\alpha$  parenkame lygų 0,8.


Norėdami pritaikyti autoregresinį modelį, pastebėjome, kad reikšmingiausia prognozuojamos reikšmės laiko momentu  $t$  autokoreliacinė priklausomybė yra nuo reikšmių, gautų laiko momentais  $t-1$  ir  $t-2$ . Taigi apskaičiavę nežinomus koeficientus, gavome tokią autoregresinės prognozės lygtį:

$$\hat{y}_t = 97589,67 + 0,948357 \cdot y_{t-1} - 0,226898 \cdot y_{t-2}.$$

8 priede pateikti liekanų autokoreliacijos ir dalinės autokoreliacijos funkcijų grafikai ir tikrinamo Box'o-Ljung'o kriterijaus rezultatai. Sudarytą modelį galime laikyti priimtiniu.

Palyginimui grafiškai pavaizduojame taikytų prognozavimo modelių prognozes 2005-ųjų metų antrajam ketvirčiui (2.3.4.1 paveikslas).

2.3.4.1 lentelėje pateikti visų taikytų prognozavimo metodų rezultatai.



2.3.4.1 pav. Turto draudimo sutarčių prognozių palyginimas

Turto draudimo sutarčių prognozių grafikai pateikti 11 priede.

**2.3.4.1 lentelė**

**Turto draudimo sutarčių prognozavimo rezultatai**

| Prognozavimo metodas                       | Prognozuojamas sutarčių skaičius | Sudarytų sutarčių sk. | Absoliutinė ir santykinė paklaidos | Vidutinė kvadratinė paklaida |
|--|----------------------------------|-----------------------|------------------------------------|------------------------------|
| Tiesinis trendas                           | 368771                           | 403011                | 34240<br>(8,50%)                   | $6,05 \cdot 10^8$            |
| Logaritminis trendas                       | 354843                           |                       | 48168<br>(11,95%)                  | $7,05 \cdot 10^8$            |
| Eksponentinis trendas                      | 368012                           |                       | 34999<br>(8,68%)                   | $6,01 \cdot 10^8$            |
| Paprastais slenkamųjų vidurkių metodas     | 383893                           |                       | 19118<br>(4,74%)                   | $6,27 \cdot 10^8$            |
| Svertinis slenkamųjų vidurkių metodas      | 387140                           |                       | 15871<br>(3,94%)                   | $5,78 \cdot 10^8$            |
| Paprastojo eksponentinio glodinimo metodas | 392764                           |                       | 10247<br>(2,54%)                   | $3,87 \cdot 10^8$            |
| Autoregresinis modelis                     | 386302                           |                       | 16709<br>(4,15%)                   | $3,43 \cdot 10^8$            |

## 2.4 NUOSTOLIŲ SUMOS PROGNOZAVIMAS

Atliksime visų Lietuvos draudimo kompanijų transporto priemonių savininkų ir valdytojų civilinės atsakomybės privalomojo draudimo, sausumos transporto priemonių, išskyrus geležinkelio transporto priemones, draudimo ir turto draudimo nuostolių prognozavimą. Prognozuosime anksčiau sutarčių prognozavimui taikytais metodais.

Nuostolių kreives aproksimavome tiesiniu, eksponentiniu trendais. Taip pat pastebėjome, kad duomenų išsibarstymas primena ir parabolinį trendą. Pabandėme ištirti sezoniškumo nuostoliams įtaką. Taikėme to paties pločio lygaus 3 paprastąjį slenkamųjų vidurkių metodą ir svertinį slenkamųjų vidurkių metodą su svertiniais koeficientais 0,1, 0,4 ir 0,5 prognozuojant transporto privalomosios civilinės atsakomybės draudimo nuostolius. Prognozuojant sausumos TP, išskyrus geležinkelio TP, draudimo ir turto draudimo nuostolius parinkti svoriai: 0,35, 0,3 ir 0,35. Taikant paprastojo eksponentinio glodinimo metodą, glodinimo konstantos kiekvienai draudimo rūšiai atitinkamai buvo parinktos lygios: 0,58, 0,46, 0,49. Norėdami nustatyti autoregresinio modelio eilę, kaip ir anksčiau, braižėme autokoreliacijos funkcijų diagramas (žiūrėti 7 priede). Visų trijų draudimo rūšių nuostoliams gavome, kad reikšmingiausia prognozuojamos reikšmės laiko momentu  $t$  autokoreliacinė priklausomybė yra nuo reikšmių, gautų laiko momentais  $t-1$  ir  $t-2$ . Priklausomai nuo to, kokie tų pačių

autokoreliacijos funkcijų dalinių autokoreliacijos funkcijų pavidalai (žiūrėti 7 priede), ieškojome tinkamų ARIMA modelių.


Kaip ir sutarčių skaičiaus prognozavime, transporto priemonių savininkų ir valdytojų civilinės atsakomybės privalomojo draudimo nuostolių sumas prognozuoti pabandėme naudodami trumpesnio laikotarpio duomenis, t.y. nuo 2002-ųjų metų II-ojo ketvirčio iki 2005-ųjų metų II-ojo ketvirčio. Prognozavimo rezultatai lentelės pavidalu pateikti 12 priede. Palyginimui pateiksime tų metodų skirtumų tarp prognozių ir turimo nuostolių skaičiaus rezultatų lentelę, kuriems gautos prognozės ženkliai skyrėsi. *Absoliutinė ir santykinė paklaidos\_1* – tai paklaidos, gautos naudojant ilgesnio laikotarpio duomenis, *Absoliutinė ir santykinė paklaidos\_2* – trumpesnio.

2.4.1 lentelė

### Skirtumų tarp turimų ir prognozuotų nuostolių lentelė

| Prognozavimo metodas                        | Absoliutinė ir santykinė paklaidos_1 | Absoliutinė ir santykinė paklaidos_2 |
|---|--------------------------------------|--------------------------------------|
| Tiesinis trendas                            | 16,20%                               | 4,09%                                |
| Tiesinis trendas su sezoniniais svyravimais | 16,25%                               | 7,08%                                |
| EkspONENTINIS trendas                       | 10,96%                               | 8,51%                                |
| Parabolinis trendas                         | 14,77%                               | 6,23%                                |
| Autoregresinis modelis                      | 22,91%                               | 28,96%                               |

Palyginimui grafiškai pavaizduojame taikytų prognozavimo modelių nuostolių prognozes 2005-ųjų metų antrajam ketvirčiui (2.4.1 paveikslas).



2.4.1 pav. Nuostolių prognozių palyginimas

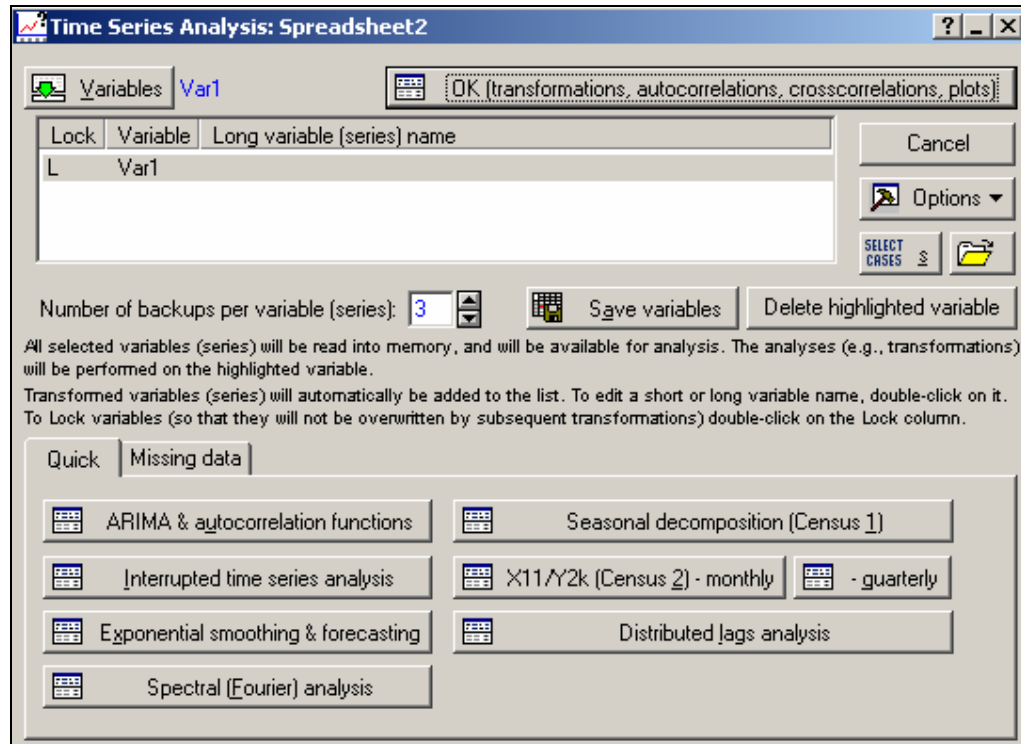


Trijų nagrinėtų draudimo rūšių nuostolių prognozavimo rezultatų lentelė pateikta 12 priede: procentai, parodantys, kiek tiksliai prognozė atitinka esamas 2005-ųjų metų antro ketvirčio nuostolių sumas, vidutinių kvadratinių paklaidų reikšmės. Iš šios lentelės pagal paklaidų reikšmes galime nustatyti, kuriuos metodus taikydami turėtume gauti tiksliausias 2005-aisiais metais draudimo kompanijų patirtų nuostolių sumas.

Visų taikytų prognozavimo modelių grafikai pateikti 9, 10 ir 11 prieduose.


### 3. PROGRAMINĖ REALIZACIJA IR INSTRUKCIJA VARTOTOJUI

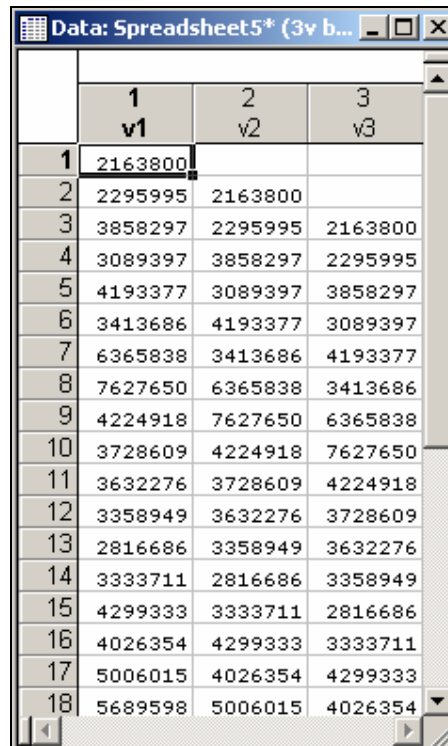
Trumpai apžvelgsime pasirinkto statistinio paketo STATISTICA galimybes, kuriomis pasinaudojome šiame darbe. Vienas pagrindinių STATISTICA paketo naudojamų analizės langų duomenims prognozuoti yra *Time Series Analysis* langas:



3.1 pav. Modulio Time Series Analysis langas

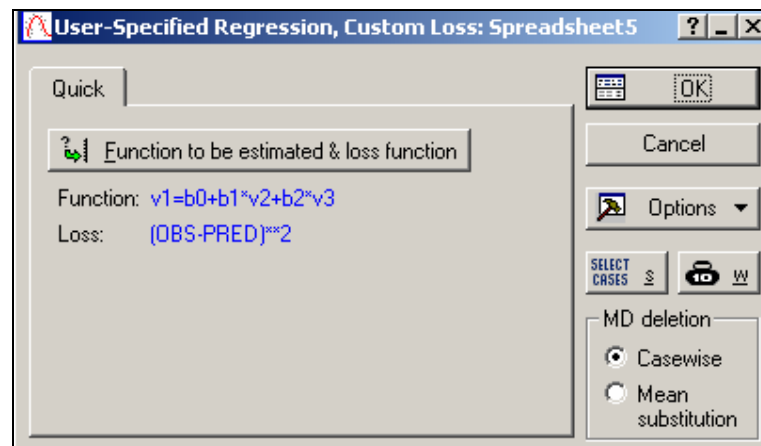
Šiame pagrindiniame laiko eilučių analizės lange parinkus duomenų kintamąjį ir nuspaudus atitinkamus mygtukus, galima atlikti prognozavimą pasirinktu ARIMA modeliu (apatinėje lango dalyje viršuje kairėje pusėje mygtukas „ARIMA & autocorrelation functions“), prognozuoti paprastojo eksponentinio glodinimo metodu („Exponential smoothing & forecasting“ mygtukas), rasti sezoniškumo indeksus („Seasonal decomposition“ mygtukas). Pačiame lango viršuje esančiu mygtuku iškviečiamas langas, kuriame atlikus tam tikrus nurodymus, diferencijuojame duomenis, braižome duomenų autokoreliacijų ir dalinių autokoreliacijų diagramas. Nustačius autoregresinio modelio eilę, kuris priklauso nuo autokoreliacijos funkcijos pavidalo, autoregresinės lygties koeficientus rasdavome naudodami modulį *Nonlinear Estimations*. Pirmiausiai į STATISTICA lentelę surašome duomenis, taip kaip parodyta 3.2 paveiksle (būtent antros eilės autoregresiniam modeliui, kai autokoreliacijos funkcijos reikšmės didžiausios esant pirmam ir antram postūmiui). Tuomet užrašome regresijos lygtį (3.3 pav.). Mūsų atveju visoms nagrinėtoms draudimo rūšių nuostoliams ir sutarčių skaičiui

prognozuoti tiko ta pati regresijos lygtis. Paspaudus OK, gautame rezultatų lange, norėdami rasti nežinomų koeficientų įverčius, nuspaudžiame mygtuką  Summary: Parameter estimates



|    | 1<br>v1 | 2<br>v2 | 3<br>v3 |
|----|---------|---------|---------|
| 1  | 2163800 |         |         |
| 2  | 2295995 | 2163800 |         |
| 3  | 3858297 | 2295995 | 2163800 |
| 4  | 3089397 | 3858297 | 2295995 |
| 5  | 4193377 | 3089397 | 3858297 |
| 6  | 3413686 | 4193377 | 3089397 |
| 7  | 6365838 | 3413686 | 4193377 |
| 8  | 7627650 | 6365838 | 3413686 |
| 9  | 4224918 | 7627650 | 6365838 |
| 10 | 3728609 | 4224918 | 7627650 |
| 11 | 3632276 | 3728609 | 4224918 |
| 12 | 3358949 | 3632276 | 3728609 |
| 13 | 2816686 | 3358949 | 3632276 |
| 14 | 3333711 | 2816686 | 3358949 |
| 15 | 4299333 | 3333711 | 2816686 |
| 16 | 4026354 | 4299333 | 3333711 |
| 17 | 5006015 | 4026354 | 4299333 |
| 18 | 5689598 | 5006015 | 4026354 |

3.2 pav. Modulo *Nonlinear Estimations* duomenų langas



Quick

Function to be estimated & loss function

Function:  $v1=b0+b1*v2+b2*v3$

Loss:  $(OBS-PRED)**2$

OK

Cancel

Options

SELECT CASES

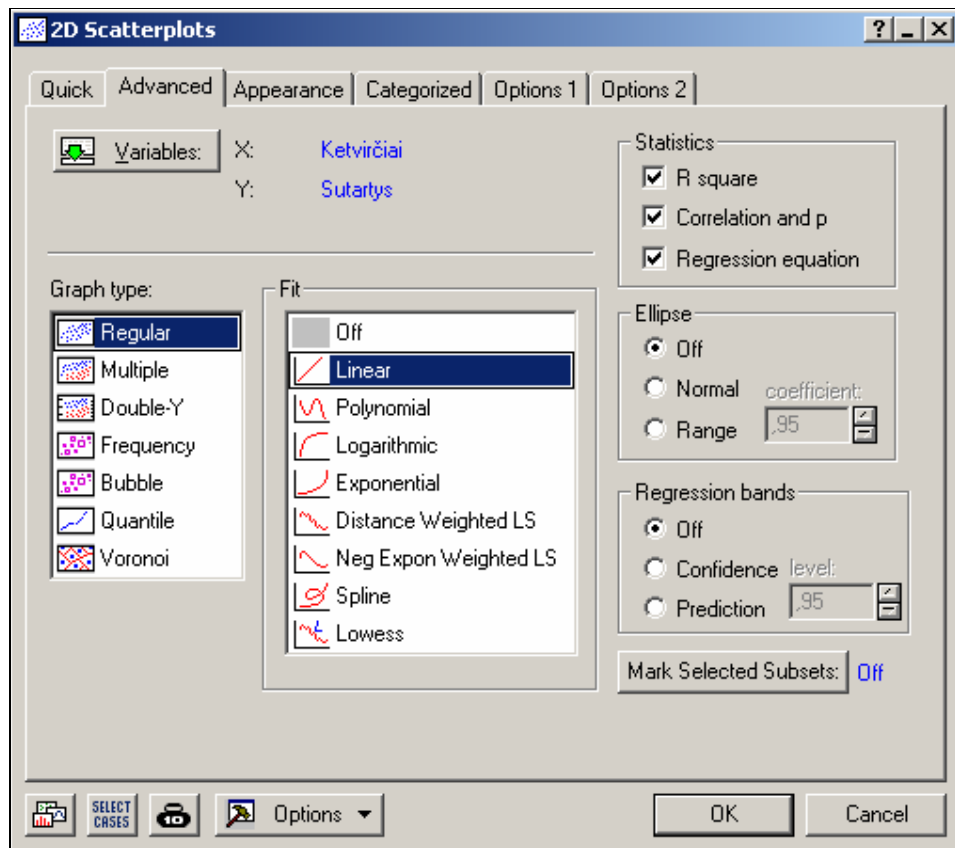
MD deletion

Casewise

Mean substitution

3.3 pav. Modulo *Nonlinear Estimations* regresinės lygties koeficientų radimo langas

Trendo kreivių koeficientams ir tikslumo įverčiams nustatyti naudojome iš pagrindinio meniu pasirinktą *Graphs, Stats 2D Graphs..., Scatterplots..* modulius. Grafiko parametrų, taikomo trendo parinkimo forma:



3.4 pav. Modulio *2D Scatterplots* regresinės kreivės nustatyti parametrų parinkimo langas

## 4. DISKUSIJOS

Nagrinėjant įvairių ne gyvybės draudimo rodiklių kitimo tendencijas, pastebime, kad ne gyvybės draudimo rinka lyg ir nusistovi, tačiau paskutiniai metai parodo, kad rinka vis dar nėra stabili. Ilgą laiką gyvavusių ne gyvybės draudimo kompanijų skaičius sumažėjo. Panašu, kad pasirašytos įmokos iki šiol itin nekinta, o patiriami apsidraudusiųjų nuostoliai išaugo net 28%, nors prieš metus žalų suma buvo sumažėjusi. Sudarytų draudimo sutarčių skaičius sumažėjo net 15%.

Dėl duomenų trūkumo nepavyko paanalizuoti ne gyvybės draudimo kompanijų mokumo situacijos 2005-aisiais metais. Dviems iš septynių ne gyvybės draudimo kompanijų 2004-aisiais metais būtinoji mokumo atsarga viršija turimąją mokumo atsargą. Tai reiškia, kad jeigu padidėtų nuostolių skaičius, draudimo kompanijoms iškiltų reali bankroto grėsmė. Kadangi, jau kaip minėjome, 2005-aisiais įmokos padidėjo, tačiau nedaug, o patirtų žalų sumos išaugo ženkliai, tai galima spėti, kad padaugėtų draudimo kompanijų, kurioms būtinoji mokumo atsarga būtų didesnė negu turimoji mokumo atsarga.

Išanalizavus įmokų ir išmokų struktūrą paaiškėjo, kad nagrinėjamu laikotarpiu draudžiantis transporto privalomuoju civilinės atsakomybės draudimu, draudžiant sausumos transporto priemones, išskyrus geležinkelio transporto priemones ar draudžiant turtą, pasirašoma daugiausiai įmokų. Draudimo kompanijos apmoka didžiausius šių draudimo rūšių nuostolius. Dėl šios priežasties smulkiau nagrinėjant sudarytų minėtų draudimo grupių sutarčių skaičiaus ir nuostolių kitimą, sudaryti keli prognozavimo modeliai. Norint išsiaiškinti tiksliausius prognozavimo metodus, kuriuos taikant prognozės geriausiai atitiktų iš tikrųjų sudarytą sutarčių skaičių ir apmokėtas žalias, skaičiavome vidutines kvadratinės paklaidas. Taip pat gautas prognozes lyginome su tikraisiais duomenimis.

Apibendrinant galime pasakyti, kad ne visuomet taikant pačius tiksliausius modelius gaudavome labiausiai tikrovę atitinkančias prognozes. Vis dėl to prognozės, kurioms gavome didžiausias paklaidas, labiausiai skirdavosi nuo tikrųjų duomenų. Iš duomenų grafikų matyti, kad viena iš pagrindinių sutarčių ir nuostolių laiko eilučių komponentių yra trendas. Tačiau taikant duomenų aproksimavimą tiesiniais ir netiesiniais trendais nepavyko gauti labai tikslų prognozių. Buvo tirta ir sezoniškumo įtaka turimiems duomenims, tačiau rezultatas nepagerėdavo lyginant su tiesinio trendo aproksimacija. Kadangi duomenų išsidėstymą įtakoja ir atsitiktinumų komponentė, buvo taikomi ir kiti metodai. Viena iš taikymo sąlygų buvo duomenų stacionarumas. Vizualiai duomenis generuojantys procesai neatrodo stacionarūs. Taip pat apie duomenų (net ir apie diferencijuotų duomenų) nestacionarumą sprendžiame ir iš duomenų autokoreliacijos funkcijų grafikų. 7 priede pateiktas TPCAD nuostolių autokoreliacijos funkcijos reikšmių diagrama ir tikrinamo Box'o-Ljung'o kriterijaus rezultatų lentelė. Panašūs rezultatai, iš kurių buvo galima padaryti tą pačią išvadą, buvo gauti visoms nagrinėjamų duomenų imtims. Tačiau padarėme prielaidą, jog stacionarumo sąlyga yra tenkinama.

Paaiškėjo, jog taikant šiuos: paprastojo eksponentinio glodinimo, paprastąjį slenkamųjų vidurkių, svertinį slenkamųjų vidurkių, antros eilės autoregresinio prognozavimo ir ARIMA(2,1,0) modelius, galima gauti pakankamai tikslius rezultatus.

Transporto priemonių savininkų ir valdytojų civilinės atsakomybės privalomajam draudimui pabandėme prognozuoti naudojant ir mažiau duomenų, kadangi tiek žalų, tiek sutarčių skaičius smarkiai išaugo nuo 2002-ųjų metų antro ketvirčio įsigaliojus reikalavimui apdrausti transporto priemonės. Tuomet nuostolių ir sutarčių skaičiaus prognozės gautos duomenis aproksimuojant trendais yra žymiai tikslesnės. Nagrinėjant sezoniško įtaką transporto priemonių savininkų ir valdytojų civilinės atsakomybės privalomojo draudimo sutartims ir nuostoliams 2002-2005-aisiais metais rezultatai gavome tikslesnį lyginant su prognozavimo rezultatais gautais, naudojant ilgesnio laikotarpio duomenis. Autoregresinį modelį geriau taikyti, kai turime daugiau duomenų, nes priešingu atveju prognozė dar labiau skiriasi nuo turimų duomenų.

TPCAD sutarčių skaičių prognozuojant pagal trumpesnio laikotarpio sutarčių duomenis, mažiausios kvadratinės paklaidos gautos jau nebe antros eilės autoregresiniam modeliui, o taikant tiesinio trendo su sezoniniais svyravimais metodą. Šio metodo vidutinė kvadratinė paklaida už kitų metodų paklaidas mažesnė iki kelių kartų. Prognozės nuo tikro 2005-ųjų metų antro ketvirčio sutarčių skaičiaus mažiausiai skiriasi, kuomet sutarčių skaičius aproksimuojamas logaritminiu trendu, tačiau atsižvelgiant į vidutinės kvadratinės paklaidos didumą, šis metodas neturėtų būti tikslus. Mūsų tikslas yra, kad prognozė kuo mažiau skirtųsi nuo turimų duomenų, o naudojamo metodo vidutinė kvadratinė paklaida būtų kuo mažesnė. Šiuo atžvilgiu būtų geriausia eksponentinio trendo aproksimacija. To paties 2002-2005-ųjų laikotarpio duomenis naudojant nuostolių prognozavimui taip pat tiksliausias tiesinio trendo su sezoniniais svyravimais metodas, o slenkamųjų vidurkių prognozė artimiausia tikrajai nuostolių sumai.

Lyginat to paties laikotarpio trijų pasirinktų pagrindinių draudimo rūšių prognozes pastebime, kad prognozuojant sutarčių skaičius tiksliausi tie patys autoregresiniai modeliai ir paprastojo eksponentinio glodinimo metodai. Tą patį galima būtų pasakyti ir apie nuostolių prognozavimą, išskyrus tai, jog prognozuojant TPCAD nuostolius autoregresiniu modeliu gauta prognozė mažiausiai tiksli. Beje, visų trijų draudimo rūšių sutarčių ir nuostolių prognozuojamų reikšmių laiko momentu  $t$  gauta reikšmingiausia priklausomybė nuo reikšmių, gautų laiko momentais  $t-1$  ir  $t-2$ .

## IŠVADOS

- Analizuojant draudimo rinkos rodiklius ryškėja tendencija, kad draudimo rinka tampa stabilesnė.
- Atlikus 7 ne gyvybės draudimo kompanijų mokumo analizę, gavome, kad dviems iš jų gresia bankrotas.
- Atliktas sutarčių skaičiaus ir nuostolių prognozavimas, naudojant statistinius duomenis nuo 1998-ųjų metų pirmo ketvirčio iki 2005-ųjų metų antro ketvirčio ir gautas prognozes palyginus su 2005-ųjų metų antro ketvirčio duomenimis nustatyta, kad prognozuojami duomenys artimi tikriesiems duomenims.
- Sausumos transporto priemonių, išskyrus geležinkelio transporto priemones, draudimui tiksliausias antros eilės autoregresinis sutarčių skaičiaus prognozavimo modelis. Pronozuojamoms nuostolių sumoms mažiausias kvadratinės paklaidas gavome taikydami parabolinio trendo aproksimaciją.
- Turto draudimui iš nagrinėtų metodų tiksliausias yra paprastasis slenkamųjų vidurkių metodas. Prognozuojant turto draudimo nuostolių sumą tiksliausias antros eilės autoregresinis modelis.
- TPCAD prognozavime naudojant trumpesnį laikotarpio duomenis gauti regresinių kreivių prognozavimo rezultatai artimesni žinomam 2005-ųjų metų antro ketvirčio sutarčių skaičiui ir nuostoliams.
- Transporto priemonių savininkų ir valdytojų civilinės atsakomybės draudimo sutartims prognozuoti tiksliausias turėtų būti autoregresinis modelis, tikrajam sutarčių skaičiui artimiausia prognozė gauta taikant paprastojo eksponentinio glodinimo metodą.

## **REKOMENDACIJOS**


Tolimesniems tyrimams būtų įdomi panaši ne gyvybės draudimo analizė, atliekant atskirų ne gyvybės draudimo kompanijų įmokas lemiančių charakteristikų prognozavimą.




## LITERATŪROS SĄRAŠAS

1. V.Sakalauskas. Duomenų analizė su “Statistica“, Vilnius: Margi raštai, 2003, 235p.
2. Вентцель Е. С. Теория вероятностей, Москва, “Государственное издательство физико-математической литературы”, 1962, p. 564.
3. J.Čepinskis, D.Raškinis ir kiti. Draudimas, Kaunas, Pasaulio lietuvių kultūros, mokslo ir švietimo centras, 1999. - 460 p.
4. <http://www.google.lt/search?hl=lt&q=stacionarumas&meta=>
5. [www.dpk.lt](http://www.dpk.lt)


## 1 PRIEDAS. DRAUDIMO VEIKLA UŽSIIMANČIŲ KOMPANIJŲ SKAIČIAUS Palyginimas




1.1 pav. Ne gyvybės ir gyvybės draudimo kompanijų skaičiaus palyginimas



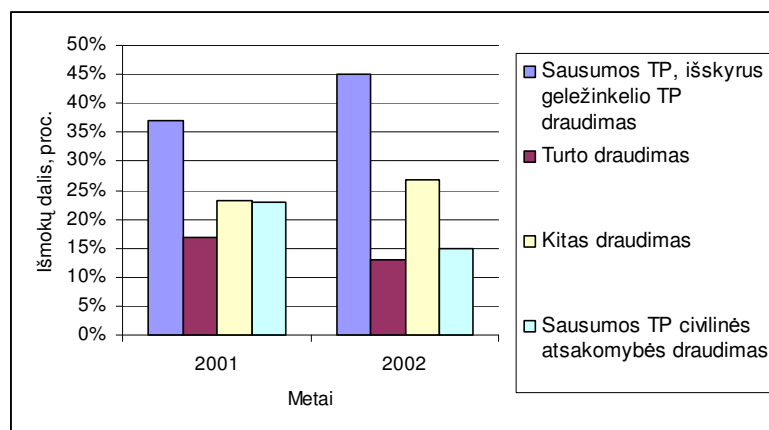
1.2 pav. Ne gyvybės draudimo įmokų struktūros kitimas 2003-2005 metais



1.3 pav. Ne gyvybės draudimo įmokų struktūros kitimas 1998-2002 metais



1.4 pav. Ne gyvybės draudimo išmokų struktūros kitimas 2003-2004 metais



1.5 pav. Ne gyvybės draudimo išmokų struktūros kitimas 2001-2002 metais

## 2 PRIEDAS. DUOMENYS BMA IR TMA SKAIČIUOTI

### 2.1 lentelė

#### Duomenys skaičiuoti BMA

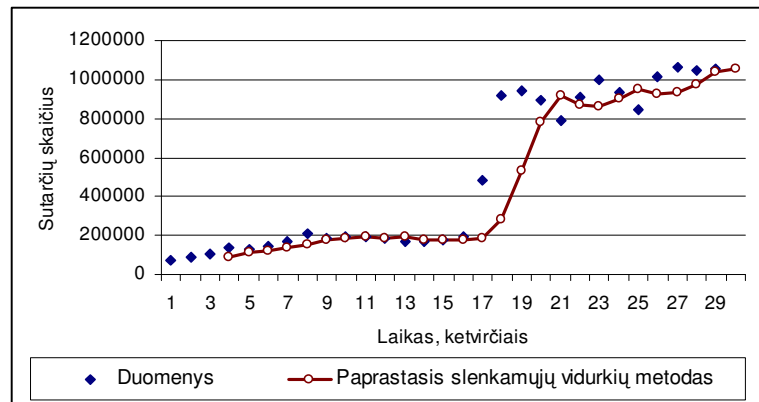
| Įmokų bazė | Koreguota įmokų bazė | 50 mln.litų atitinka eurų: | 35 mln.litų atitinka eurų: | Išmokų bazė | Koreguota išmokų bazė | Perdraudikų dalis |
|------------|----------------------|----------------------------|----------------------------|-------------|-----------------------|-------------------|
| 208698729  | 208360500            | 172640000                  | 120848000                  | 259836172   | 86612057              | 21192172          |
| 54623958   | 54448381             |                            |                            | 35512446    | 11837482              | 1328670           |
| 54623958   | 54517868             |                            |                            | 49143035    | 16381012              | 10742632          |
| 95601777   | 95466822             |                            |                            | 90918293    | 30306098              | 38651820          |
| 16578953   | 16578953             |                            |                            | 9947820     | 3315940               | 2108049           |
| 48581025   | 48581025             |                            |                            | 24112121    | 8037374               | 15754182          |
| 26050237   | 26050237             |                            |                            | 14717928    | 4905976               | 992603            |

### 2.2 lentelė


#### Duomenys skaičiuoti TMA

|                                       |          |         |          |          |         |         |         |
|---------------------------------------|----------|---------|----------|----------|---------|---------|---------|
| Apmokėtas įstatinis kapitalas         | 80562000 | 9000000 | 8100000  | 15109000 | 3000000 | 9605909 | 4761000 |
| Akcijų priedai                        | 3236754  | 0       | 23403199 | 23639171 | 0       | 50000   | 0       |
| Perkainojimo rezervas                 | 0        | 0       | 0        | 262920   | 0       | 801708  | 122831  |
| Kiti rezervai                         | 0        | 0       | 0        | 862000   | 1004912 | 0       | 0       |
| Nepaskirstytas pelnas (nuostolis)     | 21564302 | -840948 | -2212355 | -1810182 | 0       | 0       | 0       |
| Kaup.div.privelig. Akcijos            | 0        | 0       | 0        | 0        | 0       | 0       | 0       |
| Subordinuotos paskolos                | 0        | 0       | 0        | 0        | 1130787 | 0       | 0       |
| Kiti išleisti vertybiniai popieriai   | 0        | 0       | 0        | 0        | 0       | 0       | 0       |
| Nematerialusis turtas                 | 797723   | 223122  | 325293   | 2009096  | 73852   | 276632  | 194232  |
| Ateinančių laikotarpių sąnaudos       | 25295340 | 129527  | 3413023  | 11026393 | 782228  | 3072906 | 2250085 |
| Nuosavos akcijos                      | 0        | 0       | 0        | 0        | 0       | 0       | 0       |
| Uždelsti debitoriniai įsipareigojimai | 0        | 0       | 0        | 0        | 0       | 0       | 0       |
| Kitas riboto patikimumo turtas        | 0        | 0       | 0        | 0        | 0       | 0       | 0       |
| Turto vertės skirtumai                | 0        | 0       | 0        | 0        | 0       | 0       | 0       |
| Užbalansiniai įsipareigojimai         | 0        | 0       | 0        | 0        | 0       | 0       | 0       |


### 3 PRIEDAS. TPCAD SUTARČIŲ SKAIČIAUS PROGNOZAVIMO MODELIAI



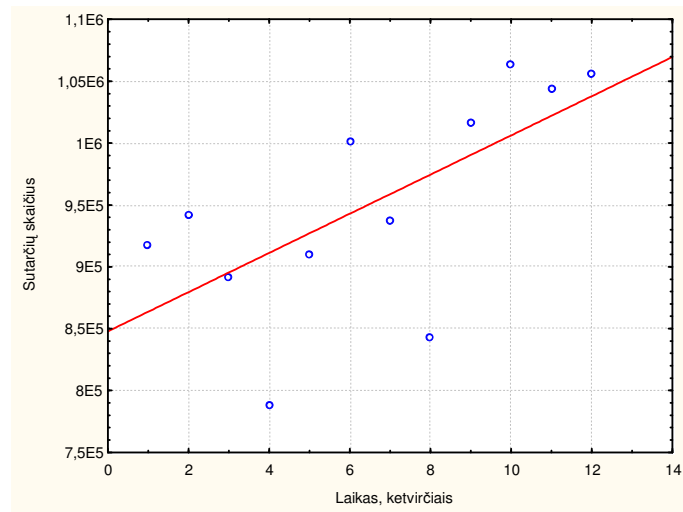
3.1 pav. Paprastojo slenkamųjų vidurkių metodo prognozės nuo 1998 metų




3.2 pav. Svertinio slenkamųjų vidurkių metodo prognozės nuo 1998 metų




3.3 pav. Tiesinio trendo su sezoniniais svyravimais prognozės nuo 1998 metų




3.4 pav. Tiesinio trendo prognozės nuo 2002-ųjų metų




3.5 pav. Tiesinio trendo su sezoniniais svyravimais prognozės nuo 2002-ųjų metų




3.6 pav. Logaritminio trendo prognozės nuo 2002-ųjų metų




3.7 pav. Eksponentinio trendo prognozės nuo 2002-ųjų metų




3.8 pav. Parabolinio trendo prognozės nuo 2002-ųjų metų



3.9 pav. Paprastojo eksponentinio glodinimo metodo prognozės nuo 2002-ųjų metų




3.10 pav. Autoregresinio modelio prognozės nuo 2002-ųjų metų




3.11 pav. ARIMA(2,1,0) modelio prognozės

#### 4 PRIEDAS. SAUSUMOS TP, IŠSKYRUS GELEŽINKELIO TP, DRAUDIMO SUTARČIŲ SKAIČIAUS PROGNOZAVIMO MODELIAI




4.1 pav. Tiesinio trendo prognozės







4.2 pav. Logaritminio trendo prognozės




4.3 pav. Eksponentinio trendo prognozės




4.4 pav. Paprastojo slenkamųjų vidurkių metodo prognozės




4.5 pav. Svertinio slenkamųjų vidurkių metodo prognozės



4.6 pav. Paprastojo eksponentinio glodinimo metodo prognozės




4.7 pav. Autoregresinio modelio prognozės




4.8 pav. ARIMA(2,1,0) modelio prognozės


## 5 PRIEDAS. TURTO DRAUDIMO SUTARČIŲ SKAIČIAUS PROGNOZAVIMO MODELIAI




5.1 pav. Tiesinio trendo prognozės




5.2 pav. Eksponentinio trendo prognozės






5.3 pav. Logaritminio trendo prognozės




5.4 pav. Paprastojo eksponentinio glodinimo metodo prognozės




5.5 pav. Paprastojo slenkamųjų vidurkių metodo prognozės



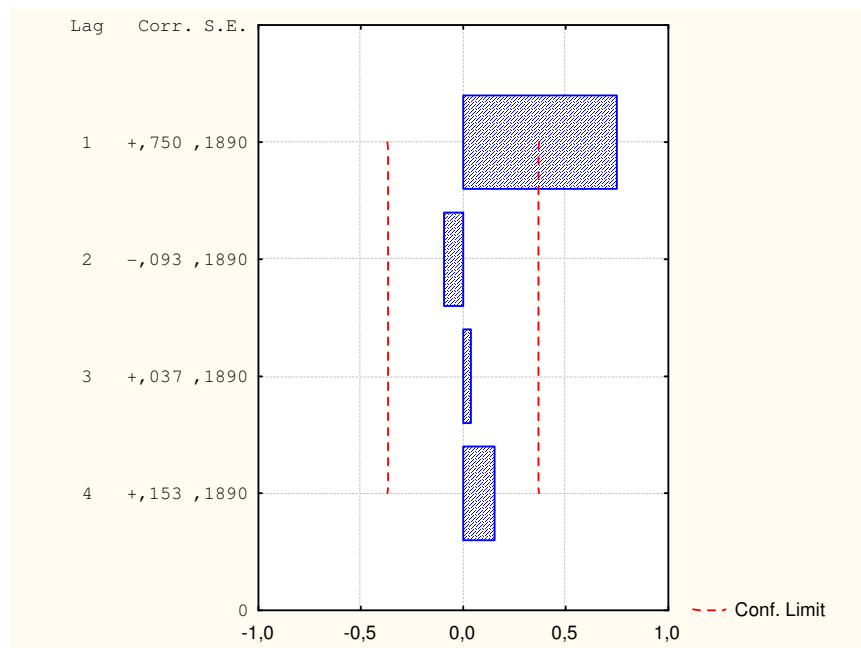
## 6 PRIEDAS. SUTARČIŲ SKAIČIAUS AUTOKORELIACIJOS IR DALINĖS AUTOKORELIACIJOS DIAGRAMOS




6.1 pav. TPCAD sutarčių skaičiaus dalinės autokoreliacijos funkcija




6.2 pav. Sausumos TP, išskyrus geležinkelio TP, draudimo sutarčių skaičiaus autokoreliacijos funkcija



6.3 pav. Sausumos TP, išskyrus geležinkelio TP, draudimo sutarčių skaičiaus dalinės autokoreliacijos funkcija




6.4 pav. Turto draudimo sutarčių skaičiaus autokoreliacijos funkcija



6.5 pav. Turto draudimo sutarčių skaičiaus dalinės autokoreliacijos funkcija

## 7 PRIEDAS. NUOSTOLIŲ AUTOKORELIACIJOS IR DALINĖS AUTOKORELIACIJOS DIAGRAMOS




7.1 pav. TPCAD nuostolių autokoreliacijos funkcija

7.1 lentelė


TPCAD nuostolių tikrinamo Box'o-Ljung'o kriterijaus rezultatų lentelė

|    | Box & Ljung | p        |    | Box & Ljung | p        |
|----|-------------|----------|----|-------------|----------|
| 1  | 18,0796     | 0,000021 | 14 | 74,1792     | 0,000000 |
| 2  | 33,6467     | 0,000000 | 15 | 78,7895     | 0,000000 |
| 3  | 41,9388     | 0,000000 | 16 | 85,3492     | 0,000000 |
| 4  | 50,0440     | 0,000000 | 17 | 91,5539     | 0,000000 |
| 5  | 53,7380     | 0,000000 | 18 | 100,8269    | 0,000000 |
| 6  | 57,9302     | 0,000000 | 19 | 106,9989    | 0,000000 |
| 7  | 59,5637     | 0,000000 | 20 | 114,1254    | 0,000000 |
| 8  | 61,0504     | 0,000000 | 21 | 118,2503    | 0,000000 |
| 9  | 61,2634     | 0,000000 | 22 | 124,6656    | 0,000000 |
| 10 | 61,3005     | 0,000000 | 23 | 128,6262    | 0,000000 |
| 11 | 62,7830     | 0,000000 | 24 | 134,9502    | 0,000000 |
| 12 | 65,7269     | 0,000000 | 25 | 139,4731    | 0,000000 |
| 13 | 69,2236     | 0,000000 |    |             |          |







7.2 pav. TPCAD nuostolių autokoreliacijos funkcija




7.3 pav. TPCAD nuostolių dalinės autokoreliacijos funkcija




7.4 pav. Sausumos TP, išskyrus geležinkelio TP, draudimo nuostolių autokoreliacijos funkcija



7.5 pav. Sausumos TP, išskyrus geležinkelio TP, draudimo nuostolių dalinės autokoreliacijos funkcija




7.6 pav. Turto draudimo nuostolių autokoreliacijos funkcija




7.7 pav. Turto draudimo nuostolių dalinės autokoreliacijos funkcija

## 8 PRIEDAS. BALTO TRIUKŠMO HIPOTEZĖS TIKRINIMAS SUDARYTŲ AUTOREGRESINIŲ MODELIŲ LIEKANOMS



8.1 pav. TPCAD sutarčių skaičiaus autoregresinio modelio liekanų autokoreliacijos funkcija




8.2 pav. TPCAD sutarčių skaičiaus autoregresinio modelio liekanų dalinės autokoreliacijos funkcija


8.1 lentelė

Baltojo triukšmo hipotezės tikrinimas liekanoms

|          | Box & Ljung | p        |           | Box & Ljung | p        |
|----------|-------------|----------|-----------|-------------|----------|
| <b>1</b> | 0,114605    | 0,734963 | <b>9</b>  | 7,341162    | 0,601650 |
| <b>2</b> | 0,608617    | 0,737635 | <b>10</b> | 7,471093    | 0,680341 |
| <b>3</b> | 0,751572    | 0,861011 | <b>11</b> | 7,567203    | 0,751453 |
| <b>4</b> | 2,011685    | 0,733610 | <b>12</b> | 7,841158    | 0,797397 |
| <b>5</b> | 3,799420    | 0,578648 | <b>13</b> | 7,865877    | 0,852202 |
| <b>6</b> | 4,041624    | 0,671044 | <b>14</b> | 8,057232    | 0,886297 |
| <b>7</b> | 4,906655    | 0,671353 | <b>15</b> | 8,291382    | 0,911543 |
| <b>8</b> | 6,694508    | 0,569931 |           |             |          |



8.3 pav. Sausumos TP, išskyrus geležinkelio TP, draudimo sutarčių skaičiaus autoregresinio modelio liekanų autokoreliacijos funkcija




8.4 pav. Sausumos TP, išskyrus geležinkelio TP, draudimo sutarčių skaičiaus autoregresinio modelio liekanų dalinės autokoreliacijos funkcija


8.2 lentelė

#### Baltojo triukšmo hipotezės tikrinimas liekanoms

|          | Box & Ljung | p        |           | Box & Ljung | p        |
|----------|-------------|----------|-----------|-------------|----------|
| <b>1</b> | 0,004872    | 0,944353 | <b>9</b>  | 7,328766    | 0,602935 |
| <b>2</b> | 0,005231    | 0,997388 | <b>10</b> | 7,854625    | 0,643033 |
| <b>3</b> | 1,224328    | 0,747177 | <b>11</b> | 7,906661    | 0,721628 |
| <b>4</b> | 4,868268    | 0,301106 | <b>12</b> | 8,005783    | 0,784659 |
| <b>5</b> | 4,893174    | 0,429074 | <b>13</b> | 8,030875    | 0,841559 |
| <b>6</b> | 5,492994    | 0,482319 | <b>14</b> | 8,624738    | 0,854286 |
| <b>7</b> | 5,999864    | 0,539776 | <b>15</b> | 9,279807    | 0,862409 |
| <b>8</b> | 6,049991    | 0,641633 |           |             |          |



8.5 pav. TPCAD nuostolių autoregresinio modelio liekanų autokoreliacijos funkcija




8.6 pav. TPCAD nuostolių autoregresinio modelio liekanų dalinės autokoreliacijos funkcija


8.3 lentelė

## Baltojo triukšmo hipotezės tikrinimas liekanoms

|          | Box & Ljung | p        |           | Box & Ljung | p        |
|----------|-------------|----------|-----------|-------------|----------|
| <b>1</b> | 2,38697     | 0,122360 | <b>9</b>  | 7,65005     | 0,569768 |
| <b>2</b> | 2,56739     | 0,277026 | <b>10</b> | 7,65103     | 0,662877 |
| <b>3</b> | 4,73429     | 0,192343 | <b>11</b> | 7,65181     | 0,744098 |
| <b>4</b> | 5,51727     | 0,238242 | <b>12</b> | 7,77537     | 0,802409 |
| <b>5</b> | 7,00162     | 0,220552 | <b>13</b> | 7,77806     | 0,857728 |
| <b>6</b> | 7,22886     | 0,300233 | <b>14</b> | 7,91341     | 0,893762 |
| <b>7</b> | 7,38865     | 0,389592 | <b>15</b> | 10,81347    | 0,765676 |
| <b>8</b> | 7,62267     | 0,471189 |           |             |          |



8.7 pav. Sausumos TP, išskyrus geležinkelio TP, draudimo nuostolių autoregresinio modelio liekanų autokoreliacijos funkcija




8.8 pav. Sausumos TP, išskyrus geležinkelio TP, draudimo nuostolių autoregresinio modelio liekanų dalinės autokoreliacijos funkcija


8.4 lentelė

#### Baltojo triukšmo hipotezės tikrinimas liekanoms

|          | Box & Ljung | p        |           | Box & Ljung | p        |
|----------|-------------|----------|-----------|-------------|----------|
| <b>1</b> | 0,70026     | 0,402701 | <b>9</b>  | 5,53723     | 0,785178 |
| <b>2</b> | 2,75349     | 0,252414 | <b>10</b> | 7,44556     | 0,682811 |
| <b>3</b> | 3,62556     | 0,304857 | <b>11</b> | 7,45482     | 0,761132 |
| <b>4</b> | 3,77950     | 0,436684 | <b>12</b> | 11,81230    | 0,460896 |
| <b>5</b> | 4,02942     | 0,545197 | <b>13</b> | 11,81554    | 0,542837 |
| <b>6</b> | 4,50064     | 0,609259 | <b>14</b> | 12,66073    | 0,553405 |
| <b>7</b> | 5,39195     | 0,612251 | <b>15</b> | 13,66232    | 0,551289 |
| <b>8</b> | 5,40924     | 0,713068 |           |             |          |



8.9 pav. Turto draudimo nuostolių autoregresinio modelio liekanų autokoreliacijos funkcija




8.10 pav. Turto draudimo nuostolių autoregresinio modelio liekanų dalinės autokoreliacijos funkcija


8.5 lentelė

#### Baltojo triukšmo hipotezės tikrinimas liekanoms

|          | Box & Ljung | p        |           | Box & Ljung | p        |
|----------|-------------|----------|-----------|-------------|----------|
| <b>1</b> | 0,000558    | 0,981162 | <b>9</b>  | 4,081846    | 0,905931 |
| <b>2</b> | 0,196699    | 0,906332 | <b>10</b> | 4,107677    | 0,942347 |
| <b>3</b> | 0,197726    | 0,977955 | <b>11</b> | 4,761305    | 0,942159 |
| <b>4</b> | 0,230495    | 0,993848 | <b>12</b> | 5,290655    | 0,947545 |
| <b>5</b> | 1,115003    | 0,952764 | <b>13</b> | 5,429353    | 0,964473 |
| <b>6</b> | 3,249252    | 0,776970 | <b>14</b> | 5,907490    | 0,968756 |
| <b>7</b> | 3,320636    | 0,853834 | <b>15</b> | 9,199803    | 0,866811 |
| <b>8</b> | 4,055409    | 0,852079 |           |             |          |



8.11 pav. TPCAD sutarčių skaičiaus autoregresinio modelio liekanų autokoreliacijos funkcija (prognozuojant pagal trumpesnio laikotarpio duomenis)




8.12 pav. TPCAD sutarčių skaičiaus autoregresinio modelio liekanų dalinės autokoreliacijos funkcija (prognozuojant pagal trumpesnio laikotarpio duomenis)

## 8.6 lentelė


### Baltojo triukšmo hipotezės tikrinimas liekanoms

|          | Box & Ljung | p        |
|----------|-------------|----------|
| <b>1</b> | 0,988717    | 0,320064 |
| <b>2</b> | 0,988962    | 0,609892 |
| <b>3</b> | 1,087562    | 0,780078 |
| <b>4</b> | 4,275814    | 0,369983 |
| <b>5</b> | 5,829103    | 0,323231 |





8.13 pav. TPCAD nuostolių autoregresinio modelio liekanų autokoreliacijos funkcija (prognozuojant pagal trumpesnio laikotarpio duomenis)






8.14 pav. TPCAD nuostolių autoregresinio modelio liekanų dalinės autokoreliacijos funkcija (prognozuojant pagal trumpesnio laikotarpio duomenis)


8.6 lentelė

#### Baltojo triukšmo hipotezės tikrinimas liekanoms


|   | Box &    | p        |
|---|----------|----------|
| 1 | 0,236585 | 0,626687 |
| 2 | 0,794429 | 0,672193 |
| 3 | 4,300345 | 0,230827 |
| 4 | 6,193015 | 0,185218 |

## 9 PRIEDAS. TPCAD NUOSTOLIŲ SUMOS PROGNOZAVIMO MODELIAI







9.4 pav. Paprastojo slenkamųjų vidurkių metodo prognozės




9.5 pav. Svertinio slenkamųjų vidurkių metodo prognozės



9.6 pav. Paprastojo eksponentinio glodinimo metodo prognozės




9.7 pav. Autoregresinio modelio prognozės




9.8 pav. ARIMA(2,1,0) modelio prognozės


## 10 PRIEDAS. SAUSUMOS TP, IŠSKYRUS GELEŽINKELIO TP, DRAUDIMO NUOSTOLIŲ SUMOS PROGNOZAVIMO MODELIAI




10.1 pav. Tiesinio trendo prognozės




10.2 pav. EkspONENTINIO trendo prognozės




10.3 pav. Logaritminio trendo prognozės




10.4 pav. Parabolinio trendo prognozės




10.5 pav. Paprastojo slenkamųjų vidurkių metodo prognozės




10.6 pav. Svertinio slenkamųjų vidurkių metodo prognozės




10.7 pav. Paprastojo eksponentinio glodinimo metodo prognozės



10.8 pav. Autoregresinio modelio prognozės




10.9 pav. ARIMA(2,1,0) modelio prognozės




10.10 pav. ARIMA(1,1,1) modelio prognozės

## 11 PRIEDAS. TURTO DRAUDIMO NUOSTOLIŲ SUMOS PROGNOZAVIMO MODELIAI




11.1 pav. Tiesinio trendo prognozės




11.2 pav. Eksponentinio trendo prognozės







11.3 pav. Logaritminio trendo prognozės




11.4 pav. Parabolinio trendo prognozės




11.5 pav. Paprastojo slenkamųjų vidurkių metodo prognozės




11.6 pav. Svertinio slenkamųjų vidurkių metodo prognozės




11.7 pav. Paprastojo eksponentinio glodinimo metodo prognozės



11.8 pav. Autoregresinio modelio prognozės



11.9 pav. ARIMA(2,1,0) modelio prognozės



11.10 pav. ARIMA(1,1,1) modelio prognozės

## 12 PRIEDAS. PROGNOZAVIMO REZULTATŲ LENTELĖS

12.1 lentelė

Sutarčių skaičiaus prognozavimo rezultatai, naudojant ARIMA(2,1,0) modelį

| TPCAD                            | Sausumos TP, išskyrus geležinkelio TP, draudimas | Turto draudimas              |
|----------------------------------|--|------------------------------|
| Prognozuojamas sutarčių skaičius | Absoliutinė ir santykinė paklaidos               | Vidutinė kvadratinė paklaida |
| 1069691                          | 58184<br>(5,75%)                                 | $10,53 \cdot 10^9$           |
| 96176                            | 3329<br>(3,35%)                                  | $1,84 \cdot 10^7$            |
| 395073                           | 7938<br>1,97%                                    | $3,91 \cdot 10^8$            |

## 12.1 lentelė

## Nuostolių sumos prognozavimo rezultatai

| Prognozavimo metodas                        | Transporto privalomosios civilinės atsakomybės draudimas |                     | Sausumos TP, išskyrus geležinkelio TP, draudimas |                     | Turto draudimas              |                     |
|---|--|---------------------|--|---------------------|------------------------------|---------------------|
|   | Vidutinė kvadratinė paklaida                             | Prognozės tikslumas | Vidutinė kvadratinė paklaida                     | Prognozės tikslumas | Vidutinė kvadratinė paklaida | Prognozės tikslumas |
| Tiesinis trendas                            | $1,36583 \cdot 10^{13}$                                  | 16,20%              | $0,54345 \cdot 10^{13}$                          | 18,33%              | $0,16728 \cdot 10^{13}$      | 4,99%               |
| Logaritminis trendas                        | $2,53666 \cdot 10^{13}$                                  | 37,62%              | $1,31943 \cdot 10^{13}$                          | 33,37%              | $0,19841 \cdot 10^{13}$      | 9,55%               |
| EkspONENTINIS trendas                       | $0,97219 \cdot 10^{13}$                                  | 10,96%              | $0,41441 \cdot 10^{13}$                          | 11,95%              | $0,16918 \cdot 10^{13}$      | 12,07%              |
| Parabolinis trendas                         | $0,53708 \cdot 10^{13}$                                  | 14,77%              | $0,37808 \cdot 10^{13}$                          | 7,04%               | $0,16563 \cdot 10^{13}$      | 9,20%               |
| Tiesinis trendas su sezoniniais svyravimais | $1,36583 \cdot 10^{13}$                                  | 16,20%              | $0,54345 \cdot 10^{13}$                          | 18,33%              | $0,16728 \cdot 10^{13}$      | 4,99%               |
| Paprastasis slenkamųjų vidurkių metodas     | $1,14339 \cdot 10^{13}$                                  | 0,38%               | $0,65962 \cdot 10^{13}$                          | 15,25%              | $0,20758 \cdot 10^{13}$      | 2,20%               |
| Svertinis slenkamųjų vidurkių metodas       | $0,87129 \cdot 10^{13}$                                  | 4,46%               | $0,65559 \cdot 10^{13}$                          | 15,39%              | $0,20592 \cdot 10^{13}$      | 1,62%               |
| Paprastojo eksponentinio glodinimo metodas  | $1,06865 \cdot 10^{13}$                                  | 3,54%               | $0,82788 \cdot 10^{13}$                          | 13,83%              | $0,20549 \cdot 10^{13}$      | 1,23%               |
| Autoregresinis modelis                      | $0,54336 \cdot 10^{13}$                                  | 22,91%              | $0,58407 \cdot 10^{13}$                          | 1,67%               | $0,15364 \cdot 10^{13}$      | 3,98%               |
| ARIMA(1,1,1)                                |  |                     | $0,717 \cdot 10^{13}$                            | 5,89%               | $0,176 \cdot 10^{13}$        | 7,66%               |
| ARIMA(2,1,0)                                | $0,59 \cdot 10^{13}$                                     | 20,25%              | $0,698 \cdot 10^{13}$                            | 8,73%               | $0,177 \cdot 10^{13}$        | 8,96%               |

## 12.2 lentelė

TPCAD sutarčių skaičiaus prognozavimo rezultatai, naudojant trumpesnio laikotarpio duomenis

| Prognozavimo metodas                        | Prognozuojamas sutarčių skaičius | Sudarytų sut. sk. | Absoliutinė ir santykinė paklaidos | Vidutinė kvadratinė paklaida |
|---|----------------------------------|-------------------|------------------------------------|------------------------------|
| Tiesinis trendas                            | 1053689                          | 1011507           | 42182<br>(4,17%)                   | $4,036 \cdot 10^9$           |
| Tiesinis trendas su sezoniniais svyravimais | 1108162                          |                   | 96655<br>(9,56%)                   | $1,306 \cdot 10^9$           |
| Logaritminis trendas                        | 1002936                          |                   | 8571<br>(0,85%)                    | $5,263 \cdot 10^9$           |
| EkspONENTINIS trendas                       | 1053534                          |                   | 42027<br>(4,15%)                   | $3,968 \cdot 10^9$           |
| Parabolinis trendas                         | 1021817                          |                   | 10310<br>(1,02%)                   | $4,263 \cdot 10^9$           |
| Paprastais slenkamųjų vidurkių metodas      | 1054649                          |                   | 43142<br>(4,27%)                   | $9,283 \cdot 10^9$           |
| Svertinis slenkamųjų vidurkių metodas       | 1050898                          |                   | 39391<br>(3,89%)                   | $8,479 \cdot 10^9$           |
| Paprastojo eksponentinio glodinimo metodas  | 991292                           |                   | 20215<br>(2,00%)                   | $7,030 \cdot 10^9$           |
| Autoregresinis modelis                      | 1105966                          |                   | 94459<br>(9,34%)                   | $2,293 \cdot 10^9$           |

## 12.3 lentelė

TPCAD sutarčių skaičiaus prognozavimo rezultatai, naudojant ilgesnio laikotarpio duomenis

| Prognozavimo metodas                        | Prognozuojamas sutarčių skaičius | Sudarytų sut. sk. | Absoliutinė ir santykinė paklaidos | Vidutinė kvadratinė paklaida |
|---|----------------------------------|-------------------|------------------------------------|------------------------------|
| Tiesinis trendas                            | 1133449                          | 1011507           | 121942<br>(12,06%)                 | $26,408 \cdot 10^9$          |
| Tiesinis trendas su sezoniniais svyravimais | 1174240                          |                   | 162733<br>(16,09%)                 | $25,479 \cdot 10^9$          |
| Logaritminis trendas                        | 835182                           |                   | 176325<br>(17,43%)                 | $63,439 \cdot 10^9$          |
| EkspONENTINIS trendas                       | 1576812                          |                   | 565305<br>(55,89%)                 | $32,731 \cdot 10^9$          |
| Paprastais slenkamųjų vidurkių metodas      | 1054649                          |                   | 43142<br>(4,27%)                   | $29,133 \cdot 10^9$          |
| Svertinis slenkamųjų vidurkių metodas       | 1050898                          |                   | 39391<br>(3,89%)                   | $25,254 \cdot 10^9$          |
| Paprastojo eksponentinio glodinimo metodas  | 1050418                          |                   | 38911<br>(3,85%)                   | $23,902 \cdot 10^9$          |
| Autoregresinis modelis                      | 1058035                          |                   | 46528<br>(4,4%)                    | $10,641 \cdot 10^9$          |

## 12.4 lentelė

## TPCAD nuostolių prognozavimo rezultatai, naudojant trumpesnio laikotarpio duomenis

| Prognozavimo metodas                        | Prognozuojamas sutarčių skaičius | Apmokėtų nuostolių sk. | Absoliutinė ir santykinė paklaidos | Vidutinė kvadratinė paklaida |
|---|----------------------------------|------------------------|------------------------------------|------------------------------|
| Tiesinis trendas                            | 24000500                         | 23057318               | 943182<br>(4,09%)                  | $4,91 \cdot 10^{12}$         |
| Tiesinis trendas su sezoniniais svyravimais | 21425296                         |                        | 1632022<br>(7,08%)                 | $3,56 \cdot 10^{12}$         |
| EkspONENTINIS trendas                       | 25019446                         |                        | 1962128<br>(8,51%)                 | $3,96 \cdot 10^{12}$         |
| Parabolinis trendas                         | 21620708                         |                        | 1436610<br>(6,23%)                 | $6,17 \cdot 10^{12}$         |
| Paprastais slenkamųjų vidurkių metodas      | 22970250                         |                        | 87068<br>(0,38%)                   | $12,16 \cdot 10^{12}$        |
| Svertinis slenkamųjų vidurkių metodas       | 24086166                         |                        | 1028848<br>(4,46%)                 | $9,62 \cdot 10^{12}$         |
| Paprastojo eksponentinio glodinimo metodas  | 23872446                         |                        | 815128<br>(3,54%)                  | $12,62 \cdot 10^{12}$        |
| Autoregresinis modelis                      | 29733893                         |                        | 6676575<br>(28,96%)                | $3,85 \cdot 10^{12}$         |

## 12.5 lentelė

## TPCAD nuostolių prognozavimo rezultatai, naudojant ilgesnio laikotarpio duomenis

| Prognozavimo metodas                        | Prognozuojamas sutarčių skaičius | Sudarytų sutarčių sk. | Absoliutinė ir santykinė paklaidos | Vidutinė kvadratinė paklaida |
|---|----------------------------------|-----------------------|------------------------------------|------------------------------|
| Tiesinis trendas                            | 19322699                         | 23057318              | 3734619<br>(16,20%)                | $13,658 \cdot 10^{12}$       |
| Tiesinis trendas su sezoniniais svyravimais | 19310012                         |                       | 3747306<br>(16,25%)                | $13,324 \cdot 10^{12}$       |
| EkspONENTINIS trendas                       | 20530160                         |                       | 2527158<br>(10,96%)                | $9,722 \cdot 10^{12}$        |
| Paprastais slenkamųjų vidurkių metodas      | 22970250                         |                       | 87068<br>(0,38%)                   | $11,434 \cdot 10^{12}$       |
| Svertinis slenkamųjų vidurkių metodas       | 24086166                         |                       | 1028848<br>(4,46%)                 | $8,713 \cdot 10^{12}$        |
| Paprastojo eksponentinio glodinimo metodas  | 23872446                         |                       | 815128<br>(3,54%)                  | $10,687 \cdot 10^{12}$       |
| Autoregresinis modelis                      | 28338698                         |                       | 5281380<br>(22,91%)                | $5,434 \cdot 10^{12}$        |