



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

Aistė Valiukevičiūtė

**LOGISTINĖS SISTEMOS SAŃAUDŲ**  
**PROGNOZĖ**

Magistro darbas

**Vadovas**

**doc. A.Kabašinskas**

**KAUNAS, 2011**



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

**TVIRTINU**

**Katedros vedėjas**

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

**2011 06 01**

**LOGISTINĖS SISTEMOS SĄNAUDŲ**  
**PROGNOZĖ**

Taikomosios matematikos magistro baigiamasis darbas

**Vadovas**

**dr. A. Kabašinskas**

**2011 06 01**

**Recenzentas**

**doc.dr. R.Lapinskas**

**2011 05 31**

**Atliko:**

**FMMM 9/1 gr. stud.**

**A. Valiukevičiūtė**

**2011 05 23**

**KAUNAS, 2011**

## **KVALIFIKACINĖ KOMISIJA**

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

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

**Nariai:**

Algimantas Jonas Aksomaitis, profesorius (KTU)

Vytautas Janilionis, docentas (KTU)

Vidmantas Povilas Pekarskas, profesorius (KTU)

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

Zenonas Navickas, profesorius (KTU)

Arūnas Barauskas, dr., vice-prezidentas projektams (UAB „Baltic Amadeus“)

## SANTRAUKA

Šiuo metu logistika suvokiama kaip praktinis verslo instrumentas, įgalinantis siekti įmonės strateginių, taktinių bei operatyvių tikslų, integruotai ir racionaliai kaštų bei prekių ir paslaugų kokybės požiūriu sprendžiant materialinių išteklių transportavimo, transformavimo bei aptarnavimo pagal vartotojo poreikius uždavinius. Tiekimo grandinė - tai logistikos dalis siejama su prekių, žaliavų judėjimu. Logistikos sistema – ta uždara tiekimo grandinės dalis, apibūdinanti ryšius tarp grandinės veiksmų.

Darbe nagrinėjama konkrečios gamybinės įmonės logistinė sistema, bei prognozuojama jos finansiniai išlaidų srantai. Prognozėms naudojama regresinių kreivių ir laiko eilučių metodai: tokie kaip trendai, autoregresinis ARIMA; atsižvelgiama į sezoniskumus. Prognozėms naudojama statistinis paketas STATISTICA ir skaičiuoklė excel. Atliktos prognozės leidžia įmonei įsivertinti gamybinius pajėgumus ir finansinius išlaidas artimiausiais periodais.

**Valiukevičiūtė A. Logistic system expenditure prognosis: Master's work in applied mathematics / supervisor dr. A.Kabašinskas; Department of mathematical research in systems, Faculty of Fundamental Sciences, Kaunas University of Technology. – Kaunas, 2011. – 56 p.**

## **SUMMARY**

Currently, logistics is perceived as a practical business tool, enabling companies to achieve strategic, tactical and operational objectives in an integrated and rational and cost of goods and services, addressing the quality of material resources, transportation, transformation and service needs of the user's tasks. Supply chain - part of the logistics associated with trade, commodity movements. Logistics system - the closed part of the supply chain, describing the relationship between the chain of factors.

At work we analyse concrete industrial company logistic system, and its projected costs of financial flows. To forecast number are using trends with seasonal decompositions, curve of Regression, Moving Average method, Simple Exponential smoothing method, Autoregressive model and Autoregressive Integrated Moving Average (ARIMA) model and sezonal ARIMA model. We use the statistical and analytical software package STATISTICA and excel. This prognosis allow the company to evaluate capacity and financial costs in the coming periods.

## TURINYS

Lentelių sąrašas .....	8
Paveikslėlių sąrašas .....	9
Įvadas .....	11
1 Teorinė dalis.....	12
1.1 Logistinė sistema ir jos sudarymas.....	12
1.2 Laiko eilutės .....	15
1.2.1 Bendra tiesinio programavimo teorija ir statistinių modelių panaudojimas prognozei	16
1.2.2 Duomenų glodinimas .....	17
1.2.3 Trendas.....	17
1.2.4 Determinacijos ir koreliacijos koeficientai .....	18
1.2.5 Sezoniniai svyravimai.....	19
1.3 Prognozavimo metodai.....	20
1.3.1 Stacionarūs tiesiniai modeliai .....	21
1.3.2 Autoregresijos ir slenkamųjų vidurkių metodai.....	21
1.3.3 Paprastas ir svertinis slenkamųjų vidurkių metodai.....	22
1.3.4 Paprastas eksponentinio glodinimo metodas .....	23
1.3.5 Nestacionarūs tiesiniai metodai.....	23
1.3.6 ARIMA metodas .....	23
1.3.7 SARIMA metodas.....	25
1.3.8 Autokoreliacijos ir dalinės autokoreliacijos funkcijos.....	25
1.3.9 Prognozavimo metodų vertinimas.....	25
1.4 Programinė įranga .....	26
2 Tiriamoji dalis .....	27

2.1	Logistinės sistemos sudarymas .....	27
2.2	Prognozavimo sistemos sudarymas .....	28
2.3	Konteinerių skaičiaus prognozė .....	28
2.3.1	Konteinerių skaičiaus prognozavimas remiantis regresinių kreivių metodais .....	29
2.3.2	Konteinerių skaičiaus prognozavimas remiantis regresinių kreivių metodais įvertinant sezoninius svyravimus .....	31
2.3.3	Konteinerių skaičiaus prognozavimas paprastu ir svertiniu slenkamųjų vidurkių bei eksponentinio glodinimo metodais .....	34
2.4	Muitinės išlaidų prognozė .....	35
2.5	Transporto kaštų prognozavimas.....	39
2.5.1	Transporto išlaidų prognozė regresinių kreivių metodais.....	39
2.5.2	Transporto išlaidų prognozė autoregresiniu metodu.....	41
2.5.3	Transporto išlaidų prognozė taikant ARIMA modelį .....	43
2.5.4	Transporto išlaidų prgnozavimas SARIMA modeliu .....	45
	Išvados .....	47
	Literatūra.....	48
1	priedas. Pradiniai duomenys .....	49
2	priedas. Konteinerių skaičiaus prognozavimo rezultatai .....	50
3	priedas. Muitinės išlaidų prognozės rezultatai .....	52
4	priedas. Transporto išlaidų prognozės rezultatai.....	54

## **LENTELIŲ SARAŠAS**

2.1 Lentelė. Autokoreliacijos funkcijos reikšmės .....	31
2.2 Lentelė. Laiko eilutės išskaidymas .....	32
2.3 Lentelė. Konteinerių skaičiaus prognozės rezultatai skaičiuojant išlyginimo metodais.....	35
2.4 Lentelė. Trendų su sezoniškumais prognozavimo rezultatai.....	40
2.5 Lentelė. Baltojo triukšmo hipotezės tikrinimas liekanoms.....	43
2.6Lentelė. Baltojo triukšmo hipotezės tikrinimas liekanoms.....	45
1Priedas.1.1 Lentelė.Pradinių duomenų lentelė.....	49
2Priedas.2.1Lentelė.Laiko eilutės išskaidymas, kai senoniškumo postūmis.....	50
3Priedas.3.1Lentelė. Baltojo triukšmo hipotezės tikrinimas liekanoms.....	54
4Priedas.4.1Lentelė. Baltojo triukšmo hipotezės tikrinimas liekanoms.....	56



## PAVEIKSLĖLIŲ SARAŠAS

1.1pav. Prognozavimo metodų klasifikacija .....	15
2.1pav. Paprasčiausia tiekimo grandinė .....	27
2.2pav. Logistinės sistemos schema .....	27
2.3pav. Kaštų prognozavimo sistema .....	28
2.4 pav. Konteinerių skaičiaus sklaidos diagrama .....	29
2.5 pav. Dažniausiai taikomi trendai duomenų aproksimacijai .....	29
2.6 pav. Antros eilės polinominio trendo prognozės.....	30
2.7 pav. Trečios eilės polinominio trendo prognozės .....	31
2.8 pav. 3 laispio polinominio trendo prognozė, kai sezoniškumo postūmis yra 4 .....	33
2.9. pav. 3 laispio polinominio trendo prognozė, kai sezoniškumo postūmis yra 7 .....	34
2.10 pav. Konteinerių skaičiaus prognozė paprastu eksponentinio glodinimo metodu .....	35
2.11 pav. Muitinės išlaidų taškų sklaidos diagrama.....	36
2.12 pav. Muitinės išlaidų prognozių palyginimo grafikai .....	36
2.13 pav. Muitinės išlaidų prognozės polinominiais trendais .....	37
2.14 pav. Muitinės išlaidų prognozė eksponentinio glodinimo metodu .....	37
2.15 pav. Autokoreliacijos funkcija .....	38
2.16 pav. Prognozės autoregresiniu metodu rezultatai.....	38
2.17 pav. Transportavimo kaštų taškų sklaidos diagrama.....	39
2.18 pav. Transporto išlaidų prognozių palyginimo grafikai.....	39
2.19 pav. Transporto išlaidų prognozė polinominiais trendais .....	40
2.20 pav. Transporto išlaidų autokoreliacijos funkcija .....	41
2.21 pav. Transporto išlaidų prognozė autoregresiniu metodu .....	42
2.22 pav. Liekamų autokoreliacijos ir dalinės autokoreliacijos funkcijos .....	42
2.23 pav. Transporto išlaidų autokoreliacijos ir dalinės autokoreliacijos funkcijos .....	43

2.24 pav. Diferencijuota transporto išlaidų seka.....	44
2.25 pav. Prognozuotos reikšmės pagal ARIMA(1,1,1) .....	44
2.26 pav. ARIMA(1,1,1) liekanų autokoreliacijos ir dalinės autokoreliacijos funkcijos .....	45
2.27 pav. SARIMA modelio prognozės rezultatai .....	46
2.1 pav. Trendų su senoniškumais taikant adityvinį modelį prognozės rezultatai.....	51
2.2 3 laispio polinominio trendo prognozė, kai sezoniškumo postūmis yra 6.....	51
3.1 pav. Prognozės svertiniu slenkamųjų vidurkių metodu rezultatas .....	52
3.2 pav. Prognozės paprastu slenkamųjų vidurkių metodu rezultatas .....	52
3.3 pav. Autoregresinio modelio liekanų autokoreliacijos funkcija .....	53
3.4 pav. Autoregresinio modelio liekanų dalinės autokoreliacijos funkcija .....	53
4.1 pav. Transporto išlaidų prognozės rezultatai pritaikius sezoniškumus ir multiplikatyvinį metodą...54	
4.2 pav. SARIMA metodo liekanų autokoreliacinė funkcija.....	55
4.3 pav. SARIMA metodo liekanų dalinės autokoreliacijos funkcija.....	55

## IVADAS

Dauguma įmonių sudarinėja planus, biudžetus tam žinotų kokie įmonės gamybiniai ar produkcijos, paslaugų pardavimai bus ateinančiais periodais. Sudarant planus remiasi praėjusiais laikotarpiais, taip pat vertina nukrypimus nuo planų.

Savo darbe nagrinėsiu konkrečios įmonės logistinės sistemos apimamčios prekių transportavimo finansinių srautų ir fizinių konteinerių skaičiaus prognozę. Prognozės atliekamos taikant tiesinius ir netiesinius prognozavimo metodus. Taip pat atsižvelgiama į duomenų senoniškumą.

Pasinaudojant paketą STATISTICA ir excel galimybėmis ir taikant keletą prognozavimo modelių ieškoma patikimiausių ir labiausiai tikrus duomenis atitinkančių prognozių. Prognozavimui taikoma duomenų aproksimavimas tiesinėmis, eksponentinėmis, logaritminėmis ir polinominėmis kreivėmis. Taip pat naudojami išlyginimo metodai: paprastas ir svertinis slenkamųjų vidurkių, paprastas eksponentinio glodinimo ir autoregresinis prognozavimo modelis. Gauti prognozavimo duomenys pateikiami lentelių ir grafinių iliustracijų pavidalu, vertinamos gautos paklaidos.

# 1 TEORINĖ DALIS

## 1.1 LOGISTINĖ SISTEMA IR JOS SUDARYMAS

Logistika - tai su įmonės tikslais susijusios planavimo ir valdymo priemonės, optimaliam medžiagų, lėšų ir informacijos srautams užtikrinti, vykdant produkcijos gamybą, kuri prasideda gamybos veiksmų ir informacijos rinkimu, apdorojimu perdavimu ir baigiasi pagamintos produkcijos paskirstymu.

Logistikos objektas – materialių vertybių ( žaliavų, medžagų, gaminių) judėjimo bei transformavimo procesas, kitaip dar vadinamas materialiu srautu.

Su materialiuoju srautu susijusios informacijos judėjimas, jos transformavimas su tam tikros logistikos sistemos parametrais įvardijamas kaip *informacinis srautas* (information flow). Informacinio srauto duomenų rinkimas, saugojimas, apdorojimas, perdavimas logistikos sistemos viduje, iš logistikos sistemos į išorę ir atvirkščiai taip pat yra priskiriama logistikos operacijoms.

*Finansinis srautas* (financial flow) logistikoje suprantamas kaip tikslingas finansinių išteklių cirkuliavimas logistikos sistemoje ir už jos ribų, užtikrinantis efektyvų materialaus ir su juo susijusių srautų (informacinių, paslaugų) judėjimą ir valdymą. Finansinių srautų logistikoje specifika yra ta, kad jie nėra savarankiški, t.y. juos generuoja poreikis aptarnauti materialiujų – prekinių arba nematerialiujų vertybių judėjimo tam tikru laiku tam tikroje erdvėje procesą.

Logistiką taip pat galima vertinti kaip klasikinį sisteminio metodo taikymo verslo problemoms spresti pavyzdį. Esminė jos funkcija - srautinių procesų optimizavimas.

Sistemos elementas – tai sistemos dalis, sąlyginai nebeskaidoma į sudedamąsias dalis.

Logistikos sistema apibūdinama kaip sudėtinga, struktūrizuota, su grįžtamuoju ryšiu ekonominė sistema. Ją sudaro vieningame materialiujų ir su jais susijusių srautų valdymo procese tarpusavyje sąveikaujantys elementai – grandys.

Logistikos sistemas paprastai sudaro keletas posistemių, jos pasižymi tampriais ryšiais su išorine aplinka.

*Makrologistinė sistema* – tai stambi materialaus srauto valdymo sistema, integraciniais ryšiais apjungianti pramonės įmones ir organizacijas, prekybos tarpininkus, transporto organizacijas, esančias skirtinguose rajonuose, regionuose arba net skirtingose šalyse.

Mikrologistinės sistemos – tai makrologistinių sistemų posistemės, funkciniai elementai. Jos siejamos su tam tikra įmone, jų paskirtis - valdyti materialiuosius srautus gamybos, aprūpinimo ir realizavimo procese. Priklausomai nuo logistikos sistemoms keliamų tikslų ir į jas įtraukiamų bazinių veiklos sričių išskiriami tokie mikrologistinių sistemų tipai:

- Vidinės logistikos sistemos. Jų paskirtis – optimizuoti materialaus srauto valdymą gamybos technologinio ciklo ribose;
- Išorinės logistikos sistemos. Jų paskirtis – spręsti uždavinius, susijusius su materialiujų srautų valdymu nuo jų pirminių šaltinių iki paskirties vietų. Tai įmonės aprūpinimo ir prekių paskirstymo uždaviniai;
- Integruotos verslo logistikos sistemos, apjungiančios vidines ir išorines logistikos sistemas.

Kalbant apie gamybinės įmonės logistikos sistemą, išskiriami šie *pagrindiniai jos valdymo elementai*:

*Atsargos* - užperkamos pas tiekėją bei įmonės disponuojamos žaliavos, medžiagos, komplektuojami gaminiai, gatavi gaminiai. Atsargų vaidmuo sistemoje ypatingas, jos turi užtikrinti nenutrūkstamą visos sistemos funkcionavimą, apdrausti nuo įvairių neapibrėžtumų, susijusių su besikeičiančiom sąlygom rinkoje (pvz., paklausos svyravimai). Atsargos gali būti kaupiamos betarpiškai pas gamintoją arba priartintos prie vartotojo. Jų dydis turi būti optimalus, priklausomai nuo sistemai keliamų tikslų.

*Transportas*, kuris perveža krovinius iš tiekėjo į įmonę, įmonės viduje iš sandėlių į gamybos barus, pristato krovinius vartotojui (į paskirstymo tinklą). Įskaitomos visos transportavimo galimybės, neišskiriant ir transporto paslaugų pirkimo, transporto nuomos. Pagrindiniai transporto rūšies ir transportavimo būdo pasirinkimo kriterijai – kaina ir patikimumas.

Logistikos sistemos sudaromos, siekiant sudaryti naudingus rezultatus, įtraukiant į jas atitinkamus elementus, nustatant jų sąveiką ir tarpusavio ryšius bei ryšius su aplinka.

Sudarant logistines sistemas, svarbią reikšmę turi šie principai:

- *tikslingumo principas*, kuris orientuoja į pritraukimą tik to potencialo, kuris atlieka teigiamą vaidmenį, siekiant sistemai keliamų tikslų.

- *lankstumo principu*, kuris reikalauja logistikos sistemas sudaryti tokiu būdu, kad visuomet išliktų galimybė jų struktūrinius elementus sukeisti vietomis.
- *iniciatyvumo* principas, kurio taikymas numato susidarančių struktūrų sugebėjimą tinkamai reaguoti į tikėtinus įvykius, leidžia sistemai greitai adaptuotis prie vidinių ir išorinių sąlygų pokyčių.

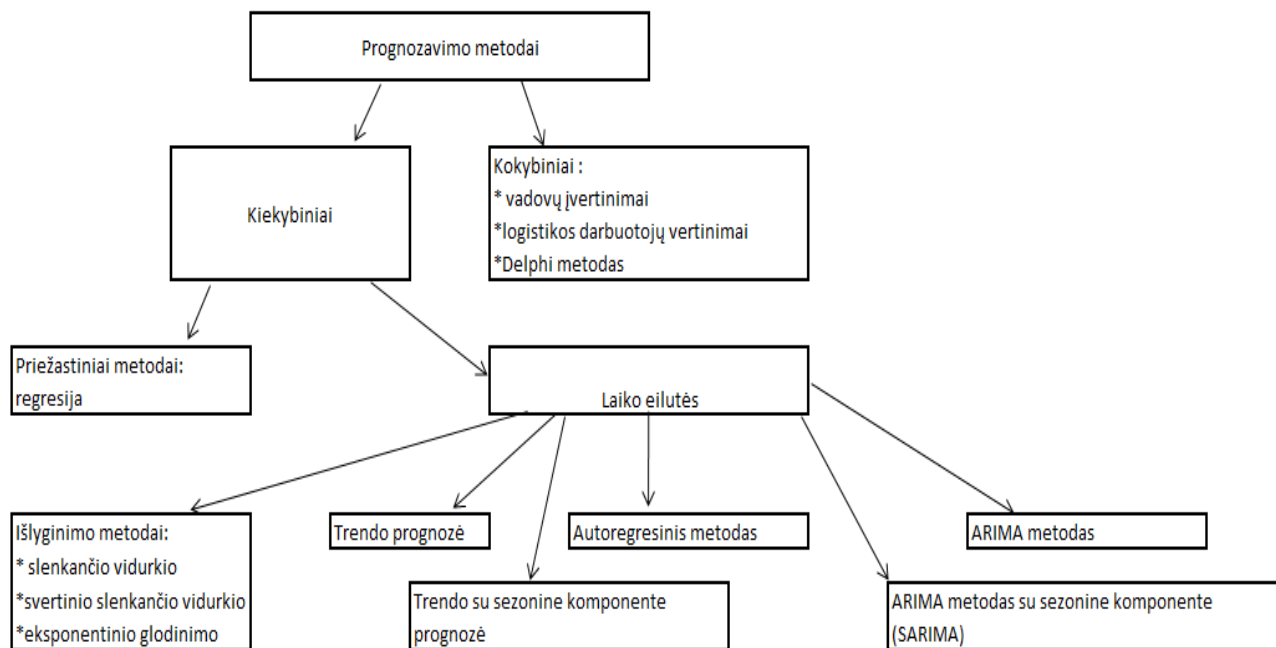
Pagrindinė logistikos sistemos sudarymo koncepcija įtvirtina visų jos funkcinų elementų ir grandžių tarpusavio suderinimo bei jų *tikslingo bendro veikimo principą*.

Logistikos sistemų funkcionavimo efektyvumą didele dalimi sąlygoja ir tai, kaip aiškiai ir pagrįstai yra apibrėžiami išskelti tikslai. Jeigu tikslai suformuluoti nekonkrečiai, neteisingai suvokiami arba jie yra nepamatuoti, nerealūs, tai negalima parinkti ir adekvačių priemonių jiems realizuoti. [1]

Nagrinėjant finansinius srautus galime taikyti įvairias logistines priemones, kurias galime suskirstyti į dvi pagrindines dalis:

- Materialios logistikos priemonės – tai tiek vidaus tiek ir išorės sistemos, kurios susijusios su transportu, sandėlių įrengimais, sandėliavimu komunikacijomis.
- Nematerialios logistikos priemonės – tai logistinės veiklos ir sprendimų būdai, kurie sudaryti iš:
  - Analizinės priemonės – tai įvairių rinkų, rodiklių tyrimai, kurie gali įtakoti įmonės darbą.
  - Planavimo priemonės leidžia planuotojams pasinaudojant sukauptais duomenis, įvertinti galimus prognozių rezultatus esant skirtingoms aplinkybėms, tokiu būdu surandamas optimaliausias variantas.
  - Idėjų kūrimo priemonės – tai naujos produkcijos, gamybos būdų, gabedimo maršrutų ar kitų įmonei svarbių faktų kūrimas ir realizavimas.

Pagrindinės planavimo (prognozavimo) priemonės (metodus) išdėstome grafine schema, kuri matoma 1.1 pav. [2]



**1.1pav. Prognozavimo metodų klasifikacija**

Darbe naudojama tik kiekybinės logistikos planavimo priemonės, nes šios priemonės yra matematinės statistikos metodai. Priežastiniais metodais - remiasi pagrindine hipoteze, kad ateities rezultatai priklauso nuo praeities duomenų. Jiems priskiriama regresija ir laiko eilučių metodai. Laiko eilučių ekstrapoliacija - praeities tendencijos išliks ir ateityje. Tokioms prognozėms yra naudojami slenkamųjų vidurkių metodai, eksponentinis glodinimas, autoregresinis, ARIMA, bei SARIMA.

## 1.2 LAIKO EILUTĖS

Statistiniai duomenys, surinkti reguliariais laiko intervalais, yra vadinami laiko eilutėmis. Analizuojant laiko eilutes, sprendžiami du pagrindiniai uždaviniai:

- nustatoma pagrindinė analizuojamų duomenų prigimtis, t.y. išskiriami pagrindiniai faktoriai, veiksniai, turintys įtakos duomenims. Šis uždavinys sprendžiamas taikant keletą metodų: duomenų glodinimą, tinkamos kreivės parinkimą ir autokoreliaciją.
- prognozuojami ateities rezultatai slenkamųjų vidurkiu, eksponentinio glodinimo ir autoregresijos metodais.

Laiko eilučių analizei naudojamos priemonės: grafikai, glodinimas, skaidymas į atskirus komponentus, regresinių modelių taikymas, ARIMA, SARIMA modelių taikymas.

### 1.2.1 BENDRA TIESINIO PROGRAMAVIMO TEORIJA IR STATISTINIŲ MODELIŲ PANAUDOJIMAS PROGNOZEI

Statistinio modelio sukūrimas nagrinėjamiems duomenims nėra savitiksliis uždavinys. Kiekvienas modelis yra tam tikra tikrovės idealizacija, todėl modelius panaudojame sprenžiant tokius uždavinius:

- prognozuoti būsimas reikšmes
- modeliuoti panašias realizacijas
- atkurti trūkstamas reikšmes stebėjimų sekoje
- išgryninti stebėjimus atmetant reikšmes dėl šalutinio poveikio

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

Tarkime, stebime atsitiktinių vektorių  $X = (X_1, X_2, \dots, X_n)^T$ . Atsitiktinio dydžio  $Y$  prognozė:

$$\hat{Y} = a + b_1X_1 + \dots + b_nX_n = a + b^T X \quad (1.1)$$

Prognozės tikslumo matas – vidutinė kvadratinė paklaida:

$$\Delta = \Delta(a, b) = E\varepsilon^2, \varepsilon = Y - \hat{Y} \quad (1.2)$$

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

$$E\varepsilon^2 = 0, \quad cov(\varepsilon, X) = 0$$

Optimalūs koeficientai randami iš lygčių:

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

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



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

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

## 1.2.2 DUOMENŲ GLODINIMAS

Kaip ir daugelis statistinių duomenų, laiko eilučių duomenys apima sistemine komponentę ir atsitiktinį triukšmą (nepaaiškinamą išsibarstymą), kuris labai apsunkina sisteminės komponentės nustatymą. Todėl labai dažnai prieš pradedant laiko eilučių tyrimą, tenka naudoti įvairių duomenų filtravimo techniką, kuri leidžia labiau išryškinti sistemine komponentę. Vienas iš paprasčiausių ir plačiausiai paplitusių yra duomenų glodinimas slenkamųjų vidurkiu metodu. Pagal šį metodą kiekvienas laiko eilutės narys yra pakeičiamas jį supančių narių vidurkiu. Naudojamas narių skaičius vadinamas glodinimo pločiu. Jei yra narių, daug besiskiriančių nuo kitų savo dydžiu, vietoje vidurkio gali būti naudojama ir mediana. Nors glodinant duomenis prarandama dalis informacijos, tačiau pagal glodintus duomenis lengviau ir tiksliau galima atlikti ateities prognozes.

Turint suglodintus duomenis, galima pereiti prie sisteminės komponentės analizės. Laiko eilutėse išskiriami keturi pagrindiniai veiksniai, darantys įtaką sisteminei komponentei:

- trendas
- sezoniškumas;
- cikliškumas;
- atsitiktinumo (nereguliaroji) komponentė.
- 

## 1.2.3 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 tiriamojoje dalyje naudojamas trendo formas.

Parabolinis trendas yra tinkamas laiko eilučių, kurių duomenų antrieji skirtumai (gretimų

pirmųjų skirtumų reikšmės) vienas nuo kito nedaug skiriasi, aproksimavimo modelis.

$$\text{Antros eilės parabolės regresijos (parabolinio trendo) lygtis: } Y = b_0 + b_1 * t + b_2 * t^2 \quad (1.3)$$

$$\text{Eksponentinio trendo lygtis: } Y = b_0 * e^{b_1 * t} \quad (1.4)$$

$$\text{Logaritminio trendo lygtis: } Y = b_0 + b_1 \log_{10} x \quad (1.5)$$

$$\text{n- tos eilės polinominio trendo lygtis: } Y = b_0 + b_1 x + \dots + b_n x^n \quad (1.6)$$

Čia užrašytose lygtyse  $b_0$ ,  $b_1$ ,  $b_n$  - 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:

$$b_1 = \frac{\overline{xy} - \bar{x} \cdot \bar{y}}{\overline{x^2} - \bar{x}^2} \quad b_0 = \bar{y} - b_1 \bar{x} \quad (1.7)$$

Čia brūkšnelis virš kintamojo žymi jo vidurkį.

Pavyzdžiui:

$$\overline{xy} = \frac{1}{n} \cdot \sum_{i=1}^n x_i y_i \quad \overline{x^2} = \frac{1}{n} \cdot \sum_{i=1}^n x_i^2$$

## 1.2.4 DETERMINACIJOS IR KORELIACIJOS KOEFICIENTAI

Tarkime turime regresinę kreivę ir norime patikrinti ar ji atitinka eksperimento duomenis. Pagrindinis tinkamumo matas yra determinacijos koeficientas, kuris žymimas  $r^2$  ir apibrėžiamas santykiu:

$$r^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad , \quad \text{kai } 0 < r^2 < 1 \quad (1.8)$$

Tai yra regresinio nuokrypio nuo kvadratų sumos ir bendro nuokrypio kvadratų santykis. Kuo determinacijos koeficientas arčiau vienetą, tuo regresinė kreivė geriau tinka eksperimento duomenis.

Kai mus 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. Mažos  $r$  reikšmės rodo, kad tiesinis ryšys tarp kintamųjų yra nežymus. Aišku, tai nereiškia, kad tarp kintamųjų negali būti stipraus netiesinio ryšio.

### 1.2.5 SEZONINIAI SVYRAVIMAI

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

Vienas populiariausių būdų nustatyti, kad nagrinėjama eilutė yra veikiamą sezoniškumo yra skirtumų tarp trendo eilutės ir laiko eilutės nagrinėjimas. Jei tų skirtumų svyravimai yra seguliarūs, galima teigti, kad eilutė yra veikiamą sezoniškumo.

Kai duomenų kreivės viršūnės yra išsidėsčiusios pagal horizontalią liniją, sakoma, kad turime adityvųjį sezoniškumo modelį. Jei viršūnių taškai turi tendenciją didėti arba mažėti, vadinasi taikomas multiplikatyvinis metodas.

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:

$$Y = b_0 + b_1 * t + b_2 * t_1 + \dots + b_n t_{n-1} \quad (1.9)$$

kur  $b_0, b_1, \dots, b_n$  – 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.

### 1.3 PROGNOZAVIMO METODAI

Prognozavimo metodai skirstomi į kokybinius (intuityvinius) ir kiekybinius (sisteminius) prognozavimo metodus. Intuityviniams metodams didžiausia įtaka turi žmonių (klientų, ekspertų ir kt.) nuomonė. Šie metodai taikomi, kai turimos informacijos nepakanka kiekybiniam įvertinimui, arba kai norima sudaryti prognozę, papildančią kiekybinę prognozę. Taikant kiekybinius prognozavimo metodus matematine forma išreiškiamas ryšys tarp prognozuojamų kintamųjų ir kitų kintamųjų (tai gali būti praeities reikšmės ar kiti su kintamaisiais susiję dydžiai).

Dažniausiai taikomi šie prognozavimo metodai:

- trendo ekstrapoliacija; slenkamųjų vidurkių metodas; eksponentinis išlyginimas.
- regresinė analizė.
- vadovų įvertinimai.
- prognozės, sudarytos remiantis vartotojų apklausa.
- „Delphi“ metodas.

Kai turimi duomenys išsidėstę visiškai atsitiktinai ir iš jų sunku išskirti trendą bei sezoniškumo komponentę, reikalingi kiti prognozavimo metodai. Panagrinėsime keletą laiko eilučių prognozavimo metodų, kai duomenis generuojantis procesas yra stacionarusis, t.y. kai proceso vidurkis ir autokoreliacijos funkcija nesikeičia keičiantis laikui:

$$\forall t, s \in T \quad \mu(t) = \mu(0) \quad (1.10)$$

$$R(t, s) = R(t - s, 0) \quad (1.11)$$

Norint taikyti prognozavimo metodus nestacionariems procesams, reikia naudoti jų transformacijas, kurios suveda į stacionarųjį pavidalą, t.y. panaikinti trendą. Ši procedūra yra vadinama diferencijavimu. Trendą galima panaikinti ir paprasčiausiai iš kiekvieno nagrinėjamos sekos nario atimant atitinkama trendo reikšmę. Tačiau diferencijavimas yra labiau tinkanti procedūra mūsų nagrinėjamiems prognozavimo metodams. Išdiferencijuoti laiko eilute  $y_t$  galima atlikus keitimą  $z_t = y_t - y_{t-1}$ , vadinasi nagrinėjant pirmuosius proceso skirtumus. Jeigu ir po tokio pakeitimo procesas nepasidaro stacionarus procedūra kartojame.

Naudojant laiko eiluciu prognozavimo metodus, reikia visada žiurėti, ar parinktas metodas leidžia pakankamai tiksliai prognozuoti. Prognozavimo klaida yra apibrėžiama kaip skirtumas tarp

stebimos laiko eilutės reikšmės ir prognozuotos. Tų skirtumų kvadratų suma vadinama prognozavimo tikslumu.

Prognozuoti patartina metodu, duodančiu didžiausia prognozavimo tikslumą.

### 1.3.1 STACIONARŪS TIESINIAI MODELIAI

Tarkime, kad  $\zeta_t$  yra stacionarus procesas su vidurkiu.  $E\zeta_t = \mu$  ir kovariacinė funkcija  $R(\tau) = cov(\zeta_t, \zeta_{t+\tau})$ . Stebima imtis  $(\zeta_1, \zeta_2, \dots, \zeta_n)$ , o reikia prognozuoti  $\zeta_s$ , ku  $s > n$ . Optimali pronozė

$$\zeta_s = \alpha + \beta_1 \zeta_1 + \dots + \beta_n \zeta_n \text{ gaunama, kai } \beta = R_{XX}^{-1} R_{X\zeta_s},$$

$$\alpha = \mu - \beta^T EX = \mu(1 - \beta_1 - \dots - \beta_n), \text{ čia } X = (\zeta_1, \dots, \zeta_n)^T,$$

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

### 1.3.2 AUTOREGRESIJOS IR SLENKAMŲJŲ VIDURKIŲ METODAI

Jei laiko eilutės stebimos reikšmės stipriai koreliuotos tarpusavyje, tai ateities reikšmę galima prognozuoti naudojantis praeityje stebėtomis reikšmėmis, dažniausiai turinčiomis didžiausia įtaka. Stacionarus procesas  $\zeta_t$  vadinamas p eilės autoregresijos procesu (AR(p)), jei jis išreiškiamas:

$$\zeta_t = \mu + a_1 \zeta_{t-1} + \dots + a_p \zeta_{t-p} + \varepsilon_t, \quad t \in Z, \quad (1.12)$$

čia  $\varepsilon_t$  – baltas triušmas.

Atsitiktinis procesas  $\varepsilon_t$  vadinamas baltu triukšmu, jei jis tenkina  $E\varepsilon_t = 0$  ir  $cov(\varepsilon_t, \varepsilon_s) = 0$ , kai  $t \neq s$  savybes ir yra stacionarus.

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.

Stacionarus procesas  $\zeta_t$  vadinamas q eiles slenkamojo vidurkio procesu (MA(q)), jei jis išreiškiamas:

$$\zeta_t = \mu + \varepsilon_t + b_1 \varepsilon_{t-1} + \dots + b_q \varepsilon_{t-q}, \quad t \in Z \quad (1.13)$$

čia  $\varepsilon_t$  – baltas triušmas.

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.

### 1.3.3 PAPRASTAS IR SVERTINIS SLENKAMŪJŲ VIDURKIŲ METODAI

Tai yra vienas iš paprasčiausių prognozavimo metodų. Pronozuodami pagal slenkamųjų vidurkių metodą, tariame, kad prognozuojama reikšmė geriausiai reprezentuojama  $n$  prieš tai stebėtų reikšmių aritmetiniu vidurkiu. Simboliškai tai galima užrašyti formule:

$$\hat{y} = \frac{y_{t-1} + y_{t-2} + \dots + y_{t-n}}{n} \quad (1.14)$$

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 ankstenės. Todėl yra imamas svertinis prieš tai stebėtų reikšmių vidurkis:

$$\hat{y} = d_1 \cdot y_{t-1} + d_2 \cdot y_{t-2} + \dots + d_n \cdot y_n, \quad (1.15)$$

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.

### 1.3.4 PAPRASTAS EKSPONENTINIO GLODINIMO METODAS

Paprastojo eksponentinio glodinimo metodas šiandien yra plačiausiai naudojama tarp prognozavimo metodų. Šis metodas skiriasi nuo slenkamųjų vidurkių metodo tik svorių suteikimo ankstesnėms reikšmėms metodika. Jis irgi taikytinas tik stacionariosioms laiko eilutėms. Prognozuojama reikšmė yra apskaičiuojama pagal formulę:

$$\hat{y}_t = \alpha(y_{t-1} - \hat{y}_{t-1}) + \hat{y}_{t-1}, \text{ kur } 0 \leq \alpha \leq 1 \quad (1.16)$$

vadinama glodinimo konstanta. Ji susijusi su slenkamųjų vidurkių metodo narių skaičiumi  $n$  apytiksliai tokia priklausomybe:  $\alpha = \frac{2}{n+1}$ . Todėl, kai  $\alpha$  artimas vienetui, turime nedidelį duomenų glodinimą, o kai  $\alpha$  mažas – gana smarkų glodinimą. Eksponentinio glodinimo metodo pranašumas prieš slenkamųjų vidurkių metodą yra tas, kad eksponentiniam glodinimui atlikti reikia tik paskutinio laiko momento matavimo reikšmės ir jo prognozės, o slenkamųjų vidurkių metodui – visos eilės prieš tai buvusių duomenų, bet tai ne visada yra įmanoma.[3,4,5]

### 1.3.5 NESTACIONARŪS TIESINIAI METODAI

Tikrovėje dauguma procesų nėra stacionarus. Taip yra pavyzdžiui dėl besikeičiančios ekonominės padėties, rinkos pokyčių, konkurencijos ir pan.

Atsitiktinis procesas  $\zeta_t$  vadinamas  $d$  – eilės integruotu (žymima  $\zeta \in I(d)$ ), jei jo  $d$  eilės pokyčiai yra stacionarus procesas, o  $d - 1$  eilės pokyčiai nėra stacionarūs.

Bendru atveju:

$$\Delta^d \zeta_t = \Delta^{d-1} \zeta_t - \Delta^{d-1} \zeta_{t-1} = (1 - L)^d \zeta_t \quad (1.17)$$

### 1.3.6 ARIMA METODAS

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

atsitiktinį triukšmą aprašymo būdą.

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

$$P(L)(1 - L)^d \widehat{\zeta}_t = Q(L)\varepsilon_t \quad (1.18)$$

Čia  $P(z)$ ,  $Q(z)$  – p ir q eilės polinominiai atitikimai, o  $\varepsilon_t$  – balto triukšmo procesas.

Jei stebime  $\zeta_0, \zeta_1, \dots, \zeta_n$ , kur  $\zeta_t$  yra ARIMA(p,d,q) procesas, tai pažymėję  $\eta_t = (1 - L)^d \zeta_t$  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 taikome bendrą tiesinio programavimo teoriją.

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

$$\eta_t = (1 - L)^d \zeta_t = \sum_{k=0}^d (-1)^k \binom{d}{k} \zeta_{t-k}, \quad \text{čia } \binom{d}{k} = \frac{d!}{k!(d-k)!}$$

Žinodami  $\eta_t$  ir  $\zeta_0, \zeta_1, \dots, \zeta_n$ , reikšmes  $\zeta_t$ , rekurentiniu būdu galime surasti

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

Pirmas žingsnis taikant ARIMA modelį, yra procesų, apsprendžiančių laiko eilučių pobūdį, identifikacija. Turi būti nustatytos modelio ARIMA(p, d, q) parametrų 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. Parametru 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 pirmasias dalinės autokoreliacijos funkcijos reikšmes.

Slenkamųjų vidurkių modeliai ARIMA (0, 0, q) turi aiškiai išsiskiriančias pirmasias 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.



### 1.3.7 SARIMA METODAS

SARIMA – sezoninis autoregresinis integruotas slenkamųjų vidurkių metodas. Šio metodo dalis struktūros tokia pati kaip ARIMA modelio t.y turi AR, MA faktorius ir diferencijavimą. Sezoninė modelio dalis yra visų šių faktorių apjungimas atsižvelgiant į sezoniškumus.

Modelis klasifikuojamas taip:

$$\text{SARIMA} = \text{ARIMA}(p,d,q) \times (P,D,Q)S$$

čia P- sezoninio AR modelio komponentė, D – sezoninių diferencijavimų skaičius, Q- sezoninio MA modelio komponentė., S- senoniškumas. Taikydami šį metodą pirmiausia turime surasti d ir D reikšmes, su kuriomis procesas  $Y_t = (1 - L)^d(1 - L^S)^D X_t$  būtų stacionarus. Tuomet remiantis autokoreliacija ir daline autokoreliacija surandame P ir Q reišmes.[5,6]

### 1.3.8 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 postumiui  $k$  yra skaičiuojama pagal formulę:

$$r_k = \frac{\sum_{i=1}^{n-k} (y_i - \bar{y})(y_{i+k} - \bar{y})}{\sum_{i=0}^n (y_i - \bar{y})^2} \quad (1.19)$$

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

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

koeficientas  $a_{kk}$

### 1.3.9 PROGNOZAVIMO METODŲ VERTINIMAS

Atliekant laiko eilutės prognozę kitiems laiko momentams, labai svarbu žinoti, ar pakankamai tiksliai atliekama prognozė ir kaip reikėtų palyginti keletą prognozių, gautų skirtingais metodais.

Pateiksime keletą koeficientų, padedančių įvertinti prognozės tikslumą.

Klaidos vidurkis:

$$ME = \sum_{i=1}^n \frac{r_i - p_i}{n} \quad (1.20)$$

Klaidos absoliutinis vidurkis:

$$MAE = \sum_{i=0}^n \frac{|r_i - p_i|}{n} \quad (1.21)$$

Kvadratinė paklaida:

$$SSE = \sum_{i=0}^n (r_i - p_i)^2 \quad (1.22)$$

Vidutinė kvadratinė paklaida:

$$MSE = \frac{1}{n} \sum_{i=0}^n (r_i - p_i)^2 \quad (1.23)$$

Čia  $r_i$  – stebima reikšmė momentu  $i$ ,  $p_i$  – prognozuojama reikšmė momentu  $i$ . [4]

## 1.4 PROGRAMINĖ ĮRANGA


Darbo analizėms ir prognozėms naudojamas statistinis paketas STATISTICA bei Microsoft Excel 2007 versija. Tokį pasirinkimą nulėmė daugybė paketų sprendžiamų problemų, puikios grafinio rezultatų pateikimo galimybės, patogi vartotojo aplinka. Taip pat labai svarbu skaičiavimų tikslumas ir greitis, nagrinėjamų statistinių metodų gausa, duomenų pasikeitimo su kitomis programomis ir makrokomandų naudojimo galimybės, vidinis komandinis programavimo kalbos egzistavimas, leidžiantis atlikti reikalingą duomenų analize ir grafine jų interpretacija. Šios programos – tai kompleksinės integruotos sistemos, skirtos tiek duomenų masių statistinei analizei, tiek ir grafikų ir diagramų braižymui. Taip pat puikiai tinka informacijos masių valdymui bei turin itin platų pasirinkimą bazinių analitinių procedūrų, skirtų moksliniams, verslo ar inžineriniams skaičiavimams.

## 2 TIRIAMOJI DALIS

### 2.1 LOGISTINĖS SISTEMOS SUDARYMAS

Darbe nagrinėjama konkrečios įmonės, žaliavų tiekimo grandinės finansinius srautus. Logistinė sistema, tai tik dalis tiekimo grandinės, kuri apima tik kaštus reikalingus žaliavų gabenimui iki gamyklos.


Paprasčiausia tiekimo grandinę galime pavaizduoti taip:



**2.1pav. Paprasčiausia tiekimo grandinė**

Logistinė sistema apima grandinės dalis, kurios yra detalių transportavimas iš gamintojo iki įmonės ir iš įmonės iki vartotojo.

Kadangi savo darbe naudosis konkrečios įmonės tiekimo grandinę dalį tai supaprastinus ją galime apibėžti taip:



**2.2pav. Logistinės sistemos schema**

Gabenant produkciją iš detalių tiekėjų gamintojui svarbu žinoti ir prognozuoti kokios sąnaudos yra už prekių transportavimą ir kokie konteinerių srautai ateina į gamyklą, todėl remiantis šiomis žiniomis įmonė gali tikslingiau valdyti savo turimas lėšas bei gamyklinį inventorių. Gabenant konteinerius yra dvi pagrindinės kaštų rūšys: muitinės išlaidos ir konteinerių gabenimo (pervežimo) išlaidos.

## 2.2 PROGNOZAVIMO SISTEMOS SUDARYMAS

Remiantis žiniomis apie logistinės sistemos kaštus sudariau kaštų prognozavimo sistemą.



2.3pav. Kaštų prognozavimo sistema

**Konteinerių skaičiaus prognozė.** Ši prognozė reikalinga tam, kad galėtumėme nustatyti koks konteinerių srautas bus ateinančiais laikotarpiais. Konteinerių skaičius matuojamas sveikais vienetais.

**Muitinės kaštų prognozė.** Atsižvelgdami į prognozuojamų konteinerių srautą galime planuoti išlaidas reikalingas muitinės forminimui.


**Transportavimo kaštų prognozė.** Remiantis prognozuojamų konteinerių srautu taip pat galime, planuoti išlaidas reikalingas konteinerių gabėninui iš taško A į tašką B.

Turint visus šiuos punktus galime gauname visos logistinės sistemos kaštų prognozę. Pradiniai duomenys remiantis kurias bus atliekamos prognozės pateikiami 1 priede.

## 2.3 KONTEINERIŲ SKAIČIAUS PROGNOZĖ

Prognozavimui atlikti naudosimės duomenimis, esančiais 1 priede 1.1 lentelėje. Prognozavimą atliksime naudodami laiko eilučių prognozavimo metodus. Prognozavimas daromas 2009 metų gruodžio mėnesiui, o tikras skaičius imamas iš pradinių duomenų tuo pačiu laikotarpiu, siekiant išrinkti tikkamiausią variantą (visose prognozese laikotarpis yra tas pats).

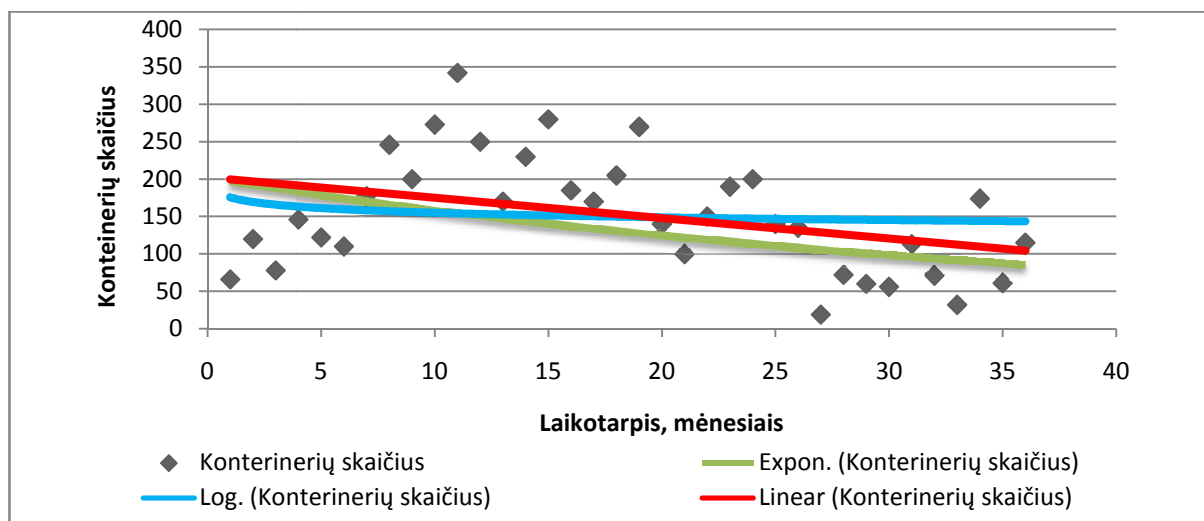
Nagrinėsime atplaukiančių konteinerių skaičių, kuris priklauso nuo laiko t.y mėnesių. Šių taškų sklaidos diagrama 2.4 pav.



2.4 pav. Konteinerių skaičiaus sklaidos diagrama

### 2.3.1 KONTEINERIŲ SKAIČIAUS PROGNOZAVIMAS REMIANTIS REGRESINIŲ KREIVIŲ METODAIS

Tarkime, kad turimus duomenis galime aproksimuoti pritaikę pasirinktą funkciją. Pasinaudodami excel teikiamomis galimybėmis, grafiniu būdu pritaikome kelių rūšių trendus. Kaip matome iš 2.5 pav. parinkti metodai aproksimuoja duomenis su didelėmis paklaidomis, todėl jų plačiau nenagrinėjame, o ieškosime tikslesnių metodų.

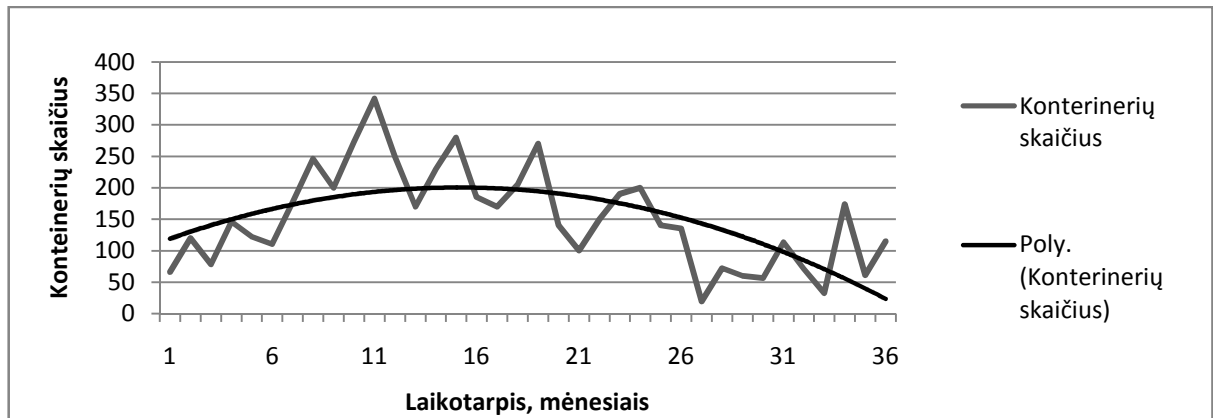


2.5 pav. Dažniausiai taikomi trendai duomenų aproksimacijai

Pritaikykite duomenis polinoninius trendus. Antros eilės polinominio trendo lygtis:

$$\text{Konteinerių skaičius} = -0.407x^2 + 12.34x + 106.9$$

Taip pat randame determinacijos ir koreliacijos koeficientus. Šiuo atveju determinacijos koeficientas  $r^2 = 0,4$ , vadinasi 2 eilės polinominis trendas nėra tinkamas duomenų aproksimacijai. Koreliacijos koeficientas  $r = 0,632$  parodo nelabai stiprią koreliacinę priklausomybę tarp laiko ir konteinerių skaičiaus. Polinominio trendo grafikas pateikiamas 2.6 pav.




**2.6 pav. Antros eilės polinominio trendo prognozės**

Taikydami trečios eilės trendą gauname, kad trečios eilės polinominio trendo lygtis:

$$\text{Konteinerių skaičius} = 0,041 * x^3 - 2,731 * x^2 + 47,21 * x - 7,839.$$

Šiuo atveju determinacijos koeficientas  $r^2 = 0,63$ , vadinasi 3 eilės polinominis trendas tinkamas duomenų aproksimacijai. Koreliacijos koeficientas  $r = 0,794$  parodo pakankamai stiprią koreliacinę priklausomybę tarp laiko ir konteinerių skaičiaus. Šiuo metodu skaičiuojant gauta prognozė 36 mėnesiui yra 65 konteineriai. Nuo tikros reikšmės konteinerių skaičiaus prognozė skiriasi 50 konteinerių (apytiksliai 43%), tačiau vertindami visą periodą iš grafiko matome, kad jis metodas yra tiksliausias lyginant su prieš tai nagrinėtais metodais.



2.7 pav. Trečios eilės polinominio trendo prognozės

### 2.3.2 KONTEINERIŲ SKAIČIAUS PROGNOZAVIMAS REMIANTIS REGRESINIŲ KREIVIŲ METODAIS ĮVERTINANT SEZONINIUS SVYRAVIMUS

Atsižvelgdami į taškų sklaidos diagramą (žr. 2.4 pav.) matome, kad duomenyse vyrauja sezoniniai svyravimai. Kadangi duomenų grafiko viršūnės išsidėsčiusios beveik pagal horizontalią liniją, tai laikome kad turime adityvųjį sezoniškumo modelį. Sezoniškumus vertinsime kas 7,6 periodus ir kas ketvirtį. Pasinaudodami programine įranga suskaičiuojame autokoreliacinės funkcijos reikšmes esant skirtingiems postūmiams.

2.1 Lentelė

#### Autokoreliacijos funkcijos reikšmės

Postūmis	Koreliacijos koeficientas
1	0,618560
2	0,460415
3	0,486155
4	0,428906
5	0,256579
6	0,145796
7	0,105096

Kai koreliacijos koeficientas lygus 0,428906 tai duomenų postūmis atliekamas per keturis narius, matome, kad pokytis tarp metų ketvirčių yra ženklus. Kai atliekamas postūmis per 7 narius tai koreliacijos koeficientas lygus 0,105096 vadinasi pokytis nėra žymus. Didžiausias ryšys yra, kai duomenų potūmis atliekamas per vieną narį, koreliacijos koeficientas lygus 0,618560, vadinasi priklausomybė tarp gretimų narių stipri.

Laiko eilučių teorijoje sezoniškumai aprašomi įvairias sezoniškumo indeksais, kurie iš eilutės leidžia išskirti sezoniškumo komponente. Pasinaudodami programine įranga iš turimos eilutės išskiriame trendo, cikliškumo, sezoniškumos ir nereguliarą komponentes.

Laiko eilutės išskaidymas kai duomenų postūmis yra 4 į komponentes ir sezoniškumo indekso apskaičiavimas pateiktas lentelėje:

2.2 Lentelė

### Laiko eilutės išskaidymas

Menuo	Konteinerių skaičius	Judantys vidurkiai (moving average)	Skirtumai	Sezoniškumo koeficientai	Komponentė be sezoniškumo	Trendo komponentė	Nereguliaroji komponentė
1	66,0000			-34,3793	100,3793	83,4621	16,9172
2	120,0000			8,5269	111,4731	90,2694	21,2037
3	78,0000	102,5000	-24,5000	19,0443	58,9557	103,8840	-44,9282
4	146,0000	116,5000	29,5000	6,8082	139,1918	117,9102	21,2816
5	122,0000	114,0000	8,0000	-34,3793	156,3793	129,7088	26,6705
6	110,0000	138,7500	-28,7500	8,5269	101,4731	145,7192	-44,2461
7	177,0000	163,7500	13,2500	19,0443	157,9557	171,7729	-13,8171
8	246,0000	183,2500	62,7500	6,8082	239,1918	207,5769	31,6150
9	200,0000	224,0000	-24,0000	-34,3793	234,3793	243,4866	-9,1073
10	273,0000	265,2500	7,7500	8,5269	264,4731	265,6081	-1,1350
11	342,0000	266,2500	75,7500	19,0443	322,9557	269,2173	53,7384
12	250,0000	258,7500	-8,7500	6,8082	243,1918	252,2435	-9,0517
13	170,0000	248,0000	-78,0000	-34,3793	204,3793	236,2644	-31,8850
14	230,0000	232,5000	-2,5000	8,5269	221,4731	224,0526	-2,5795
15	280,0000	216,2500	63,7500	19,0443	260,9557	221,2173	39,7384
16	185,0000	216,2500	-31,2500	6,8082	178,1918	209,2435	-31,0517
17	170,0000	210,0000	-40,0000	-34,3793	204,3793	208,2644	-3,8850
18	205,0000	207,5000	-2,5000	8,5269	196,4731	201,2748	-4,8017
19	270,0000	196,2500	73,7500	19,0443	250,9557	194,5506	56,4051
20	140,0000	178,7500	-38,7500	6,8082	133,1918	167,5769	-34,3850
21	100,0000	165,0000	-65,0000	-34,3793	134,3793	152,7088	-18,3295




22	150,0000	145,0000	5,0000	8,5269	141,4731	151,2748	-9,8017
23	190,0000	160,0000	30,0000	19,0443	170,9557	165,6617	5,2940
24	200,0000	170,0000	30,0000	6,8082	193,1918	170,9102	22,2816
25	140,0000	166,2500	-26,2500	-34,3793	174,3793	148,1533	26,2261
26	135,0000	123,5000	11,5000	8,5269	126,4731	109,6081	16,8650
27	19,0000	91,5000	-72,5000	19,0443	-0,0443	72,4395	-72,4838
28	72,0000	71,5000	0,5000	6,8082	65,1918	62,0213	3,1705
29	60,0000	51,7500	8,2500	-34,3793	94,3793	66,9310	27,4483
30	56,0000	75,2500	-19,2500	8,5269	47,4731	72,0526	-24,5795
31	113,0000	75,0000	38,0000	19,0443	93,9557	73,9951	19,9606
32	71,0000	68,0000	3,0000	6,8082	64,1918	80,6880	-16,4961
33	32,0000	97,5000	-65,5000	-34,3793	66,3793	88,2644	-21,8850
34	174,0000	84,5000	89,5000	8,5269	165,4731	98,3859	67,0872
35	61,0000	95,5000	-34,5000	19,0443	41,9557	105,2069	-63,2512
36	115,0000			6,8082	108,1918	108,6174	-0,4255

Laiko eilutės išskaidymas kai duomenų postūmis yra 7 komponentės ir sezoniškumo indekso apskaičiavimas pateiktas 2 priede.

Sezoniškumo indeksas parodo vidutinį duomenų nuokrypį nuo slenkamųjų vidurkių kreivės. Slenkamiesiems vidurkiams skaičiuoti naudotas pločio 4 suglodinimas. 36 mėnesio konteinerių skaičius pagal 3 eilės polinominio trendo lygtį priedėjus sezoniškumo koeficientą, yra:


$$\text{Konteinerių skaičius} = 0,041 * 36^3 - 2,731 * 36^2 + 47,21 * 36 - 7,839 + 6,8082 = 72$$

Nors prognozuojamoji reikšmė stipriai skiriasi nuo tikslios, tačiau įvertindami grafiškai matome, kad prognozės pakankamai tikslios. Šio trendo prognozė atrodo taip:



2.8 pav. 3 laispio polinominio trendo prognozė, kai sezoniškumo postūmis yra 4

Kai duomenų potūmis yra 7 gauname 2.9 pav. pavaizduotas prognozes. Nors 2.8 ir 2.9 pav. labai panašūs tačiau įvertinus prognozavimo paklaidas, gavau kad su postūmiu 4 prognozės yra tikslesnės.



2.9. pav. 3 laispnio polinominio trendo prognozė, kai sezoniškumo postūmis yra 7

### 2.3.3 KONTEINERIŲ SKAIČIAUS PROGNOZAVIMAS PAPRASTU IR SVERTINIŲ SLENKAMŲJŲ VIDURKIŲ BEI EKSPONENTINIO GLODINIMO METODAIS

Nors pritaikius 3 eilės polinominį trendą su sezoniškumais, gautos reikšmės yra pakankamai artimos faktui, tačiau ieškosime metodų, kuris dar geriau ( tiksliau) prognozuotų reikšmes.


Prognozę atliekame pločio lygaus 3 paprastuoju ir svertiniu slenkamųjų vidurkių metodais. Vadinasi tariame, kad prognozuojamą reikšmę geriausiai reprezentuojama trijų prieš tai stebėtų reikšmių aritmetiniu vidurkiu. Taikant svertinį metodą mažiausios paklaidos prognozės buvo kai svorius imame lygius 0.1, 0.7 ir 0.2. Toks svorių parinkimas rodo, kad didžiausią įtaka prognozei turi vidurinis dėmuo. Taikydami eksponentinio glodinimo metodą prognozuojame pasirinkdami  $\alpha=0.5$ . Šiais trimis metodais atliktų prognozių rezultatai pateikti lentelėje.

## 2.3 Lentelė

## Konteinerių skaičiaus prognozės rezultatai skaičiuojant išlyginimo metodais

	Tikras skaičius	Prognozė	Pokytis
Konterenerių skaičius	115		
Paprastasis slenkamųjų vidurkių metodas		89	23%
Svertinis slenkamųjų vidurkių metodas		137	-19%
Paprastasis eksponentinio glodinimo metodas, kai $\alpha=0.5$		101	12%

Matome, mažiausia paklaida gauta prognozuojant eksponentinio glodinimo metodu, kai glodinimo konstanta  $\alpha=0.5$ . Šios prognozės grafikas pateikiamas 2.10 pav, o kitų metodų grafikai pateikiami priede.




2.10 pav. Konteinerių skaičiaus prognozė paprastu eksponentinio glodinimo metodu

Taigi gavome, kad tiksliausiai konteinerių skaičių prognozuoja paprastas eksponentinio glodinimo ir 3 eilės polinominis trendas su sezoniškumais.

## 2.4 MUITINĖS IŠLAIDŲ PROGNOZĖ


Prognozavimui atlikti naudosimės duomenimis, esančiais 1 priede 1.1 lentelėje. Prognozavimas daromas 2009 metų gruodžio mėnesiui, o tikras skaičius imamas iš pradinių duomenų tuo pačiu laikotarpiu. Nagrinėsime plaukiančių konteinerių per muitinės postus išlaidas patiriamas muitinėje.

Muitinės kaštų taškų sklaidos diagrama 2.11 pav.




2.11 pav. Muitinės išlaidų taškų sklaidos diagrama

Taikydami regresinių kreivių metodus gauname prognozes, kurios pavaizduotos 2.12 pav. Iš grafiko matome, kad šie metodai nėra tinkami prognozuoti muitinės išlaidas, todėl jų plačiau nenagrinėjame.



2.12 pav. Muitinės išlaidų prognozių palyginimo grafikai

Ieškome kitų regresinių metodų. Taikome skirtingus polinominius trendus. Lygindami šiais metodais gautas prognozes 36 mėnesiui gauname, kad 4 laipsnio polinominis trendas nuo tikros reikšmės skiriasi - 81 %, o 2 laipsnio 89 %, tačiau įvertindami visą periodą (žr.2.13pav. ) matome, kad 4 laipsnio polinomas yra pakankamai tikslus.



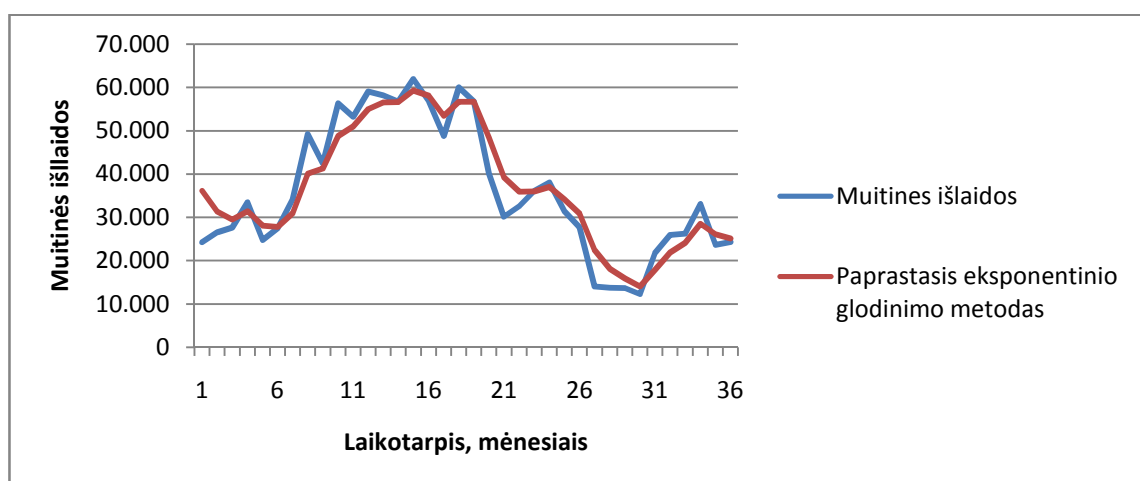
**2.13 pav. Muitinės išlaidų prognozės polinomiais trendais**

Ketvirto laipsnio polinominio trendo lygtis:

$$\text{Muitinės išlaidos} = 0,712x^4 - 42,39x^3 + 616,8x^2 + 193,1x + 21459$$

Determinacijos koeficientas lygus 0,842 vadinasi šis būdas yra tinkamas duomenų aproksimacijai. Koreliacijos koeficientas lygus 0,91 todėl turime stiprią koreliacinę priklausomybę nuo laiko.

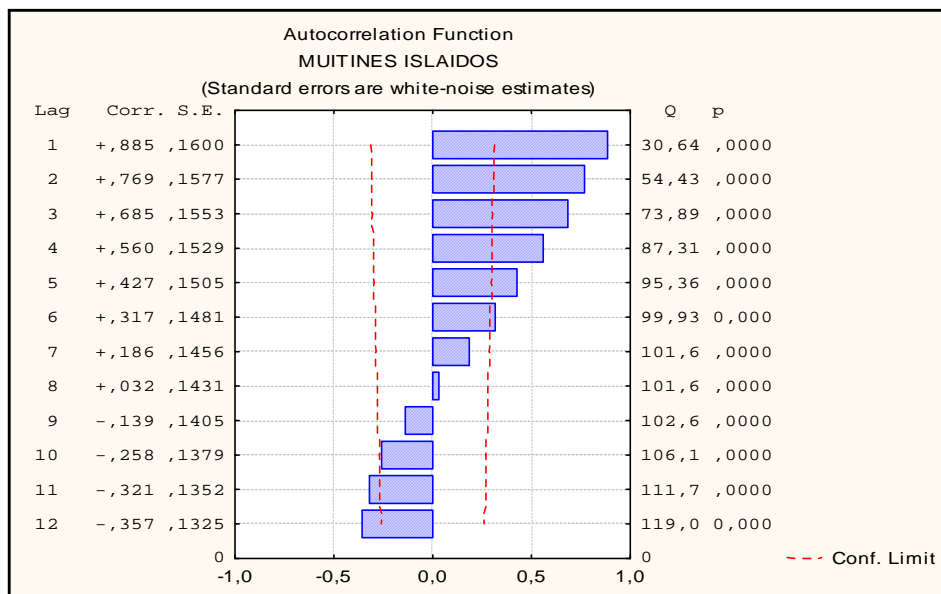
Atliekame muitinės išlaidų prognozę pagal slenkamųjų ir svertinių vidurkių, eksponentinio glodinimo metodus. Tiksliausiai iš šių metodų prognozuoja eksponentinis glodinimo metodas su  $\alpha = 0.5$ . Grafiniai prognozės vaizdas 2.14 pav., kitų metodų grafikai pateikti 3 priede.



**2.14 pav. Muitinės išlaidų prognozė eksponentinio glodinimo metodu**

Prognozuojant autoregresiniu metodu reikšmingiausia prognozuojamos reikšmės laiko momentu

t autokoreliacinė priklausomybė nuo reikšmių, gautų laiko momentais t-1 ir t-2.




**2.15 pav. Autokoreliacijos funkcija**

Autokoreliacijos grafikas pateiktas 2.15 pav. todėl todėl autoregresijos lygtis atrodo taip:

$$\bar{y}_t = 4169,20 + 0,893 * y_{t-1} - 0,008 * y_{t-2}$$

Taikant autoregresinį modelį, gautos prognozės kreivė pavaizduota 2.16 pav. 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. Šios prielaidos tikrinimo rezultatai pateikti 3 priede. Iš rezultatų gavome, kad prielaida priimtina.




**2.16 pav. Prognozės autoregresiniu metodu rezultatai**

Apibendrinant gautus rezultatus matome, kad geriausia muitinės išlaidas prognozuoti autoregresiniu ir 4 laipsnio polinominiu trendu.

## 2.5 TRANSPORTO KAŠTŲ PROGNOZAVIMAS

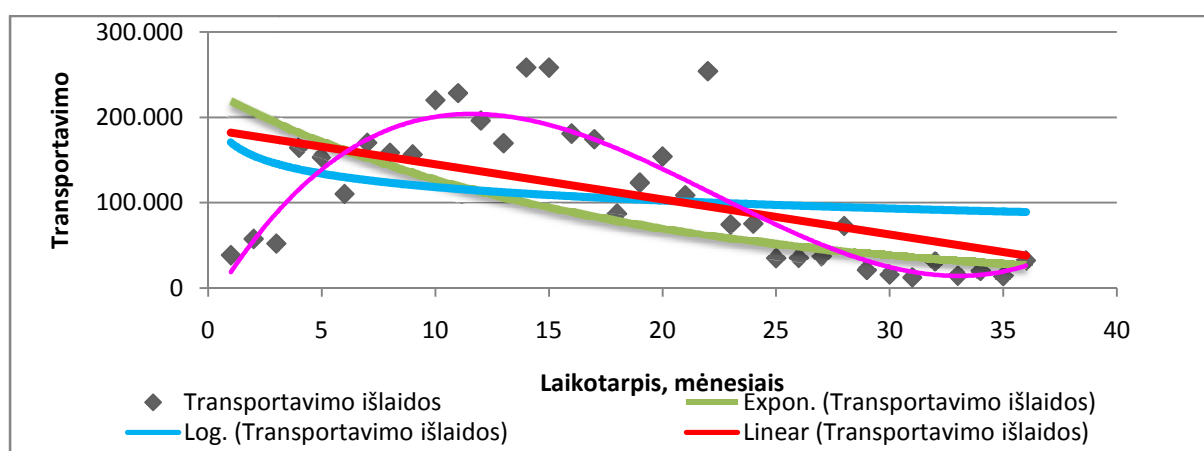
Įmonei X taip pat labai svarbu kiek ji išleidžia pinigų krovinių transportavimui, kuris vyksta tiek į gamyklą tiek ir iš jos. Prognozes atliksime laiko atžvilgiu tam, kad matytūsi kaip kito išlaidos nagrinėjamu periodu. Transportavimo išlaidų taškų sklaidos diagrama matoma 2.17 pav.



2.17 pav. Transportavimo kaštų taškų sklaidos diagrama

### 2.5.1 TRANSPORTO IŠLAIDŲ PROGNOZĖ REGRESINIŲ KREIVIŲ METODAIS

Pasinaudodami programine įranga kai kuriuos metodus prognozuojame grafiniu būdu:



2.18 pav. Transporto išlaidų prognozių palyginimo grafikai


Taikydami trendus ir trendus su seziniškumais gauname rezultatus pateiktus 2.4 lentelėje.

## 2.4 Lentelė

## Trendų su sezoniškumais prognozavimo rezultatai

	Transportavimo išlaidos	
Transportavimo išlaidos	32.341	
Polinominis 3 laispnio trendas	26.662	18%
Tiesinis trendas adi.	8.890	73%
Polinominis 3 laispnio trendas adi.	-2.584	108%
Logaritminis trendas adi.	59.807	-85%
Ekspontentinis trendas adit.	-2.458	108%

Skaičiuodami sezoniškumus taikėme adityvinį metodą, o multiplikatyviniu metodu atliktų prognozių rezultatai pateikti 4 priede. Kaip matome iš 1.4 lentelės mažiausia paklaida lyginant 36 mėnesio rezultatus yra taikant 3 laispnio polinominį trendus be senoniškumų, tačiau atsižvelgdami į visą periodą iš 2.19 pav. matome, kad tikslesnis yra 3 laispnio poninominis trendas su sezoniškumais (senoniškumo duomenų postūmis yra 6).



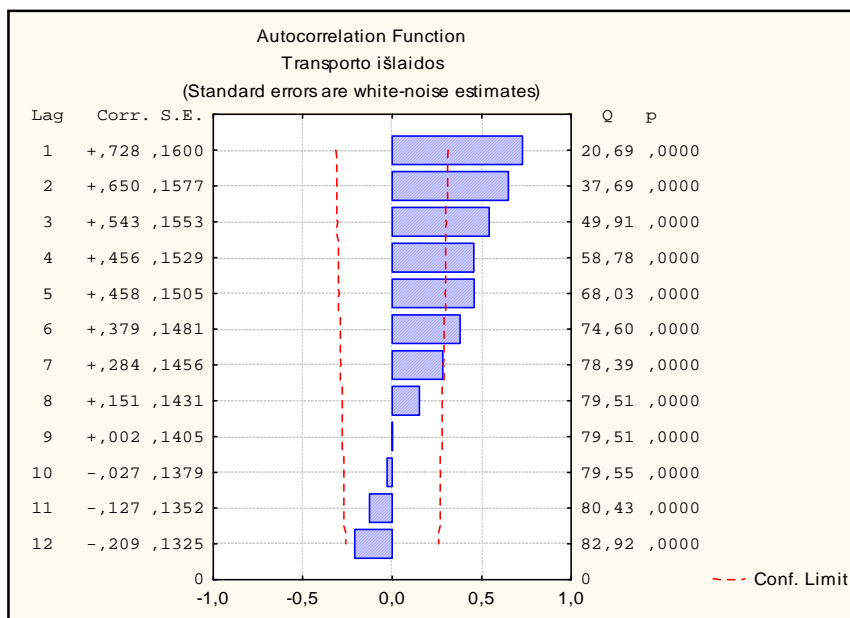
2.19 pav. Transporto išlaidų prognozė polinomiais trendais

Prognozuojant išlyginimo metodais gautos reikšmės yra su nemažomis paklaidomis lyginant su faktu, prognozavimo rezultatai pateikti priede. Todėl taikome kitus metodus.



## 2.5.2 TRANSPORTO IŠLAIDŲ PROGNOZĖ AUTOREGRESINIŲ METODŲ

Taikykime autoregresinį metodą. Pirmiausia nustatome, nuo kurių praeities duomenų yra didžiausia laiko eilutės priklausomybė.



2.20 pav. Transporto išlaidų autokoreliacijos funkcija


Reiškmingiausia prognozuojamos reikšmės autokoreliacinė priklausomybė laiko momentu  $t$  nuo reikšmių, gautų laiko momentais  $t-1$  ir  $t-2$ . Vadinasi esant pirmam ir antram postūmiams gaunamos didžiausios koreliacinės funkcijos reikšmės. Autokoreliacinės funkcijos grafikas pateiktas 2.20 pav. O prognozės lygtį galime užrašyti taip:

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

Pasinaudodami programine įranga surandame koeficientus  $b_0$ ,  $b_1$ ,  $b_2$ . Gautus rezultatus surašome į lygtį. Taigi prognozuojant 36 mėnesio išlaidas reikia 35 ir 34 mėnesio reikšmes surašyti į lygtį. Gauname tokį rezultatą:

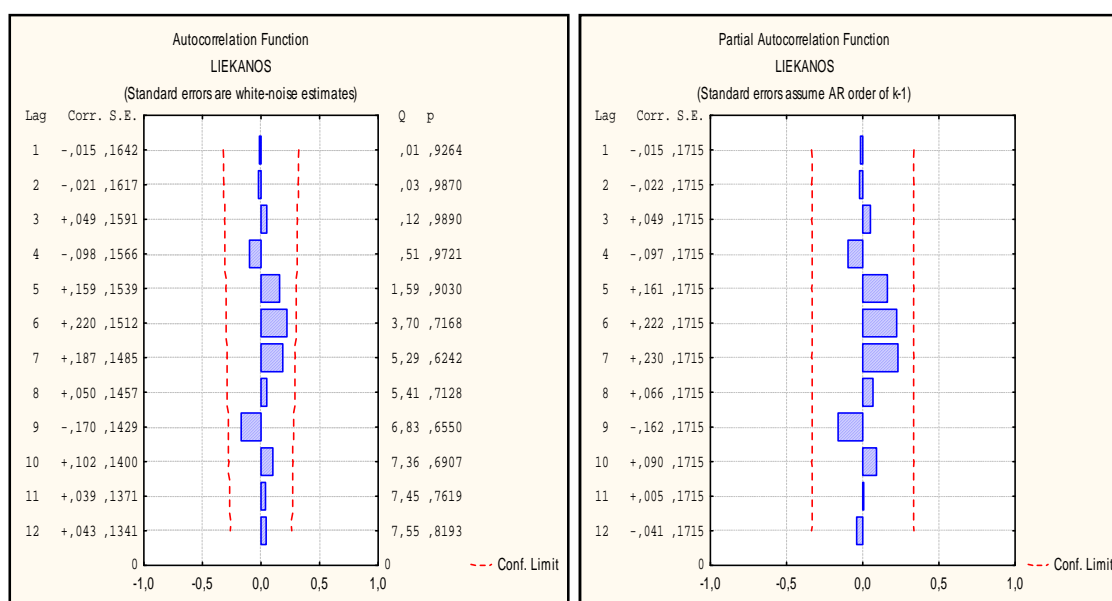
$$\hat{y}_t = 18347,39 + 0,5234 * 13818 + 0,307 * 19951 = 31705$$

Taikant autoregresinį modelį gautos prognozės kreivė pavaizduota 2.21 pav.



**2.21 pav. Transporto išlaidų prognozė autoregresiniu metodu**

Aprašyto modelio liekanų eilutės autokoreliacijos ir dalinės autokoreliacijos funkcijos neturi reikšmingai skirtis nuo nulio ir liekanų reikmės turi būti atsitiktinės. Ši prielaida tikrinama taikant Box – Ljung kriterijų.



**2.22 pav. Liekamų autokoreliacijos ir dalinės autokoreliacijos funkcijos**

Kaip matyti iš 2.22 pav funkcijų reikšmės pasiskirsčiusios atsitiktinai, o iš 2.5 lentelės, kad Box – Ljung kriterijus yra statistiškai nereišmingas visiems postūmiams. Todėl autoregresinį modelį galime laikyti priimtinu.

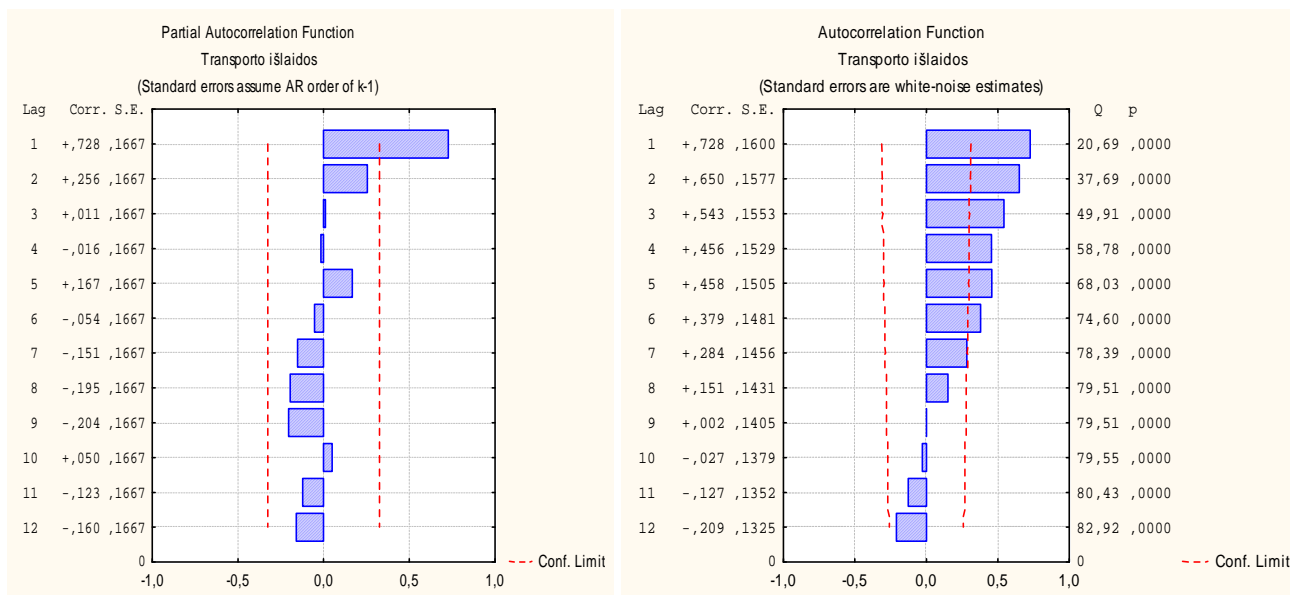
## 2.5 Lentelė

## Baltojo triukšmo hipotezės tikrinimas liekanoms:

BOX & LJUNG	P
0,008542	0,926361
0,026071	0,987049
0,122172	0,989050
0,513760	0,972147
1,585849	0,902951
3,703048	0,716786
5,293182	0,624236
5,411887	0,712776
6,828554	0,654962
7,363815	0,690703
7,446065	0,761881
7,549108	0,819279

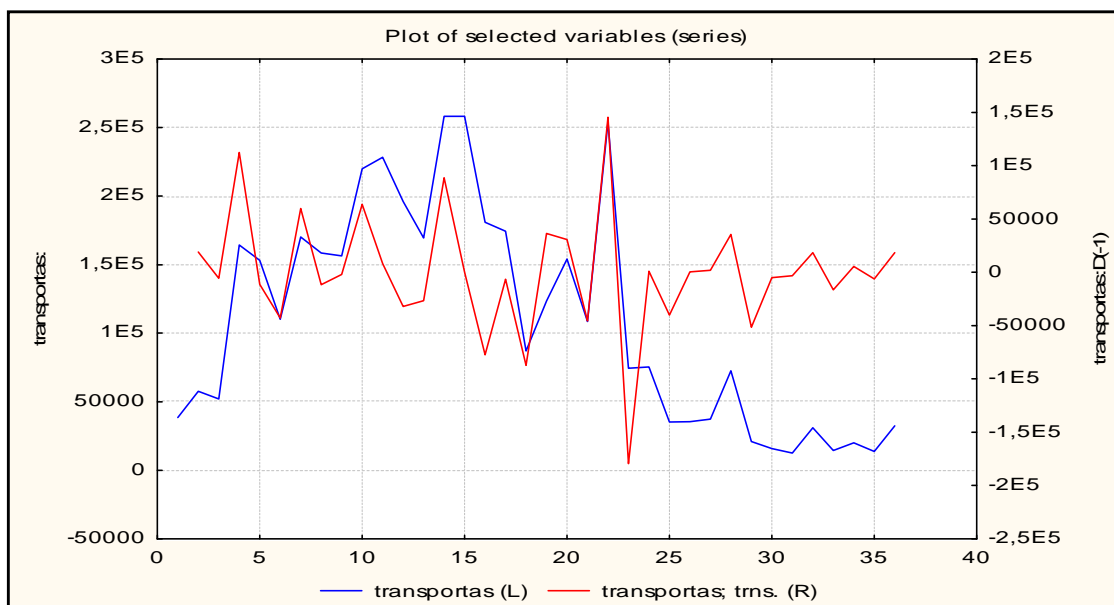
## 2.5.3 TRANSPORTO IŠLAIDŲ PROGNOZĖ TAIKANT ARIMA MODELĮ

Taikydami ARIMA modelį pirmaisia turime nustatyti parametrų p ir q reikšmes. Jie parenkami pasinaudojant autokoreliacijos ir dalinės autokoreliacijos funkcijomis.

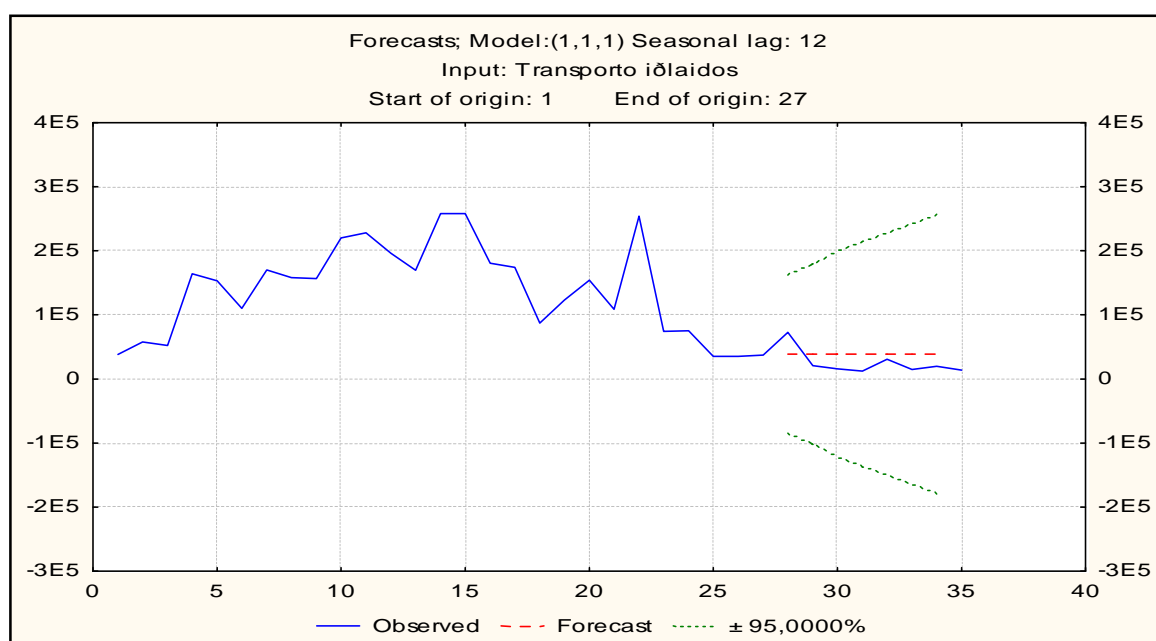


2.23 pav. Transporto išlaidų autokoreliacijos ir dalinės autokoreliacijos funkcijos

ARIMA modelis reikalauja, kad procesas būtų stacionarus, todėl pradinis duomenis diferencijuojame.

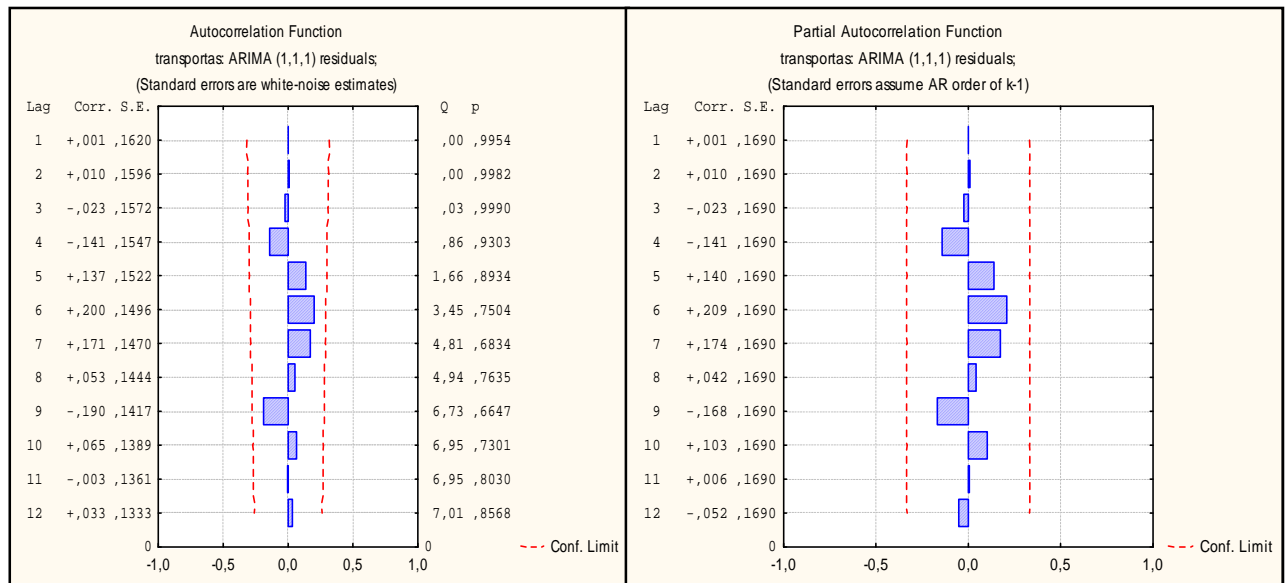


2.24 pav. Diferencijuota transporto išlaidų seka



2.25 pav. Prognozuotos reikšmės pagal ARIMA(1,1,1)

Tiksliausios prognozavimo reikšmės gautos taikant ARIMA(1,1,1) modelį. Šio modelio liekanų eilutės neturi reišmingai skirtis nuo nulio ir turi būti atsitiktinės, todėl šia prielaidą tikriname pritaikę Box-Ljung kriterijų.



**2.26 pav. ARIMA(1,1,1) liekanų autokoreliacijos ir dalinės autokorelaicijos funkcijos**

Iš grafikų matome, kad modelį galime laikyti priimtinu.


**2.6Lentelė**

### Baltojo triukšmo hipotezės tikrinimas liekanoms

BOX & LJUNG	P
0,000033	0,995399
0,003654	0,998175
0,025025	0,998955
0,859564	0,930287
1,664150	0,893381
3,451499	0,750407
4,808211	0,683353
4,944790	0,763452
6,734682	0,664718
6,950921	0,730059
6,951545	0,802976
7,012052	0,856794

## 2.5.4 TRANSPORTO IŠLAIDŲ PRGNOZAVIMAS SARIMA MODELIU

Iš 2.25 pav. matome, kad prognozės nėra labai tikslios, todėl taikome SARIMA metodą. Vadinasi ARIMA (1,1,1) modeliui pritaikome sezoninius svyravimus. Mažiausią paklaidą taikant SARIMA (1,1,1)(0,0,1). Šis metodas tinkamas taikyti, nes jo liekanos yra atsitiktinės. Modelio tinkamumo tikrinimas pateiktas 4 priede. Prognozė atlikta kai senoninis postūmis yra 7.



2.27 pav. SARIMA modelio prognozės rezultatai

## IŠVADOS

Konteinerių skaičiaus prognozę tiksliausiai atlikti taikant paprastas eksponentinio glodinimo metodą. Šiek tiek didesnės paklaidos gaunamos taikant 3 eilės polinominį trendą su sezoniškumais.

Prognozuojant muitinės išlaidas mažiausios paklaidos gaunamos taikant 4 laispnio polinominį trendą.

Transpoto išlaidų prognozė tiksliausia prognozuojant SARIMA(1,1,1)(0,0,1) ir polinominiu trečios eilės trendą su sezoniškumais.

## LITERATŪRA

1. Liudmila Braškienė. Logistika. Paskaitų konspektas. Vilnius, 2009 63 p.
2. Minalga R. Logistika. Vilnius, 2001, p. 383p.
3. Sakalauskas V. Statistika su statistika. Vilnius, 1998 , 228p
4. Murauskas G. Statistika ir jos taikymai. Vilnius, 2003 - 2004, 272p.
5. M. Kavaliauskas, R. Rudzkis Laiko eilučių analizė. Paskaitų konspektas. Kaunas 2009, 25p.
6. Peter J. Brockwell Richard A. Davis Introduction to time series and forecasting. 2001 449p
7. Ghiani G., Laporte G., Musmanno R. Introduction to logistics systems planning and control. Chichester : John Wiley & Sons, 2004, 352p.



# 1 PRIEDAS. PRADINIAI DUOMENYS

## 1.1 Lentelė

Pradinių duomenų lentelė


Metai	Mėnesis	Konterinerių skaičius	Muitines išlaidos	Transportavimo išlaidos	Bendros išlaidos
2007-01	1	66	24.256	38.474	62.730
2007-02	2	120	26.520	57.567	84.087
2007-03	3	78	27.628	52.043	79.671
2007-04	4	146	33.434	164.343	197.777
2007-05	5	122	24.766	153.122	177.888
2007-06	6	110	27.450	110.229	137.679
2007-07	7	177	34.161	170.159	204.320
2007-08	8	246	49.200	158.461	207.661
2007-09	9	200	42.400	156.435	198.835
2007-10	10	273	56.238	220.071	276.309
2007-11	11	342	53.188	228.274	281.462
2007-12	12	250	59.000	196.130	255.130
2008-01	13	170	58.080	169.604	227.684
2008-02	14	230	56.690	258.207	314.897
2008-03	15	280	61.880	258.157	320.037
2008-04	16	185	56.815	180.820	237.635
2008-05	17	170	48.760	174.278	223.038
2008-06	18	205	59.975	87.046	147.021
2008-07	19	270	56.700	123.401	180.101
2008-08	20	140	40.100	154.028	194.128
2008-09	21	100	30.100	108.584	138.684
2008-10	22	150	32.550	253.955	286.505
2008-11	23	190	36.100	74.434	110.534
2008-12	24	200	38.000	75.320	113.320
2009-01	25	140	31.360	35.110	66.470
2009-02	26	135	27.675	35.378	63.053
2009-03	27	19	14.009	37.230	51.239
2009-04	28	72	13.752	72.644	86.396
2009-05	29	60	13.680	20.984	34.664
2009-06	30	56	12.264	15.779	28.043
2009-07	31	113	21.809	12.432	34.241
2009-08	32	71	25.904	30.944	56.848
2009-09	33	32	26.240	14.506	40.746
2009-10	34	174	33.060	19.951	53.011
2009-11	35	61	23.603	13.818	37.421
2009-12	36	115	24.265	32.341	56.606

## 2 PRIEDAS. KONTEINERIŲ SKAIČIAUS PROGNOZAVIMO REZULTATAI

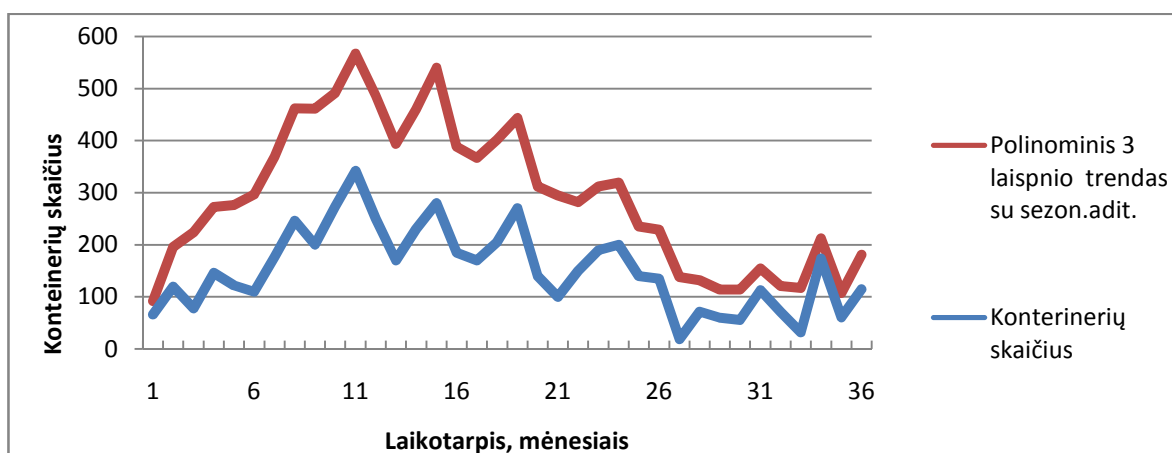
### 2.1 Lentelė

#### Laiko eilutės išskaidymas, kai senoniškumo postūmis

Mėnuo	Konteinerių skaičius	Judantys vidurkiai	Skirtumai	Sezoniškumo koeficientai	Komponentė be sezoniškumo	Trendo komponentė	Nereguliaroji komponentė
1	66,0000			19,0571	46,9429	67,6012	-20,6583
2	120,0000			-3,9786	123,9786	74,6452	49,3333
3	78,0000			24,9857	53,0143	88,7333	-35,7190
4	146,0000	117,0000	29,0000	29,9143	116,0857	107,7619	8,3238
5	122,0000	142,7143	-20,7143	9,5143	112,4857	128,4175	-15,9317
6	110,0000	154,1429	-44,1429	-56,6214	166,6214	163,0675	3,5540
7	177,0000	182,0000	-5,0000	-22,8714	199,8714	189,2452	10,6262
8	246,0000	210,0000	36,0000	19,0571	226,9429	211,4627	15,4802
9	200,0000	228,2857	-28,2857	-3,9786	203,9786	230,4230	-26,4444
10	273,0000	236,8571	36,1429	24,9857	248,0143	249,2889	-1,2746
11	342,0000	244,4286	97,5714	29,9143	312,0857	260,4286	51,6571
12	250,0000	249,2857	0,7143	9,5143	240,4857	255,5286	-15,0429
13	170,0000	247,1429	-77,1429	-56,6214	226,6214	248,8452	-22,2238
14	230,0000	232,4286	-2,4286	-22,8714	252,8714	240,3563	12,5151
15	280,0000	212,8571	67,1429	19,0571	260,9429	226,4627	34,4802
16	185,0000	215,7143	-30,7143	-3,9786	188,9786	200,7563	-11,7778
17	170,0000	211,4286	-41,4286	24,9857	145,0143	187,1778	-42,1635
18	205,0000	192,8571	12,1429	29,9143	175,0857	191,3175	-16,2317
19	270,0000	174,2857	95,7143	9,5143	260,4857	199,1952	61,2905
20	140,0000	175,0000	-35,0000	-56,6214	196,6214	184,7341	11,8873
21	100,0000	179,2857	-79,2857	-22,8714	122,8714	164,2452	-41,3738
22	150,0000	170,0000	-20,0000	19,0571	130,9429	155,3516	-24,4087
23	190,0000	150,7143	39,2857	-3,9786	193,9786	158,5341	35,4444
24	200,0000	133,4286	66,5714	24,9857	175,0143	154,4000	20,6143
25	140,0000	129,4286	10,5714	29,9143	110,0857	133,4286	-23,3429
26	135,0000	116,5714	18,4286	9,5143	125,4857	113,0841	12,4016
27	19,0000	97,4286	-78,4286	-56,6214	75,6214	90,9563	-15,3349
28	72,0000	85,0000	-13,0000	-22,8714	94,8714	78,1341	16,7373
29	60,0000	75,1429	-15,1429	19,0571	40,9429	66,2405	-25,2976
30	56,0000	60,4286	-4,4286	-3,9786	59,9786	63,7563	-3,7778
31	113,0000	82,5714	30,4286	24,9857	88,0143	58,8444	29,1698
32	71,0000	81,0000	-10,0000	29,9143	41,0857	70,5397	-29,4540
33	32,0000	88,8571	-56,8571	9,5143	22,4857	86,9730	-64,4873
34	174,0000			-56,6214	230,6214	115,7341	114,8873
35	61,0000			-22,8714	83,8714	136,8119	-52,9405
36	115,0000			19,0571	95,9429	147,3508	-51,4079




2.1 pav. Trendų su senoniškumais taikant adityvinį modelį prognozės rezultatai




2.2 3 laispio polinominio trendo prognozė, kai sezoniškumo postūmis yra 6

### 3 PRIEDAS. MUITINĖS IŠLAIDŲ PROGNOZĖS REZULTATAI

Parinkti svoriai 0,4 0,5 0,1

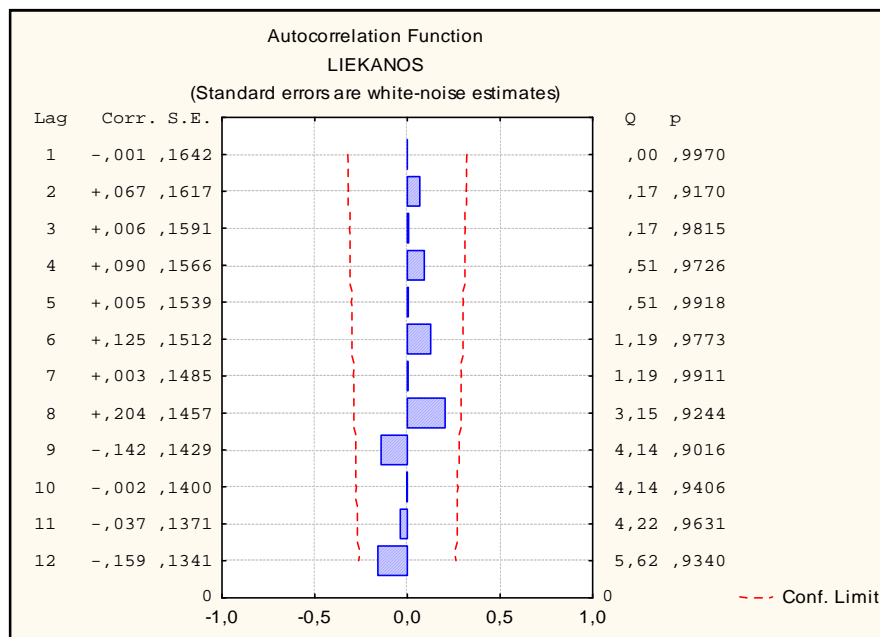


3.1pav. Prognozės svertiniu slenkamųjų vidurkių metodu rezultatas




3.2 pav. Prognozės paprastu slenkamųjų vidurkių metodu rezultatas

Prielaidos, kad liekanos atsitiktinės rezultatai:



**3.3 pav. Autoregresinio modelio liekanų autokoreliacijos funkcija**



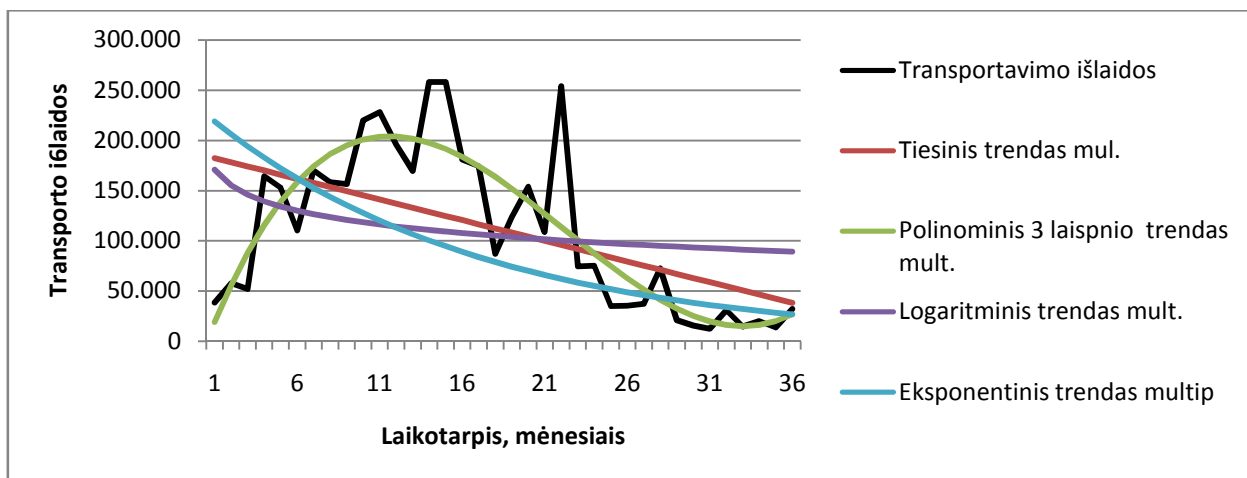
**3.4 pav. Autoregresinio modelio liekanų dalinės autokoreliacijos funkcija**

## 3.1 Lentelė


## Baltojo triukšmo hipotezės tikrinimas liekanoms

Box & Ljung	p
0,000014	0,997013
0,173327	0,916986
0,174860	0,981542
0,508839	0,972634
0,509743	0,991761
1,191916	0,977280
1,192214	0,991103
3,153052	0,924379
4,144795	0,901614
4,144958	0,940559
4,219102	0,963053
5,620822	0,933961

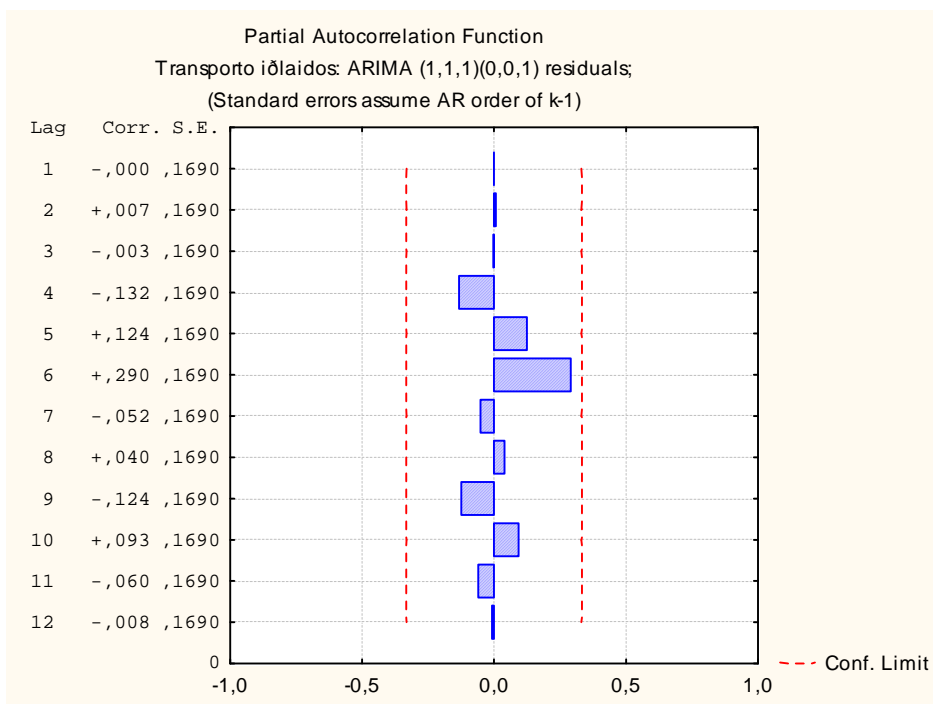
## 4 PRIEDAS. TRANSPORTO IŠLAIDŲ PROGNOZĖS REZULTATAI



4.1 pav. Transporto išlaidų prognozės rezultatai pritaikius sezoniškumus ir multiplikatyvinį metodą



**4.2 pav. SARIMA metodo liekanų autokoreliacinė funkcija**



**4.3 pav. SARIMA metodo liekanų dalinės autokoreliacijos funkcija**

## 4.1 Lentelē

**Baltojo triukšmo hipotezēs tikrinimas liekanoms**

BOX & LJUNG	P
0,000000	0,999631
0,001975	0,999013
0,002290	0,999971
0,728890	0,947717
1,371329	0,927420
4,893699	0,557527
4,984207	0,661890
5,209041	0,735011
6,313942	0,708126
6,348875	0,785136
6,372680	0,847358
6,508528	0,888292