



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

**Lina Žalgirytė**

**DAUGELIO RIZIKŲ PASĖLIŲ DRAUDIMO**  
**NUOSTOLINGUMO ANALIZĖ**

Magistro darbas

**Vadovas**  
**doc. dr. G. Račkauskas**

**KAUNAS, 2010**



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

**TVIRTINU**  
**Katedros vedėjas**  
**doc. dr. N.Listopadskis**  
**2010 06 05**

**DAUGELIO RIZIKŲ PASĖLIŲ DRAUDIMO**  
**NUOSTOLINGUMO ANALIZĖ**

Taikomosios matematikos magistro baigiamasis darbas

**Vadovas**  
**doc. dr. G. Račkauskas**  
**2010 06 03**

**Recenzentas**  
**A. Navickas**  
**2010 06 01**

**Atliko**  
**FMMM 8 gr. stud.**  
**L. Žalgirytė**  
**2010 05 25**

**KAUNAS, 2010**

## **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“)

**Žalgirytė L. Analysis of multi peril crop insurance loss ratios : Master's work in applied mathematics / supervisor dr. assoc. prof. G. Račkauskas; Department of Applied Mathematics, Faculty of Fundamental Sciences, Kaunas University of Technology – Kaunas, 2010. – 106 p.**

## **SUMMARY**

In the first part of this work, I tested if there is a relationship between weather conditions and crop insurance loss ratios. I tested two models. The first model was used to test the linear relationship between crop insurance loss ratios and weather conditions. Results show that this model does not satisfy the multiple regression model assumption about constant variance of residuals. In the second model the dependent variable – loss ratio – was transformed using power transformation. Then the linear relationship between transformed crop insurance loss ratios and weather conditions was tested. Results suggest that this dependency is weak. It shows that crop insurance loss ratios are affected not only by weather conditions but also by other factors.

In the second part, I analyzed the distribution of loss ratios for five crops. I tested three probability distributions: gamma, log-normal and shifted Pareto. Shifted and truncated gamma, truncated gamma and truncated log-normal distribution did not fit according to the distribution of data. The results show that the truncated shifted Pareto distribution can be used for insurance loss ratio approximation.

In the third part, I analyzed the intensity of indemnities and indemnity amount for one hectare. Analysis shows that there is no actual trend in average indemnity amount and average intensity for 2000 – 2005. There is no trend in standard deviation of intensity for 1995 – 2005. The results also show that there is no linear relationship between indemnity amount for one hectare and intensity of indemnities.

## SANTRAUKA

Pirmoje šio darbo dalyje tikrinau ar yra priklausomybė tarp oro sąlygų ir draudimo nuostolingumo. Tirti du modeliai. Viename tirta tiesinė priklausomybė tarp draudimo nuostolingumo ir oro sąlygų. Gauta, kad modelis netenkina daugialypės regresijos prielaidos apie liekanų dispersijos pastovumą. Kitame modelyje priklausomas kintamasis – nuostolingumas – transformuotas panaudojant laipsninę transformaciją. Tuomet tirta priklausomybė tarp transformuoto nuostolingumo ir oro sąlygų. Gauti rezultatai rodo, kad ši priklausomybė silpna. Draudimo nuostolingumą įtakoja ne tik oro sąlygos, bet ir kiti faktoriai.

Antroje darbo dalyje tyriau penkių pasėlių kultūrų nuostolingumo pasiskirstymą ir sprendžiau aproksimavimo uždavinį. Tikrinau tris pasiskirstymo dėsnius: gama, log-normalųjį ir pastumtą Pareto pasiskirstymą. Nupjautas pastumtas gama, nupjautas gama ir nupjautas log-normalusis skirstinys neatitiko duomenų pasiskirstymo. Gauta, kad duomenų aproksimavimui geriausiai tinka nupjautas pastumtas Pareto skirstinys.

Trečioje darbo dalyje tyriau žalų intensyvumo ir žalos dydį vienam hektarui. Tyrimas rodo, kad nėra aiškios vidutinio intensyvumo ir vidutinės žalos kitimo tendencijos 2000 – 2005 metais. Taip pat nėra aiškios tendencijos intensyvumo standartinio nuokrypio kitime 1995 – 2005 metais. Vieno kintamojo regresinės analizės rezultatai rodo, kad nėra tiesinės priklausomybės tarp žalos dydžio vienam hektarui ir žalos intensyvumo.

## TURINYS

ĮVADAS .....	9
1. TEORINĖ DALIS .....	10
1.1. KORELIACINĖ ANALIZĖ .....	10
1.2. VIENO KINTAMOJO TIESINĖ REGRESIJA.....	10
1.3. DAUGIALYPĖ TIESINĖ REGRESIJA .....	11
1.3.1. KLASIKINIS DAUGIALYPĖS TIESINĖS REGRESIJOS MODELIS .....	11
1.3.2. MAŽIAUSIŲ KVADRATŲ METODAS .....	12
1.3.3. REGRESIJA SU APRIBOJIMAIS .....	13
1.3.4. FIKTYVŪS KINTAMIEJI.....	14
1.3.5. KORELIACIJOS IR APIBRĖŽTUMO KOEFICIENTAS .....	14
1.3.6. REGRESIJOS MODELIO KOEFICIENTŲ REIKŠMINGUMAS.....	15
1.3.7. LIEKANŲ GRAFIKO ANALIZĖ .....	16
1.4. SKIRSTINIO PARAMETRŲ ĮVERTINIMAS. MOMENTŲ METODAS .....	17
2. TIRIAMOJI DALIS IR REZULTATAI.....	18
2.1. DAUGELIO RIZIKŲ PASĖLIŲ DRAUDIMO NUOSTOLINGUMO PRIKLAUSOMYBĖ NUO ORO SĄLYGŲ .....	18
2.2. DRPD NUOSTOLINGUMO APROKSIMAVIMAS PASIRINKTAIS SKIRSTINIAIS.....	28
2.3. DRPD ŽALOS DYDŽIO IR INTENSYVUMO TYRIMAS .....	37
3. PROGRAMINĖ REALIZACIJA IR INSTRUKCIJA VARTOTOJUI .....	42
DISKUSIJOS .....	44
IŠVADOS .....	45
REKOMENDACIJOS .....	46
LITERATŪRA.....	47
PADĖKOS .....	48
PRIEDAI.....	49
1 PRIEDAS. TRŪKSTAMŲ DUOMENŲ REIKŠMIŲ UŽPILDYMAS.....	49
2 PRIEDAS. DUOMENŲ PAVYZDYS .....	52
3 PRIEDAS. JAV PLATINAMI DRAUDIMO PLANAI .....	53
4 PRIEDAS. REGRESIJOS REZULTATAI .....	55
5 PRIEDAS. SAS PROGRAMŲ TEKSTAI.....	77
6 PRIEDAS. DUOMENŲ APROKSIMAVIMAS NUPJAUTU PASTUMTU PARETO SKIRSTINIU .....	91
7 PRIEDAS. MATLAB M RINKMENOS TEKSTAS .....	96
8 PRIEDAS. ŽALOS DYDŽIO 1 HA REGRESINĖ ANALIZĖ .....	102

## PAVEIKSLŲ SĄRAŠAS

1.1 pav. (a) liekanų dispersija pastovi; (b) – (d) nepastovi dispersija, priklausanti nuo abscisių ašyje žymimų dydžių; (e) – (f) netiesinis ryšys; (g) – (h) netiesinis ryšys ir nepastovi dispersija. ....	16
2.1 pav. Pasėlių draudimo polisų skaičius JAV pagal metus skirtingiems draudimo planams .....	19
2.2 pav. Tyrimo regionas .....	20
2.3 pav. DRPD polisų, kuriems fiksuota žala, skaičius pagal metus skirtingose JAV valstijose. ....	21
2.4 pav. Ne gyvybės draudimo rinkos palyginimas pagal pasirašytas įmokas 2005 metais .....	22
2.5 pav. Vidutinių metinių temperatūrų palyginimas Lietuvoje (a) ir rytinėje Šiaurės Dakotos valstijos dalyje (b) .....	22
2.6 pav. Vidutinio metinio kritulių kiekio palyginimas Lietuvoje (a) ir rytinėje Šiaurės Dakotos valstijos dalyje (b) .....	23
2.7 pav. Kviečių DRPD nuostolingumo modelio normuotų liekanų grafikas .....	25
2.8 pav. Transformuoto kviečių nuostolingumo modelio normuotų liekanų grafikas .....	26
2.9 pav. Miežių, kviečių, rapsų, bulvių ir cukrinių runkelių DRPD nuostolingumo histogramos.....	29
2.10 pav. Duomenų, log-normaliojo ir pastumto gama ir gama pasiskirstymo tankio grafikai. ....	30
2.11 pav. Kviečių nuostolingumo aproksimavimo nupjautu pastumtu Pareto skirstiniu paklaidų paviršius .....	36
2.12 pav. Kviečių DRPD nuostolingumo ir nupjauto pastumto Pareto atsitiktinių dydžių histogramų ir pasiskirstymo funkcijų grafikai.....	37
2.13 pav. Miežių, kviečių, rapsų, bulvių ir cukrinių runkelių žalų intensyvumo histogramos.....	39
2.14 pav. Miežių modelio normuotų liekanų grafikas.....	40
2.15 pav. Žalos dydžio 1 ha ir žalų intensyvumo vidurkio bei standartinio nuokrypio kitimas .....	41
3.1 pav. Programos langas .....	43

## LENTELIŲ SĄRAŠAS

2.1 lentelė. Šiaurės Dakotos valstijos pasėlių draudimas pasirinktoms kultūroms 2001 – 2005 metais	20
2.2 lentelė. Draudimo grupės pagal pasirašytas įmokas, 2005 m. ....	21
2.3 lentelė. DRPD nuostolingumo transformacijos koeficientai.....	25
2.4 lentelė. Transformuoto kviečių nuostolingumo modelio dispersinės analizės rezultatai .....	26
2.5 lentelė. Hipotezės apie liekanų vidurkio lygybę 0 tikrinimo rezultatai .....	27
2.6 lentelė. Hipotezės apie liekanų pasiskirstymo normalumą tikrinimo rezultatai.....	27
2.7 lentelė. DRPD nuostolingumo modelio apibrėžtumo koeficientai.....	27
2.8 lentelė. DRPD nuostolingumo empirinės charakteristikos .....	28
2.9 lentelė. Perskaičiuotos DRPD nuostolingumo empirinės charakteristikos.....	29
2.10 lentelė. Nupjauto pastumto Pareto skirstinio charakteristikos .....	36
2.11 lentelė. Aproximavimo paklaidos .....	37
2.12 lentelė. Žalų intensyvumo ir žalos dydžio 1 ha charakteristikos.....	38
2.13 lentelė. Spirmeno koreliacijos tarp žalos dydžio 1 ha ir žalų intensyvumo koeficientai.....	40



## IVADAS

Pasėlių draudimas – vienas populiariausių rizikos, susijusios su klimatinėmis ar ekonominėmis sąlygomis, valdymo būdų. Draudimo programos ir draudžiamos pasėlių kultūros įvairiose šalyse skiriasi, priklausimai nuo valstybės pasirinktos žemės ūkio politikos strategijos, auginamų pasėlių kultūrų ir klimatinė sąlygų. Šiame darbe nagrinėtas daugelio rizikų pasėlių draudimas viename JAV regione, kuris savo plotu artimas Lietuvai.

Literatūroje plačiai aprašomas klimato kaitos poveikis derlingumui ir žemės ūkio produkcijai. Be to tyrimai rodo, kad yra stiprus ryšys tarp pasėlių derlingumo ir draudimo nuostolingumo. JAV atlikto tyrimo rezultatai rodo, kad kai kurių pasėlių kultūrų draudimo nuostolingumas priklauso nuo kritulių kiekio ir aukštos oro temperatūros. Dėl šių priežasčių vienoje darbo dalyje buvo pasirinkta patikrinti, ar yra tiesinė priklausomybė tarp draudimo nuostolingumo ir oro sąlygų kitame tyrimo regione ir kitoms pasėlių kultūroms. Šiame tyrime taikoma daugialypė tiesinė regresija su apribojimais ir fiktyviais kintamaisiais. Gauti rezultatai rodo, kad tarp draudimo nuostolingumo ir oro sąlygų yra silpnas tiesinis ryšys. Draudimo nuostolingumą veikia ne tik oro sąlygos, bet ir kiti faktoriai.

Antroje darbo dalyje tiriamas penkių pasėlių kultūrų nuostolingumo pasiskirstymas ir sprendžiamas duomenų aproksimavimo uždavinys. Tikrinti trys pasiskirstymo dėsniai: gama, log-normalusis ir pastumtas Pareto pasiskirstymas. Pasinaudojus momentų metodo idėja, rasti skirstinių parametrai ir duomenų aproksimavimui parinktas nupjautas pastumtas Pareto skirstinys.

Trečioje dalyje tiriamas pasėlių draudimo žalų intensyvumas ir žalos dydis vienam hektarui. Buvo apskaičiuotos šių dydžių vidurkiai, standartiniai nuokrypiai, asimetriškumai. Taip pat tikrinta ar vidutiniam žalų intensyvumui ir vidutiniam žalos dydžiui galima nustatyti kitimo tendenciją. Pasinaudojus vieno kintamojo regresine analize, iširta ar yra tiesinė priklausomybė tarp žalos dydžio ir žalų intensyvumo.

## 1. TEORINĖ DALIS

### 1.1. KORELIACINĖ ANALIZĖ

Koreliacinėje analizėje statistinio ryšio stiprumas tarp stebėtų kintamųjų yra išreiškiamas koeficientu. Spirmeno ranginės koreliacijos koeficientas naudojamas ryšio stiprumui įvertinti tarp kintamųjų, išmatuotų santykių, intervalinėje ir tvarkos skalėse. Jis apibūdina ryšio tarp  $X$  ir  $Y$  stiprumą monotoniškumo prasme, t.y.  $X$  didėjant,  $Y$  monotoniškai didėja (nebūtinai tiesiškai) arba mažėja. Apskaičiuojant Spirmeno ranginį koeficientą naudojamos ne stebėtos  $(X, Y)$  reikšmės  $(x_i, y_i)$ ,  $i = \overline{1, n}$ , bet jų rangai  $(rx_i, ry_i)$ . Empirinį Spirmeno koeficientą galime rasti iš formulės:

$$\hat{\rho}_s = r_s = 1 - \frac{6 \sum_{i=1}^n (rx_i - ry_i)^2}{n(n_2 - 1)}, |r_s| \leq 1. \quad (1.1)$$

### 1.2. VIENO KINTAMOJO TIESINĖ REGRESIJA

Vieno kintamojo regresinė analizė nagrinėja statistinę dviejų atsitiktinių dydžių  $X$  ir  $Y$  tarpusavio priklausomybę. Tiesinės regresijos lygtis užrašoma

$$Y = \beta_0 + \beta_1 \cdot X \quad (1.2)$$

Pagrindiniai parametrai, lemiantys modelio pasirinkimą –  $r^2$  apibrėžtumo koeficientas, kuris parodo, kuri atsitiktinio dydžio  $Y$  sklaidos dalis apie vidurkį yra paaiškinama regresija. Idealiu atveju  $r^2 \rightarrow 1$ . Standartinė regresijos įverčio paklaida – prognozės paklaidos standartinis nuokrypis, turi būti kuo mažesnis.

Reikia ištirti gauto tiesinės regresijos modelio adekvatumą. Tiesinės regresijos analizės rezultatai yra korektiški tik tuo atveju, jei tenkinamos prielaidos:

1.  $y_i$  nuo  $\hat{y}_i$  grafikas turi būti tiesė, sudaranti  $45^\circ$  kampą su  $\hat{y}_i$  ašimi;
2. sąlyginė dispersija turi būti pastovi;
3. liekanų vidurkis lygus 0 ;
4. liekanų skirstinys normalusis.

Liekana yra skirtumas tarp stebimos ir prognozuojamos atsitiktinio dydžio  $Y$  reikšmės:

$$e_i = y_i - \hat{y}_i \quad (1.3)$$

Praktiškai adekvatumo tyrimas realizuojamas analizuojant grafikus  $Y^* \hat{Y}$ ,  $e^* \hat{Y}$  (čia modelis  $Y(X)$ ,  $\hat{Y}$  – prognozuojama  $Y$  reikšmė,  $e$  – regresijos liekana tame taške), kur pirmajame grafike  $\hat{Y}$

turi būti artimas tiesei, pasvirusiai  $45^\circ$  kampui, kai ordinačių ir absčių ašyse dydžiai atidedami vienodais masteliais, antrojo grafiko taškai turi būti tolygiai pasiskirstę apie tiesę  $Y = 0$ , bei tiriant liekanų skirstinio normalumą.

### 1.3. DAUGIALYPĖ TIESINĖ REGRESIJA

Praktikoje dažnai tenka tirti vieno kintamojo statistinę priklausomybę nuo keleto nepriklausomų kintamųjų. Tam yra naudojama daugialypė tiesinė regresija. Šito metodo esmė – surasti nepriklausomus kintamuosius, turinčius įtakos priklausomam kintamajam ir sudaryti lygtį, geriausiai prognozuojančią priklausomo kintamojo reikšmę, kai žinomos nepriklausomojo kintamojo reikšmės. Pirmiausia reikia nustatyti, kurio kintamojo reikšmės prognozuosime ir pagal kuriuos kintamuosius. Po to yra kuriamas modelis ir nagrinėjamas jo patikimumas.

#### 1.3.1. KLASIKINIS DAUGIALYPĖS TIESINĖS REGRESIJOS MODELIS

Tarkime, kad  $\mathbf{Y} = (\eta(1), \dots, \eta(n))$  yra atsitiktiniai, o  $\mathbf{X} = (x(1), \dots, x(n))$  yra daugiamačiai determinuoti dydžiai. Tuomet daugialypės tiesinės regresijos modelis užrašomas

$$\eta(t) = \theta^T x(t) + \varepsilon(t), t = \overline{1, n}, \quad (1.4)$$

čia  $\theta^T = (\theta_1, \dots, \theta_d)^T$  yra parametru vektorius,  $\varepsilon(t)$  yra modelio liekanų seka.

Tiesinio modelio taikymo prielaidos:

- Visų atsitiktinių paklaidų vidurkiai lygūs 0, t.y.  $E\varepsilon(t) \equiv 0$ ;
- Visų atsitiktinių paklaidų dispersijos pastovios, t.y.  $D\varepsilon(t) \equiv \sigma^2$ ;
- Atsitikinės paklaidos nekoreliuotos, t.y.  $E\varepsilon(t)\varepsilon(\tau) = 0, t \neq \tau$ .

Galima ir papildoma prielaida – atsitikinės paklaidos yra normaliai pasiskirstę atsitiktiniai dydžiai.

Pažymėję  $\boldsymbol{\varepsilon} = (\varepsilon(1), \dots, \varepsilon(n))$ , modelį galime perrašyti matricinėje formoje

$$\mathbf{Y} = \boldsymbol{\theta}^T \mathbf{X} + \boldsymbol{\varepsilon}, \quad (1.5)$$

čia  $\boldsymbol{\varepsilon}$  tenkina sąlygas:

- $E\boldsymbol{\varepsilon} = \mathbf{0}$ ;
- $E\boldsymbol{\varepsilon}^T \boldsymbol{\varepsilon} = \sigma^2 I$ .

### 1.3.2. MAŽIAUSIŲ KVADRATŲ METODAS

Tegul  $\theta$  reikšmė, prie kurios galioja aukščiau paminėtos prielaidos, yra nežinoma. Šią reikšmę pažymime  $\hat{\theta}$ , t.y.  $\mathbf{Y} = \hat{\theta}^T \mathbf{X} + \boldsymbol{\varepsilon}$ . Nagrinėdami  $\hat{\theta}$  kaip laisvąjį kintamąjį, gauname

$$\hat{\theta} = \arg \min_{\theta} E(\eta(t) - \theta^T x(t))^2, \forall t = \overline{1, d}. \quad (1.6)$$

Pažymėję

$$S(\theta) = \sum_{t=1}^n (\eta(t) - \theta^T x(t))^2, \quad (1.7)$$

nagrinėjame statistinį įvertį

$$\hat{\theta} = \arg \min_{\theta} S(\theta). \quad (1.8)$$

Šis įvertis vadinamas mažiausių kvadratų metodo (MKM) įverčiu. (jei galioja prielaida apie paklaidų normalųjį pasiskirstymą, MKM įvertis sutampa su maksimalaus tikėtimumo metodo (MTM) įverčiu,

$$\hat{\theta}_{MTM} = \hat{\theta}, \hat{\sigma}_{MTM}^2 = \frac{S(\hat{\theta})}{n}, \hat{\sigma}_{MTM}^2 \text{ yra paslinktas įvertis)}$$

Kadangi  $\hat{\theta}$  tenkina (1.8), tai jis turi tenkinti ir lygčių sistemą

$$S'(\theta) = 0. \quad (1.9)$$

Perrašę matricinėje formoje, gauname

$$S(\theta) = (\mathbf{Y} - \theta^T \mathbf{X})(\mathbf{Y} - \theta^T \mathbf{X})^T, \quad (1.10)$$

$$S'(\theta) = 2(-\mathbf{X}\mathbf{Y}^T + \mathbf{X}\mathbf{X}^T \theta). \quad (1.11)$$

Tuomet iš (1.9) seka, kad

$$\mathbf{X}\mathbf{X}^T \theta = \mathbf{X}\mathbf{Y}^T, \quad (1.12)$$

o jei matrica  $\mathbf{X}\mathbf{X}^T$  neišsigimusi, tai lygtis turi vienintelį sprendinį

$$\hat{\theta} = (\mathbf{X}\mathbf{X}^T)^{-1} \mathbf{X}\mathbf{Y}^T = B^{-1} \mathbf{X}\mathbf{Y}^T. \quad (1.13)$$

Šio įverčio savybės nusako Gauso – Markovo teorema,

**Gauso – Markovo teorema.** Jei  $E\varepsilon(t) \equiv 0$ ,  $D\varepsilon(t) \equiv \sigma^2$  ir  $E\varepsilon(t)\varepsilon(\tau) = 0, t \neq \tau$  bei regresorių matrica  $\mathbf{X}$  turi rangą  $d$ , t.y. matrica  $B$  yra neišsigimusi, tai MKM įverčiui, apibrėžtam (1.10), galioja šios savybės:

- įvertis yra nepaslinktas, t.y.  $E\hat{\theta} = \theta$ ;
- įverčio kovariacinė matrica  $R_{\hat{\theta}\hat{\theta}} = \sigma^2 B^{-1}$ ;

- c. įvertis turi mažiausią apibendrintą dispersiją tarp visų nepaslinktų tiesinių įverčių, t.y. jei  $\tilde{\theta} = \mathbf{A}\mathbf{Y}^T$ ,  $E\tilde{\theta} = \theta$ , tai  $R_{\tilde{\theta}\tilde{\theta}} - R_{\hat{\theta}\hat{\theta}} \geq 0$ ;
- d. jei galioja prielaida apie paklaidų pasiskirstymo normalumą, tai MKM įvertis turi mažiausią apibendrintą dispersiją tarp visų nepaslinktų (nebūtinai tiesinių) įverčių.

Jei galioja Gauso modelis, tai MKM įverčiui teisingi ir šitie teiginiai:

$$\begin{aligned}\hat{\theta} &\in N(\theta, \sigma^2 B^{-1}), \\ S(\hat{\theta}) / \sigma^2 &\stackrel{D}{=} \chi_{n-d}^2, \\ \frac{S(\theta) - S(\hat{\theta})}{\sigma^2} &\stackrel{D}{=} \chi_d^2.\end{aligned}\tag{1.14}$$

Be to,  $S(\hat{\theta})$  nepriklauso nuo  $S(\theta) - S(\hat{\theta})$  ir  $\hat{\theta}$ . Todėl gauname svarbias hipotezių tikrinimui išvadas:

#### 1. Statistika

$$T_j = \frac{\hat{\theta}_j - \theta_j}{\hat{\sigma} \sqrt{b_{ij}}}\tag{1.15}$$

turi Stjudento skirstinį su  $n-d$  laisvės laipsnių visiems  $j = \overline{1, d}$ . Čia  $[b_{ij}] = B^{-1}$ ,  $i, j = \overline{1, d}$ .

#### 2. Statistika

$$F = \frac{S(\theta) - S(\hat{\theta})}{S(\hat{\theta})} \frac{n-d}{d}\tag{1.16}$$

turi Fišerio skirstinį su parametrais  $d, n-d$ . [5]

### 1.3.3. REGRESIJA SU APRIBOJIMAIS

Tarkime, kad modelio apribojimai užrašomi matricinėje formoje  $R\theta = 0$  ir apribojimų matricos rangas  $\text{rank}(R) = s > 0$ . Kai turime regresijos modelį su apribojimais, keičiasi MKM – minimizuojama liekanų kvadratų suma, įtraukiant apribojimus  $R\theta = \phi$ . Šiuo atveju įvertis apibrėžiamas

$$\hat{\theta}_R = \hat{\theta} - (\mathbf{X}\mathbf{X}^T)^{-1} R^T \left( R(\mathbf{X}\mathbf{X}^T)^{-1} R^T \right)^{-1} (R\hat{\theta} - \phi).\tag{1.17}$$

Šis įvertis yra mažiausios dispersijos nepaslinktas įvertis. Pažymėję  $B = \mathbf{X}\mathbf{X}^T$ , galime perrašyti

$$\hat{\theta}_R = \left( I - BR^T (RBR^T)^{-1} R \right) \hat{\theta} + BR^T (RBR^T)^{-1} \phi.\tag{1.18}$$

### 1.3.4. FIKTYVŪS KINTAMIEJI

Praktikoje dažnai pasitaiko, kad stebėjimus galima suskirstyti į grupes. Kiekvieną grupę atitinka kitas parametų rinkinys. Jei dalis parametų turi tas pačias reikšmes visoms grupėms, tuomet atskirus grupių modelius galima apjungti į vieną, panaudojant fiktyvius kintamuosius, nusakančius priklausomybę vienai ar kitai grupei.

Tegu  $\eta(t)$  yra priklausomas kintamasis,  $Y(t) = (Y_1(t), \dots, Y_k(t))^T$  yra regresorių su pastoviais koeficientais vektorius,  $Z(t) = (Z_1(t), \dots, Z_p(t))^T$  – regresorių su koeficientais, priklausančiais nuo grupės, vektorius,  $t \in T = T_1 \cup \dots \cup T_q$  – grupių indeksų visuma. Tuomet galioja modelis

$$\eta(t) = \alpha^T Y(t) + \beta^T(j) Z(j) + \varepsilon(t), t \in T_j, j = \overline{1, q}. \quad (1.19)$$

Įvedame fiktyvius kintamuosius

$$Q_j(t) = \mathbf{1}_{\{t \in T_j\}}, j = \overline{1, q}. \quad (1.20)$$

Tuomet, pažymėję

$$\begin{aligned} \theta &= (\alpha_1, \dots, \alpha_k, \beta_1(1), \dots, \beta_1(q), \dots, \beta_p(q))^T, \\ X(t) &= (Y_1(t), \dots, Y_k(t), Z_1(t)Q_1(t), \dots, Z_p(t)Q_q(t), \dots, Z_p(t)Q_q(t))^T, \end{aligned} \quad (1.21)$$

iš (1.19) gauname

$$\eta(t) = \theta^T X(t) + \varepsilon(t), t \in T. \quad (1.22)$$

Taikydami MKM, minimizuojame sumą

$$S(\theta) = \sum_{t \in T} (\eta(t) - \theta^T X(t))^2. \quad (1.23)$$

[5]

### 1.3.5. KORELIACIJOS IR APIBRĖŽTUMO KOEFICIENTAS

Tegul  $\xi$  yra vienmatis atsitiktinis dydis, o  $X = (X_1, \dots, X_n)^T$  – atsitiktinis vektorius. Daugiamatės koreliacijos koeficientas tarp  $\xi$  ir  $X$  apibrėžiamas

$$\rho_{\xi X} = \max_{\theta \in \mathbb{R}^d} \text{cor}(\xi, \theta^T X), \quad (1.24)$$

čia  $\theta^T X = \theta_1 X_1 + \theta_2 X_2 + \dots + \theta_n X_n$ . Daugiamatės koreliacijos koeficientas yra vienmatis dydis. Jei  $\theta$  yra vektorius ant kurio pasiekiamas maksimumas, tai

$$\xi = \theta^T X + \varepsilon, \text{cov}(\varepsilon, X) = 0, R_{X\xi} = R_{XX} \theta. \quad (1.25)$$

Koreliacijos koeficientui  $\rho_{\xi X}$  galioja savybės:

- $\rho_{\xi X} \leq 1$ ;
- $\rho_{\xi X} = 0$  tada ir tik tada, kai  $\xi$  ir  $X$  tiesiškai nepriklausomi t.y. tiesinės regresijos funkcija  $f(x) \equiv E\eta$ ;
- $\rho_{\xi X} = 1$  tada ir tik tada, kai  $\xi$  tiesinė  $X$  funkcija  $\xi = a + b^T X$ .

Tegul  $f(x)$  yra regresijos funkcija, t.y.  $f(x) = E(\xi | X = x)$ , tuomet dydžio  $\rho_{\xi X}^* = \text{cor}(\xi, f(X))$  kvadratas vadinamas apibrėžtumo koeficientu. Galima apibrėžti

$$\rho_{\xi X}^{*2} = 1 - \frac{D\varepsilon}{D\xi}, \quad (1.26)$$

čia  $\varepsilon = \xi - f(X)$ . Apibrėžtumo koeficientas parodo, kurią dispersijos  $D\xi$  dalį paaiškina atsitiktinis vektorius  $X$ ). [5]

### 1.3.6. REGRESIJOS MODELIO KOEFICIENTŲ REIŠMINGUMAS

Nagrinėjant tiesinės regresijos modelį, vieni regresoriai teikia daugiau informacijos apie priklausomą kintamąjį negu kiti. Dėl to reikia nustatyti, ar visi į modelį įtraukti regresoriai yra reikalingi. Pašalinus dalį regresorių kartais padidėja modelio tikslumas, nes likusiųjų koeficientai įvertinami tiksliau.

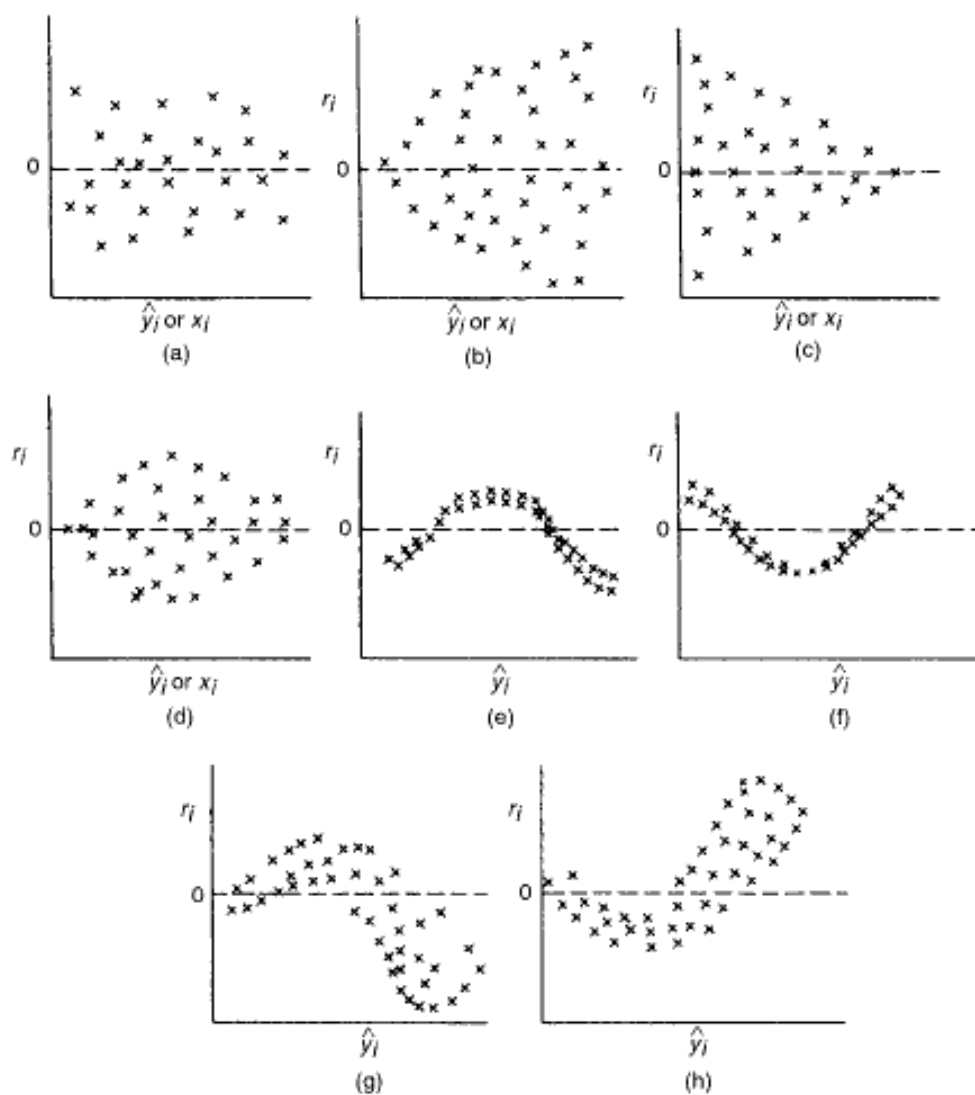
Įvertinat regresorių koeficientus, nusakomas jų reikšmingumas. Koeficiento  $\theta_i$  reikšmingumo lygis  $p_i$  apibrėžiamas kaip hipotezės  $H_0: \theta_i = 0$  kritinis reikšmingumo lygmuo. Paprastai ši hipotezė tikrinama priimant prielaidą, kad paklaidos  $\varepsilon(t)$  pasiskirsčiusios pagal normalųjį dėsnį. Tuomet klasikinio regresijos modelio atveju statistika

$$T_i = \frac{\hat{\theta}_i - \theta_i}{\hat{\sigma} \sqrt{b_{ii}}} \quad (1.27)$$

turi Studento skirstinį su  $n - d$  laisvės laipsnių, čia  $b_{ii}$  yra matricos  $B^{-1}$  i-asis įstrižainės elementas. Kuo  $p_i$  reikšmė mažesnė, tuo ją atitinkantis regresorius reikšmingesnis. [5]

### 1.3.7. LIEKANŲ GRAFIKO ANALIZĖ

Liekana yra skirtumas tarp stebimos ir prognozuojamos atsitiktinio dydžio reikšmės. Viena liekanų analizės dalis – standartizuotų liekanų ir prognozuojamų reikšmių grafiko tyrimas. **1.1 pav.** pateikti grafiko pavyzdžiai ir jų paaiškinimai. Regresijos funkcija stebėjimų elgesį charakterizuoja tuo geriau, kuo šios reikšmės tolygiau išsibarsčiusios apie abscisių ašį.



**1.1 pav. (a) liekanų dispersija pastovi; (b) – (d) nepastovi dispersija, priklausanti nuo abscisių ašyje žymimų dydžių; (e) – (f) netiesinis ryšys; (g) – (h) netiesinis ryšys ir nepastovi dispersija.<sup>1</sup>**

<sup>1</sup> Stapleton J.H., Models for probability and statistical inference. Theory and applications., John Wiley & Sons Inc., Hoboken, New Jersey, USA, 2008 m., 172 psl.



## 1.4. SKIRSTINIO PARAMETRŲ ĮVERTINIMAS. MOMENTŲ METODAS

Atsitiktinio dydžio  $X$   $j$ -osios eilės pradiniu momentu vadinamas dydis

$$E(x^j) = \int_{-\infty}^{\infty} x^j f_X(x) dx, \quad (1.28)$$

čia  $f_X(x)$  atsitiktinio dydžio  $X$  tankio funkcija.

Jeigu turime  $n$  dydžio imtį  $X = (x_1, \dots, x_n)$ , tai  $j$ -osios eilės pradiniu empiriniu momentu vadinamas dydis

$$A_j = \frac{1}{n} \sum_{i=1}^n x_i^j. \quad (1.29)$$

Tarkime, kad atsitiktinio dydžio  $X$  skirstinys priklauso nuo  $s$ -mačio parametro  $\theta = (\theta_1, \dots, \theta_s)$  ir atsitiktinis dydis  $X$  turi  $s$  pirmųjų teorinių momentų  $E(x^r; \theta_1, \dots, \theta_s)$ ,  $r = \overline{1, s}$ . Sudarome pirmuosius  $s$  empirinių momentų  $A_r$ ,  $r = \overline{1, s}$  ir sulyginame juos su atitinkamais teoriniais momentais. Gauname  $s$  lygčių su  $s$  nežinomųjų:

$$E(x^r; \theta_1, \dots, \theta_s) = A_r, \quad r = \overline{1, s}. \quad (1.30)$$

Išsprendę lygčių sistemą, gausime sprendinį  $\hat{\theta} = (\hat{\theta}_1, \dots, \hat{\theta}_s)$ . Įverčius  $\hat{\theta}_1, \dots, \hat{\theta}_s$  laikome parametru  $\theta_1, \dots, \theta_s$  taškiniais įverčiais, gautais momentų metodu. [7]

## 2. TIRIAMOJI DALIS IR REZULTATAI

### 2.1. DAUGELIO RIZIKŲ PASĖLIŲ DRAUDIMO NUOSTOLINGUMO PRIKLAUSOMYBĖ NUO ORO SĄLYGŲ

Šioje dalyje aprašomas pasėlių draudimo nuostolingumo priklausomybės nuo oro sąlygų tyrimas, taikant daugialypę tiesinę regresiją su apribojimais ir fiktyviais kintamaisiais.

Tyrimai rodo, kad klimato kaita įtakoja pasėlių derlingumą (Chmielewski F.M., Potts J. M., 1994, 1995). Padidėjęs pasėlių draudimo nuostolingumas taip pat gali būti siejamas su klimato pasikeitimu (Mafoua E. K., Turvey C. G., 2004). Šioje dalyje tirsime daugelio rizikų pasėlių draudimo nuostolingumo priklausomybę nuo oro sąlygų.

Mafoua E. K., Turvey C. G. sudarė draudimo – oro sąlygų modelį, kuris sieja pasėlių kultūrų draudimo nuostolingumą su kritulių kiekiu ir temperatūra. Temperatūros įvertinimui naudotas rodiklis – per mėnesį sukaupta aukštesnių nei ribinė temperatūra laipsnių suma (angl. cumulative degree-days), skaičiuojamas pagal formulę:

$$CDD = \sum_{i=1}^N \max(0, T_i - T_B), \quad (2.1)$$

čia  $N$  – mėnesio dienų skaičius,  $T_i$  – maksimali mėnesio  $i$ -osios dienos temperatūra,  $T_B$  – ribinė temperatūra. Buvo ištirtas trijose Naujojo Džersio (angl. New Jersey) valstijos apygardose<sup>2</sup> auginamų kukurūzų, sojų pupelių, obuolių, persikų, mėlynių ir spanguolių draudimų nuostolingumas 1989 – 2001 m. laikotarpiu. Naudoti balandžio – rugsėjo mėnesių meteorologiniai duomenys. Bendra modelio išraiška užrašoma:

$$LR_{cst} = \sum_{s=1}^n \alpha_c APH_{ct} D + \sum_{s=1}^n \beta_c CRC_{ct} D + \sum_{s=1}^n \phi_c RA_{ct} D + \sum_{s=1}^n \eta_c CAT_t D + \sum_{m=1}^n \gamma_c R_{mst} + \sum_{m=1}^n \theta_c H_{mst} + \sum_{m=1}^n \delta_c (RH)_{mst} + \varepsilon_t, \quad (2.2)$$

čia  $LR_{cst}$  – apygardos  $s$  draudimo nuostolingumas<sup>3</sup>  $t$ -aisiais metais, kai draudimo padengimo kategorija<sup>4</sup>  $c$ ,  $APH_{ct} D$  – fiktyvus kintamasis lygus 1, jei apygardoje  $s$   $t$ -aisiais metais draudimo planas<sup>5</sup> APH ir padengimo kategorija  $c$ ,  $CRC_{ct} D$  – fiktyvus kintamasis lygus 1, jei apygardoje  $s$   $t$ -aisiais metais draudimo planas CRC ir padengimo kategorija  $c$ ,  $RA_{ct} D$  – fiktyvus kintamasis lygus 1, jei apygardoje  $s$   $t$ -aisiais metais draudimo planas RA ir padengimo kategorija  $c$ ,  $CAT_t D$  – fiktyvus

<sup>2</sup> JAV teritorija suskirstyta į 3140 administracinių vienetų – apygardų.


<sup>3</sup> Draudimo nuostolingumas lygus žalų sumos ir surinktų įmokų santykiui.

<sup>4</sup> Draudimo padengimo kategorija tai yra besidraudžiančio ūkininko pasirinktas vidutinis derlingumas procentais. Jei derlingumas bus mažesnis nei pasirinktas, ūkininkas gaus draudimo išmoką.

<sup>5</sup> Draudimo planas – tai draudimo kompanijos siūlomas pasėlių draudimo variantas. Visi planų aprašymai pateikti **3 priede**.

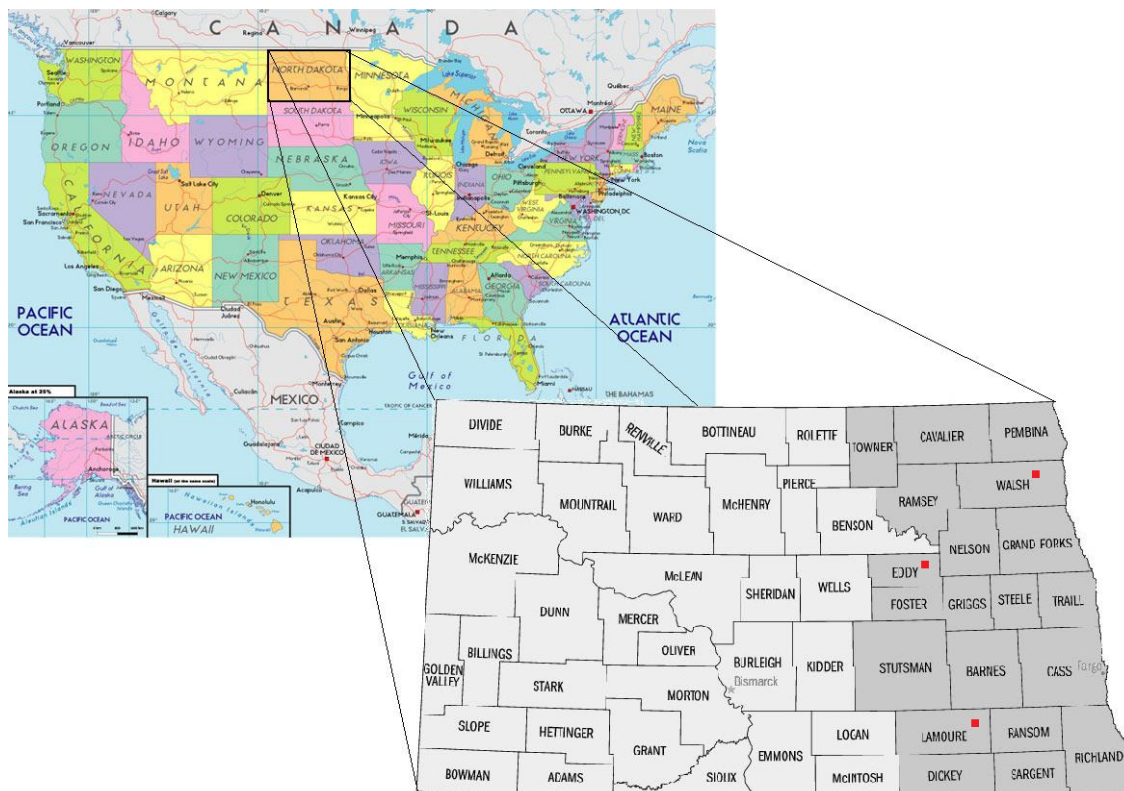
kintamasis lygus 1, jei apygardoje  $s$   $t$ -aisiais metais draudimo planas APH ir padengimo kategorija katastrofinė (CAT),  $R_{mst}$  – apygardoje  $s$   $t$ -aisiais metais  $m$ -ąjį mėnesį sukauptas kritulių kiekis,  $H_{mst}$  – apygardoje  $s$   $t$ -aisiais metais  $m$ -ąjį mėnesį sukaupta aukštesnių nei ribinė temperatūra laipsnių suma,  $(RH)_{mst}$  – apygardoje  $s$   $t$ -aisiais metais  $m$ -ąjį mėnesį sukauptos aukštesnės nei ribinė temperatūra laipsnių sumos ir sukaupto kritulių kiekio bendra įtaka,  $\varepsilon_t$  – paklaida. Gauti modelių apibrėžtumo koeficientai 0.49 – 0.92. [2]

Šiame darbe nagrinėtas tik daugelio rizikų pasėlių draudimas (DRPD, angl. APH arba MPCD). Šis draudimas yra labiausiai paplitęs JAV, be to tokio tipo draudimą gali rinktis ūkininkai ir Lietuvoje. **2.1 pav.** pateiktas JAV platinamų draudimo planų palyginimo grafikas pagal polisų, kuriems surinktos įmokos, skaičių 1995 – 2005 m. laikotarpiu.



**2.1 pav. Pasėlių draudimo polisų skaičius JAV pagal metus skirtingiems draudimo planams**

Pasirinktas tyrimo laikotarpis 1995 – 2005 metai. Tyrimui pasirinkta Šiaurės Dakotos valstijos (JAV) rytinė dalis – 17 apygardų. Tyrimo nepanaudoti duomenys iš 3 apygardų, pažymėtų raudonu kvadratėliu (žr. **2.2 pav.**), nes nebuvo pakankamo meteorologinių duomenų kiekio. Tyrimo regionas savo plotu (~63 tūkst. km<sup>2</sup>) artimas Lietuvai.




**2.2 pav. Tyrimo regionas**

Tyrimo regiono pasirinkimą lėmė tai, kad Šiaurės Dakotos valstijoje draudžiamų pasėlių plotas sudaro 84% – 100% viso pasėlių ploto (2.1 lentelė). Be to Šiaurės Dakotos valstijoje vienas didžiausių polišų, kuriems fiksuota žala, skaičių visoje JAV (žr. 2.3 pav.). Taigi gaunamas pakankamas draudimo duomenų kiekis. O šiuo atveju duomenų kiekis yra vienas svarbiausių veiksnių, renkantis tyrimo regioną.

**2.1 lentelė.**

**Šiaurės Dakotos valstijos pasėlių draudimas pasirinktoms kultūroms 2001 – 2005 metais**

Pasėlių kultūra	2001		2003		2005	
	Pasėlių plotas, ha	Apdraustas plotas, %	Pasėlių plotas, ha	Apdraustas plotas, %	Pasėlių plotas, ha	Apdraustas plotas, %
<b>Miežiai</b>	607,028.46	100%	829,605.57	90%	485,622.77	84%
<b>Kviečiai</b>	3,824,279.32	100%	3,492,437.09	96%	3,678,592.49	96%
<b>Rapsai</b>	526,091.33	100%	392,545.07	86%	420,873.07	97%
<b>Bulvės</b>	47,752.91	100%	47,348.22	94%	37,231.08	95%
<b>Cukriniai runkeliai</b>	105,622.95	100%	104,813.58	94%	103,194.84	94%



**2.3 pav. DRPD polisų, kuriems fiksuota žala, skaičius pagal metus skirtingose JAV valstijose.**


Jei palygintume įvairias ne gyvybės draudimo grupes Lietuvoje ir turimus pasėlių draudimo rezultatus tyrimo regione 2005 metais, tuomet pasėlių draudimas užimtų ketvirtą vietą tarp ne gyvybės draudimo grupių Lietuvoje pagal pasirašytas įmokas (**2.2 lentelė**). 2005 metais tai būtų sudarytę apie 10 % Lietuvos ne gyvybės draudimo rinkos (žr. **2.4 pav.**).

**2.2 lentelė.**

**Draudimo grupės pagal pasirašytas įmokas, 2005 m.<sup>6</sup>**

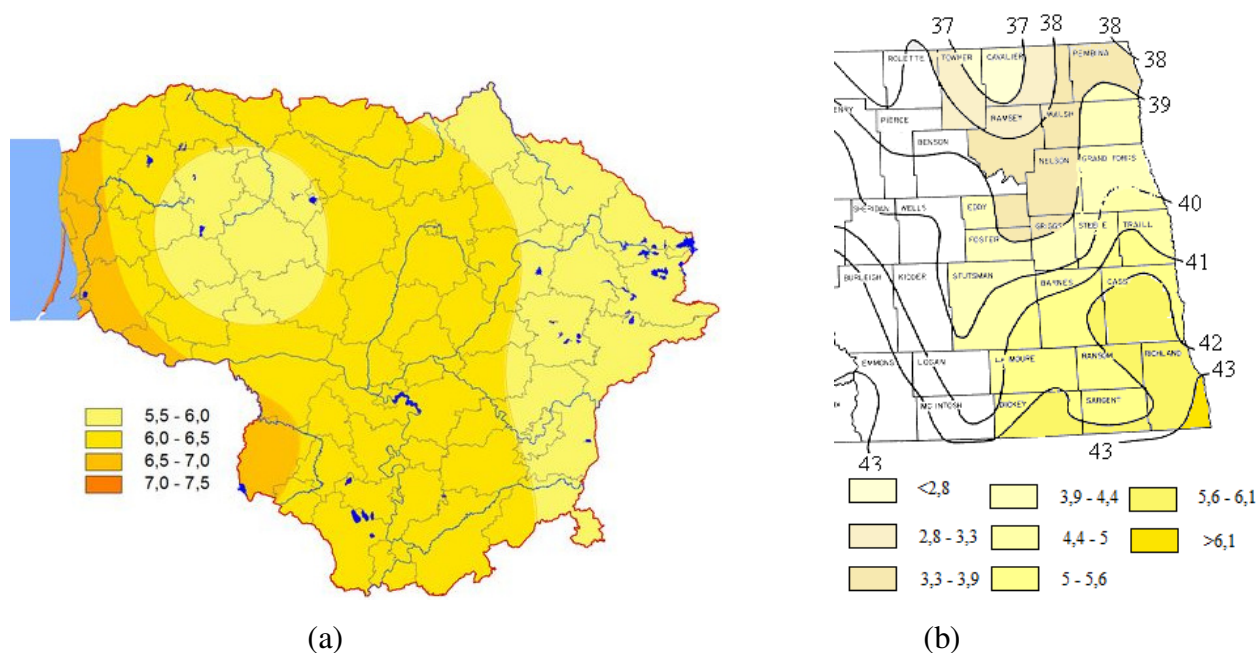
Eil. nr.	Draudimo grupė	Pasirašytos įmokos, Lt
1.	Transporto priemonių savininkų ir valdytojų civilinės atsakomybės	239`339`397
2.	Sausumos transporto priemonių (išskyrus geležinkelio)	234`428`486
3.	Turto draudimas nuo gaisro ar gamtinių jėgų bei nuo kitų žalų	123`440`489
<b>4.</b>	<b>Pasėlių draudimas</b>	<b>83`479`904</b>
5.	Draudimas ligos atvejui bei draudimas nuo nelaimingų atsitikimų	55`448`530
6.	Bendrosios civilinės atsakomybės	41`384`207
7.	Laidavimo draudimas	27`510`466
8.	Kredito draudimas	14`924`224
9.	Vežamų krovinių draudimas	8`832`411
10.	Laivų civilinės atsakomybės draudimas bei laivų draudimas	3`936`765
11.	Finansinių nuostolių draudimas	3`012`799
12.	Skraidymo aparatų civilinės atsakomybės bei skraidymo aparatų	1`667`117
13.	Pagalbos draudimas	627`685
14.	Geležinkelio transporto priemonių draudimas	263`210

<sup>6</sup> <http://www.dpk.lt/rezultatai.menesio.php>



**2.4 pav. Ne gyvybės draudimo rinkos palyginimas pagal pasirašytas įmokas 2005 metais**

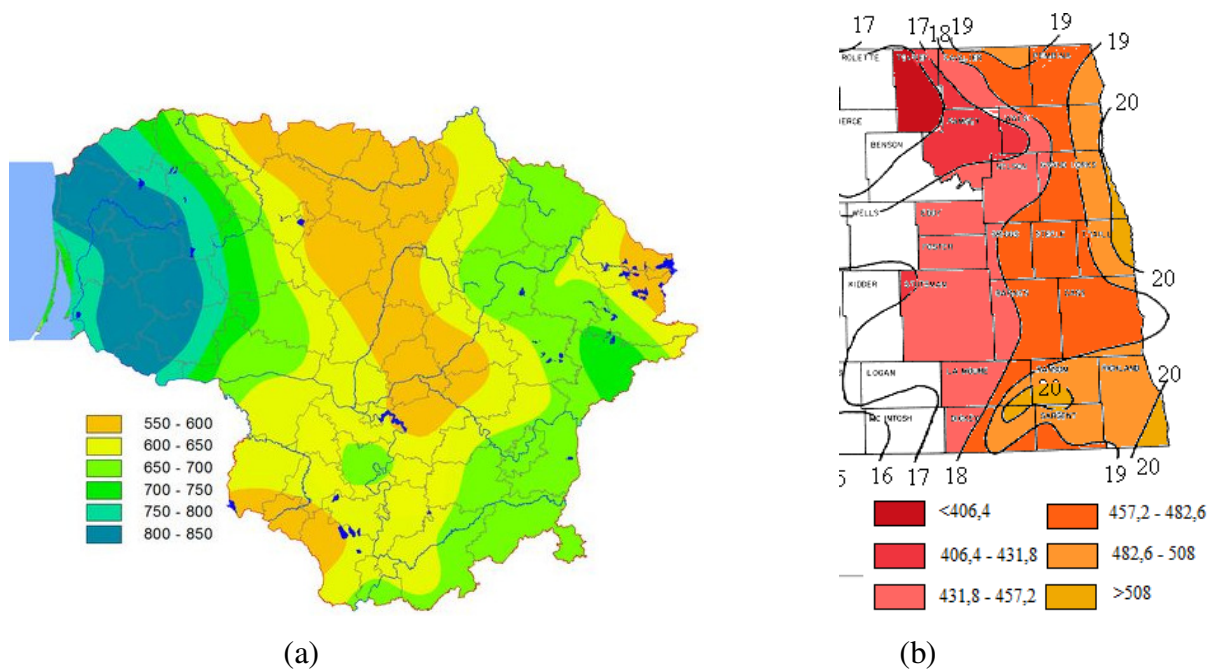
Iš visų JAV regionų, kuriose fiksuotas didžiausias besidraudžiančiųjų skaičius, Šiaurės Dakotos valstijos rytinė dalis klimatinio požiūriu artimiausia Lietuvai. Šiaurės Dakota yra tarp  $45^{\circ}55'$  ir  $49^{\circ}$  šiaurės platumos, o Lietuva yra tarp  $53^{\circ}54'$  ir  $56^{\circ}27'$  šiaurės platumos. Šiaurės Dakotoje vyrauja žemyninis klimatas, o Lietuvoje jūrinis pereinantis į žemyninį. Vidutinių metinių temperatūrų ir vidutinio metinio kritulių kiekio palyginimai pateikti **2.5 – 2.6 pav.** Matome, kad pasirinktame regione kritulių kiekis ir temperatūra žemesni nei Lietuvoje.



**2.5 pav. Vidutinių metinių temperatūrų palyginimas Lietuvoje<sup>7</sup> (a) ir rytinėje Šiaurės Dakotos<sup>8</sup> valstijos dalyje (b)**

<sup>7</sup> [http://www.meteo.lt/klim\\_lt\\_klimatas.php?tipas=oro\\_temp](http://www.meteo.lt/klim_lt_klimatas.php?tipas=oro_temp)

<sup>8</sup> <http://www.npwrc.usgs.gov/resource/habitat/climate/figure1.htm#fig2>



2.6 pav. Vidutinio metinio kritulių kiekio palyginimas Lietuvoje<sup>9</sup> (a) ir rytinėje Šiaurės Dakotos<sup>10</sup> valstijos dalyje (b)

Dar viena priežastis, lėmusi regiono pasirinkimą yra ta, kad tiek Lietuvoje, tiek pasirinktoje teritorijoje dalis auginamų kultūrų sutampa. Be to dalis pasirinktoje teritorijoje draudžiamų pasėlių kultūrų draudžiamos ir Lietuvoje. Iš draudžiamų pasėlių kultūrų sąrašo pasirinkti kviečiai, miežiai, rapsai, cukriniai runkeliai ir bulvės. Surinktų duomenų pavyzdys pateiktas **2 priede**. Draudimo duomenys atsisiųsti iš internetinio puslapio <http://www.rma.usda.gov/tools/>, meteorologiniai duomenys iš internetinio puslapio <http://beaumont.tamu.edu/CLIMATICDATA>.

Šiame darbe kiekvienai iš pasirinktų pasėlių kultūrų tirtas modelis

$$LR_t = \alpha_0 + \sum_{j=1}^9 \alpha_j \cdot CovCat_t + \sum_{k=1}^n \beta_k \cdot CumPRCP_{k_t} + \sum_{k=1}^n \delta_k \cdot CumGDD_{k_t} + \sum_{k=1}^n \varphi_k \cdot (CumPRCP \cdot CumGDD)_{k_t} + \varepsilon_t, \quad (2.3)$$

čia  $LR_t$  – draudimo nuostolingumas  $t$ -aisiais metais,  $CovCat_t$  – fiktyvų draudimo padengimo kategorijos  $t$ -aisiais metais kintamąjį atitinkantis narys<sup>11</sup>,  $CumPRCP_{k_t}$  –  $k$ -ojo mėnesio sukauptas kritulių kiekis (mm),  $CumGDD_{k_t}$  –  $k$ -ąjį mėnesį sukauptos augimui palankios temperatūros laipsnių suma ( $^{\circ}C$ ),  $(CumPRCP \cdot CumGDD)_{k_t}$  –  $k$ -ąjį mėnesį sukauptos augimui palankios temperatūros

<sup>9</sup> [http://www.meteo.lt/klim\\_lt\\_klimatas.php?tipas=krituliai](http://www.meteo.lt/klim_lt_klimatas.php?tipas=krituliai)

<sup>10</sup> <http://www.npwrc.usgs.gov/resource/habitat/climate/figure40.htm#fig41>

<sup>11</sup> Taikomas apribojimas  $\sum_{i=1}^9 \alpha_i = 0$

laipsnių sumos ir sukaupto kritulių kiekio bendra įtaka,  $\varepsilon_i$  – paklaida. (2.3) išraiškoje naudojamas dydis  $n$  – pasėlių kultūrų auginimo laikotarpis mėnesiais (pagal auginimo technologiją):

- Kviečiams  $n = 12$  mėnesių (auginami žieminiai ir vasariniai kviečiai);
- Bulvėms  $n = 6$  mėnesiai: Gegužė – Spalis.
- Cukriniams runkeliams, miežiams, rapsui  $n = 7$  mėnesiai: Balandis – Spalis.

Modelis skiriasi nuo to, kurį nagrinėjo Mafoua E. K., Turvey C. G. Temperatūros įvertinimui pasirinktas kitas dydis, nes norėta patikrinti ar pasėlių nuostolingumui turi įtakos tai, kokia temperatūra buvo visu kultūros augimo laikotarpiu. Be to, siekdami turėti kuo didesnę duomenų kiekį kiekvienos pasėlių kultūros nuostolingumo tyrimui, regiono neskaidome į dalis. Visą pasirinktą teritoriją vertiname kaip vieną vienetą.

Mėnesio sukauptos augimui palankios temperatūros laipsnių suma apskaičiuojama:

1. Jei dienos minimali arba maksimali temperatūra mažesnė nei bazinė minimali temperatūra, tai

$$T_{\min} = T_{\min(\text{bazinė})} \text{ arba } T_{\max} = T_{\min(\text{bazinė})};$$

2. Jei dienos minimali arba maksimali temperatūra didesnė nei bazinė maksimali temperatūra, tai

$$T_{\min} = T_{\max(\text{bazinė})} \text{ arba } T_{\max} = T_{\max(\text{bazinė})};$$


$$CumGDD = \sum_{i=1}^N \left( \frac{(T_{\min i} + T_{\max i})}{2} - T_{\min(\text{bazinė})} \right), \quad (2.4)$$

čia  $N$  – dienų skaičius mėnesyje. [8]

Mėnesio sukauptos augimui palankios temperatūros laipsnių sumos ir mėnesio sukaupto kritulių kiekio skaičiavimuose naudoti kiekvienai apygardai tiesiogiai išmatuoti oro sąlygų rodikliai – dienos minimali ir maksimali temperatūra bei kritulių kiekis. Kai kurių apygardų meteorologinių duomenų rinkmenose trūko dienos kritulių kiekio. Toms apygardoms, kurioms trūko nedaug duomenų, buvo ištirtas kritulių kiekio pasiskirstymas. Nustačius pasiskirstymo dėsnį ir skirstinio parametrus, buvo sugeneruoti trūkstami duomenys. Gauta, kad kritulių kiekio pasiskirstymą geriausiai aprašo eksponentinis skirstinys. Ši tyrimo dalis pateikta **1 priede**.

Tiriant modelio tinkamumą, pirmiausia tikrinta prielaida apie liekanų dispersijos pastovumą. Nubraižius (2.3) modelio pasirinktoms pasėlių kultūroms liekanų grafiką, gauta, kad ši prielaida netenkinama. **2.7 pav.** pateiktas liekanų grafiko pavyzdys. Matome, kad liekanų dispersija nėra pastovi ir galimas netiesinis ryšys.





2.7 pav. Kviečių DRPD nuostolingumo modelio normuotų liekanų grafikas

Norint, kad dispersija būtų pastovi, galima taikyti transformaciją tiek priklausomam kintamajam, tiek nepriklausomiems kintamiesiems. Buvo pasirinkta priklausomo kintamojo laipsninė transformacija

$$\psi(U, \lambda) = U^\lambda. \quad (2.5)$$

Keičiant parametą  $\lambda$ , gaunamos skirtingos transformacijos, pvz. kai  $\lambda = \frac{1}{2}$  kvadratinė šaknis,  $\lambda = \frac{1}{3}$  kubinės šaknis,  $\lambda = -1$  atvirkštinė,  $\lambda = 0$  logaritminė transformacija. Kintamasis  $U$  turi būti teigiamas. [9]

Pritaikome nuostolingumui (2.5) transformaciją. Tuomet draudimo nuostolingumo priklausomybės nuo oro sąlygų modelis užrašomas taip:

$$LR_t^\lambda = \alpha_0 + \sum_{j=1}^9 \alpha_j \cdot CovCat_t + \sum_{k=1}^n \beta_k \cdot CumPRCP_{k_t} + \sum_{k=1}^n \delta_k \cdot CumGDD_{k_t} + \sum_{k=1}^n \varphi_k \cdot (CumPRCP \cdot CumGDD)_{k_t} + \varepsilon_t. \quad (2.6)$$

Pasėlių kultūroms parinkti laipsnių rodikliai pateikti 2.3 lentelėje.

2.3 lentelė.

#### DRPD nuostolingumo transformacijos koeficientai

	$\lambda$
Miežių DRPD nuostolingumas	0.35
Kviečių DRPD nuostolingumas	0.30
Rapsų DRPD nuostolingumas	0.23
Bulvių DRPD nuostolingumas	0.22
Cukrinių runkelių DRPD nuostolingumas	0.22


Atlikus dispersinę analizę, patikrinta hipotezės: nulinė hipotezė  $H_0$ : „Regresija yra netiesinė“, alternatyvi hipotezė  $H_a$ : „Regresija yra tiesinė“, kai reikšmingumo lygmuo  $1 - \alpha = 0,95$ . Iš gautų rezultatų (2.4 lentelė), matome, kad nulinė hipotezė atmesta, nes apskaičiuota Fišerio statistikos reikšmė patenka į kritinę sritį ( $p < 0.0001$ ). Šiame modelyje 29.1% sklaidos paaiškinama tiesine regresija su 0.26707 standartine regresijos įverčio paklaida.

2.4 lentelė.

#### Transformuoto kviečių nuostolingumo modelio dispersinės analizės rezultatai

<b>F statistikos reikšmė</b>	8.69	<b>Pr &gt; F</b>	<.0001
<b>Standartine regresijos įverčio paklaida</b>	0.26707		
<b>Apibrėžtumo koeficientas</b>	0.2910		
<b>Koreguotas apibrėžtumo koeficientas</b>	0.2575		

Patikrintos 1.3.1 skyriuje surašytos daugialypės regresijos modelio prielaidos. Nubraižius (2.6) modelio liekanų grafiką, gauta, kad liekanų dispersija pastovi (žr. 2.8 pav.)



2.8 pav. Transformuoto kviečių nuostolingumo modelio normuotų liekanų grafikas

Toliau tikrinta hipotezė apie liekanų vidurkio lygybę 0. Patikrinta nulinė hipotezė  $H_0$ : „ $\mu_0 = 0$ “, alternatyvi hipotezė  $H_a$ : „ $\mu_0 \neq 0$ “, kai reikšmingumo lygmuo  $1 - \alpha = 0,95$ . Nulinė hipotezė  $H_0$  priimta, nes Stjudento statistikos reikšmės patenka į hipotezės priėmimo sritį ( $p = 1 > 0.05$ ) (žr. 2.5 lentelę).

## 2.5 lentelė.

**Hipotezės apie liekanų vidurkio lygybę 0 tikrinimo rezultatai**

Kriterijus	Statistika	p reikšmė
Stjudento t	0	1.0000

Patikrintos hipotezės: nulinė hipotezė  $H_0$ : „Liekanų skirstinys normalusis“, alternatyvi hipotezė  $H_a$ : „Liekanų skirstinys nėra normalusis“. Nulinė hipotezė  $H_0$  priimta, nes statistikos reikšmės patenka į hipotezės priėmimo sritį ( $p = 0.6797$ ) (2.6 lentelė).

## 2.6 lentelė.

**Hipotezės apie liekanų pasiskirstymo normalumą tikrinimo rezultatai**

Kriterijus	Statistika	p reikšmė
Kolmogorovo-Smirnovo	0.998658	0.6797

Patikrinę modelio adekvatumą, gauname, kad šis regresijos modelis taikomas korektiškai. Gauti modelių apibrėžtumo koeficientai pateikti 2.7 lentelėje. Mažos apibrėžtumo koeficientų reikšmės rodo, kad draudimo nuostolingumas priklauso ne tik nuo oro sąlygų.

## 2.7 lentelė.

**DRPD nuostolingumo modelio apibrėžtumo koeficientai**

	$\rho^{*2}$	Koreguotas $\rho^{*2}$
Miežių DRPD nuostolingumas	0.25	0.22
Kviečių DRPD nuostolingumas	0.29	0.26
Rapsų DRPD nuostolingumas	0.32	0.26
Bulvių DRPD nuostolingumas	0.29	0.22
Cukrinių runkelių DRPD nuostolingumas	0.35	0.27

Visi daugialypės regresijos rezultatai pateikti 3 priede.

## 2.2. DRPD NUOSTOLINGUMO APROKSIMAVIMAS PASIRINKTAIS SKIRSTINIAIS

Šioje darbo dalyje sprendžiamas duomenų pasiskirstymo aproksimavimo uždavinys. Iš turimų duomenų galime suskaičiuoti tik empirines skirstinio charakteristikas: vidurkį, dispersiją, asimetriškumo koeficientą ir t.t. Kadangi duomenų pasiskirstymo dėsnio nežinome, remdamiesi gauta duomenų histograma galime parinkti skirstinius, savo forma artimus duomenų pasiskirstymui. Tuomet belieka surasti pasirinktų skirstinių parametrų reikšmes ir įvertinti, kaip šie skirstiniai atitinka realius duomenis.

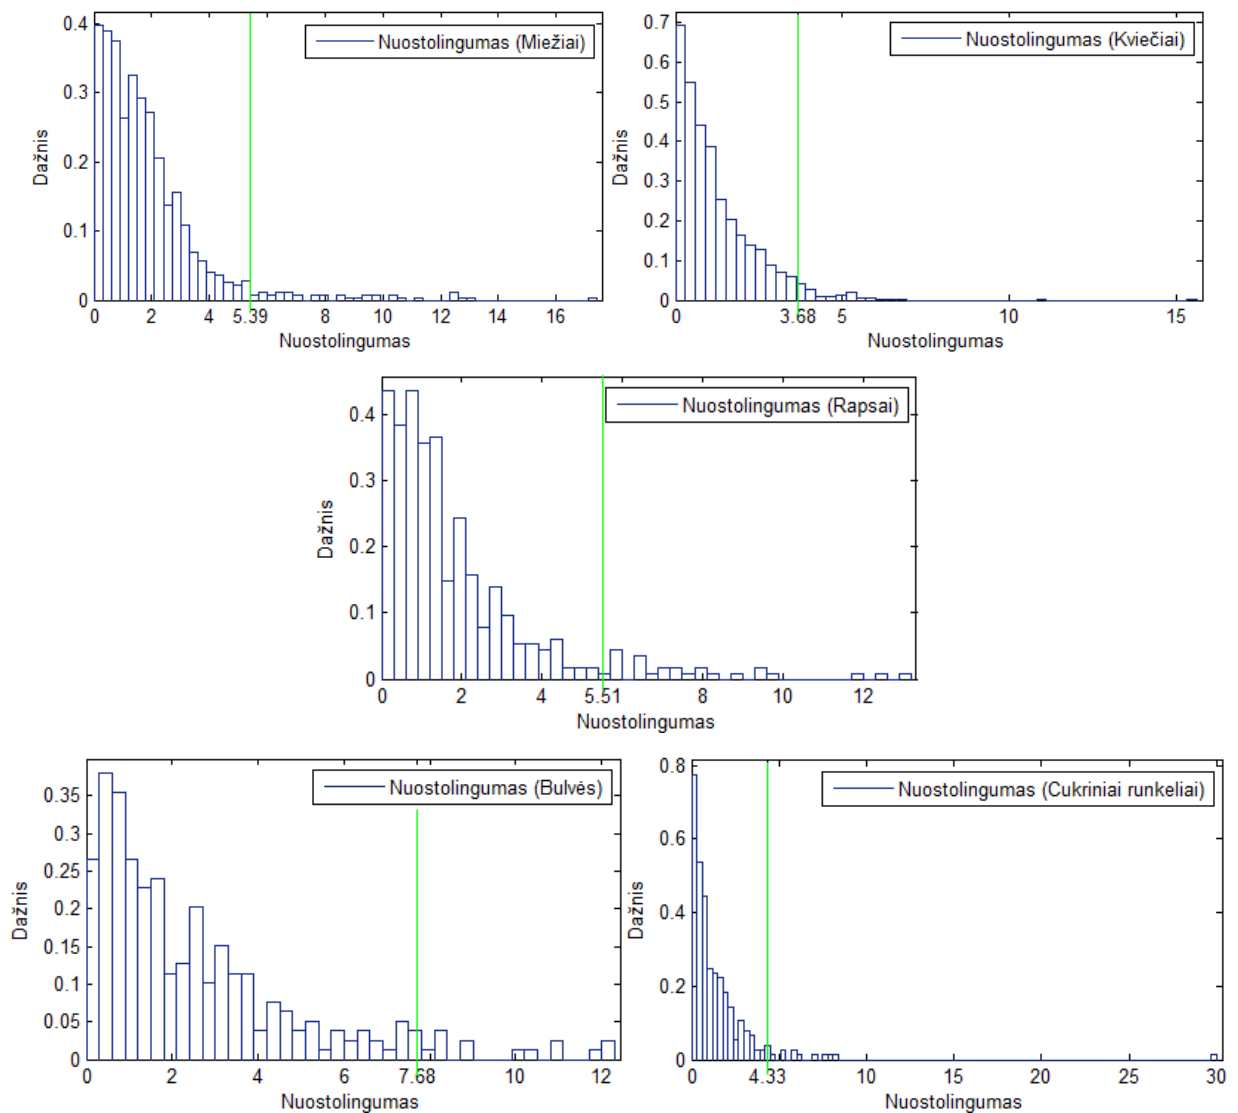
Pirmiausia pasiskaičiuojame empirines tiriamų pasėlių kultūrų DRPD nuostolingumo charakteristikas (**2.8 lentelė**) ir nusibraižome histogramas (žr. **2.9 pav.**).

**2.8 lentelė.**

**DRPD nuostolingumo empirinės charakteristikos**

	Duomenų skaičius	Min.	Maks.	Vidurkis	Dispersija	Asimetriš- kumas
<b>Miežių DRPD nuostolingumas</b>	923	0.0034	17.3711	1.8495	3.5838	2.9719
<b>Kviečių DRPD nuostolingumas</b>	981	0.0021	15.4755	1.2384	1.6012	3.0107
<b>Rapsų DRPD nuostolingumas</b>	382	0.0101	13.1824	1.8728	4.1010	2.4018
<b>Bulvių DRPD nuostolingumas</b>	263	0.0280	12.2022	2.5769	6.2200	1.6270
<b>Cukrinių runkelių DRPD nuostolingumas</b>	254	0.0037	29.8163	1.4436	5.3199	7.8485

Iš **2.8 lentelės** matome, kad duomenys pasižymi dideliu asimetriškumu. Tai būdinga draudimo nuostolingumui. Duomenų reikšmės, didesnes nei trys vidurkio reikšmės (**2.9 pav.**, pažymėta žalia linija), priskiriame katastrofiniam nuostolingumui. Skirtingoms pasėlių kultūroms šios reikšmės sudaro 3.98% – 6.54% visų duomenų reikšmių. Aproksimavime šių reikšmių nenaudojame.



**2.9 pav. Miežių, kviečių, rapsų, bulvių ir cukrinių runkelių DRPD nuostolingumo histogramos**

Perskaičiuojame empirines charakteristikas, atmetę katastrofinio nuostolingumo reikšmes (2.9 lentelė).

**2.9 lentelė.**

**Perskaičiuotos DRPD nuostolingumo empirinės charakteristikos**

	Duomenų skaičius	Min.	Maks.	Vidurkis	Dispersija	Asimetriškumas
<b>Miežių DRPD nuostolingumas</b>	886	0.0034	5.3896	1.5614	1.3617	0.9105
<b>Kviečių DRPD nuostolingumas</b>	942	0.0021	3.6831	1.0752	0.8136	0.9455
<b>Rapsų DRPD nuostolingumas</b>	357	0.0101	5.5064	1.453	1.3844	1.1025
<b>Bulvių DRPD nuostolingumas</b>	249	0.028	7.6833	2.1732	3.3592	1.112
<b>Cukrinių runkelių DRPD nuostolingumas</b>	243	0.0037	4.3303	1.1228	1.0588	1.1509

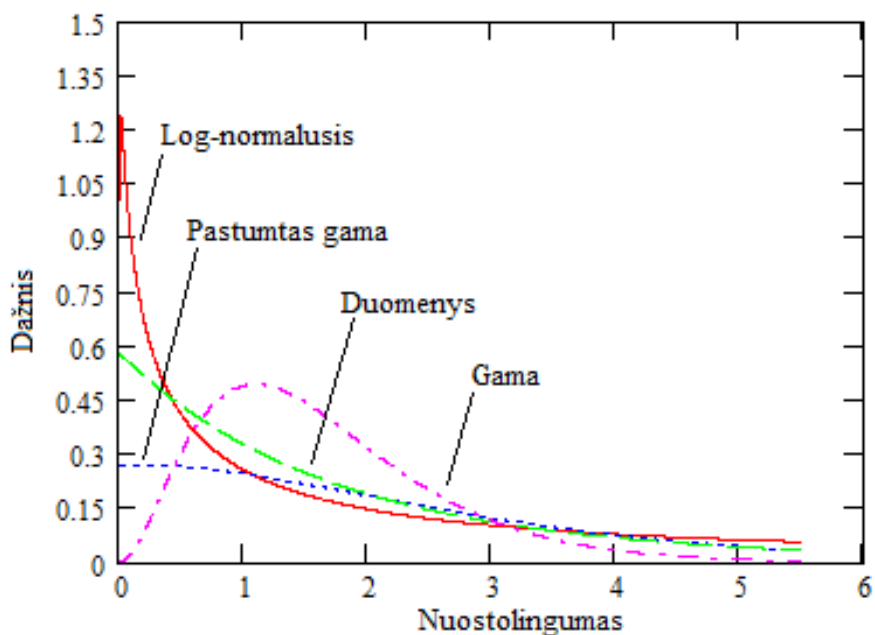
Atmetę dalį duomenų, gauname imtį, iš kairės apribotą minimalia, o iš dešinės maksimalia reikšme. Tegu  $X$  yra atsitiktinis dydis, turintis tankio funkciją  $f(x)$ . Tuomet palengvinto ir nupjauto atsitiktinio dydžio  $X$  tankio funkcija apibrėžiama

$$f_1(x) = \begin{cases} \frac{f(x)}{F(x_D) - F(x_K)}, & \text{kai } x_K \leq x \leq x_D; \\ 0, & \text{kitur.} \end{cases} \quad (2.7)$$

Nuostolingumą aproksimuojame palengvintu (nupjovimo riba  $y_K$ ) ir nupjautu (nupjovimo riba  $y_D$ ) ir, jei reikia, pastumtu atsitiktiniu dydžiu  $Y$ , t.y.

$$X = \begin{cases} a + Y, & \text{kai } y_K \leq y \leq y_D; \\ 0, & \text{kitur.} \end{cases} \quad (2.8)$$

Šiame darbe buvo tirti trys atsitiktinio dydžio  $Y$  pasiskirstymo dėsniai: gama, log-normalusis ir pastumtas Pareto. Aproksimavimas palengvintu ir nupjautu gama, palengvintu ir nupjautu pastumtu gama bei palengvintu ir nupjautu log-normaliuoju skirstiniu tiriamu atveju netiko. Pagal duomenis suradus nežinomus gama ir log-normaliojo skirstinio parametrus, gauta, kad tiek palengvintas ir nupjautas gama, tiek palengvintas ir nupjautas pastumtas gama, tiek palengvintas ir nupjautas log-normalusis skirstinys savo forma neatitinka duomenų pasiskirstymo (2.10 pav.).



2.10 pav. Duomenų, log-normaliojo ir pastumto gama ir gama pasiskirstymo tankio grafikai.

Pastumto Pareto atsitiktinio dydžio  $X$  tankis apibrėžiamas

$$f_X(x) = \begin{cases} \frac{\alpha \cdot (k+d)^\alpha}{(k+x)^{\alpha+1}}, & \text{kai } x > d > 0; \\ 0, & \text{kitur.} \quad [4] \end{cases} \quad (2.9)$$

Tuomet remiantis (2.7), palengvinto (nupjovimo riba  $y_K$ ) ir nupjauto (nupjovimo riba  $y_D$ ) pastumto Pareto atsitiktinio dydžio  $Y$  pasiskirstymo tankis apibrėžiamas

$$f_Y(y) = \begin{cases} \frac{\alpha \cdot (k+d)^\alpha \cdot (k+y)^{-\alpha-1}}{1 - \left(\frac{k+d}{k+y_D}\right)^\alpha - \left(1 - \left(\frac{k+d}{k+y_K}\right)^\alpha\right)}, & \text{kai } y_K \leq y \leq y_D; \\ 0, & \text{kitur.} \end{cases} \quad (2.10)$$

Toliau pateiktos išvestos trijų pradinių teorinių momentų išraiškos. Pirmasis momentas (vidurkis):

$$\begin{aligned} \mu_Y = E_Y(y) &= \int_{-\infty}^{\infty} y \cdot f_Y(y) dy = \int_{y_K}^{y_D} y \cdot f_Y(y) dy = \\ &= \frac{\alpha \cdot (k+d)^\alpha}{1 - \left(\frac{k+d}{k+y_D}\right)^\alpha - \left(1 - \left(\frac{k+d}{k+y_K}\right)^\alpha\right)} \int_{y_K}^{y_D} y \cdot (k+y)^{-\alpha-1} dy = \\ &= \frac{(k+d)^\alpha}{\left(\frac{k+d}{k+y_K}\right)^\alpha - \left(\frac{k+d}{k+y_D}\right)^\alpha} \frac{1}{\alpha-1} \left( \frac{k+y_K \cdot \alpha}{(k+y_K)^\alpha} - \frac{k+y_D \cdot \alpha}{(k+y_D)^\alpha} \right). \end{aligned} \quad (2.11)$$

Antrasis momentas:

$$\begin{aligned} E_Y(y^2) &= \int_{-\infty}^{\infty} y^2 \cdot f_Y(y) dy = \int_{y_K}^{y_D} y^2 \cdot f_Y(y) dy = \\ &= \frac{(k+d)^\alpha}{\left(\frac{k+d}{k+y_K}\right)^\alpha - \left(\frac{k+d}{k+y_D}\right)^\alpha} \int_{y_K}^{y_D} y^2 \cdot (k+y)^{-\alpha-1} dy = \\ &= \frac{(k+d)^\alpha}{\left(\frac{k+d}{k+y_K}\right)^\alpha - \left(\frac{k+d}{k+y_D}\right)^\alpha} \frac{1}{(\alpha-2)(\alpha-1)} \cdot \\ &\quad \cdot \left( \frac{y_K^2 \cdot \alpha^2 + 2 \cdot k \cdot y_K \cdot \alpha - y_K^2 \cdot \alpha + 2 \cdot k^2}{(k+y_K)^\alpha} - \frac{y_D^2 \cdot \alpha^2 + 2 \cdot k \cdot y_D \cdot \alpha - y_D^2 \cdot \alpha + 2 \cdot k^2}{(k+y_D)^\alpha} \right). \end{aligned} \quad (2.12)$$

Trečiasis momentas:

$$\begin{aligned}
E_Y(y^3) &= \int_{-\infty}^{\infty} y^3 \cdot f_Y(y) dy = \int_{y_K}^{y_D} y^3 \cdot f_Y(y) dy = \\
&= \frac{(k+d)^\alpha}{\left(\frac{k+d}{k+y_K}\right)^\alpha - \left(\frac{k+d}{k+y_D}\right)^\alpha} \int_{y_K}^{y_D} y^3 \cdot (k+y)^{-\alpha-1} dy = \\
&= \frac{(k+d)^\alpha}{\left(\frac{k+d}{k+y_K}\right)^\alpha - \left(\frac{k+d}{k+y_D}\right)^\alpha} \frac{1}{(\alpha-3)(\alpha-2)(\alpha-1)} \cdot \\
&\quad \cdot \left( \frac{6 \cdot k^3 + 6 \cdot k^2 \cdot y_K \cdot \alpha - y_K^2 (3 \cdot k \cdot \alpha + 3 \cdot k \cdot \alpha^2) + y_K^3 (\alpha^3 + 2 \cdot \alpha - 3 \cdot \alpha^2)}{(k+y_K)^\alpha} - \right. \\
&\quad \left. - \frac{6 \cdot k^3 + 6 \cdot k^2 \cdot y_D \cdot \alpha - y_D^2 (3 \cdot k \cdot \alpha + 3 \cdot k \cdot \alpha^2) + y_D^3 (\alpha^3 + 2 \cdot \alpha - 3 \cdot \alpha^2)}{(k+y_D)^\alpha} \right). \tag{2.13}
\end{aligned}$$

Kai  $\alpha = 1$ , iš (2.11) – (2.13) gauname tokias momentų išraiškas:

$$\mu_Y = \frac{(k+y_K) \cdot (k+y_D)}{y_D - y_K} \left( \frac{k + \ln(k+y_D) \cdot (k+y_D)}{(k+y_D)} - \frac{k + \ln(k+y_K) \cdot (k+y_K)}{(k+y_K)} \right),$$

$$\begin{aligned}
E_Y(y^2) &= \frac{(k+d)}{\left(\frac{k+d}{k+y_K}\right) - \left(\frac{k+d}{k+y_D}\right)} \left( \frac{-y_K \cdot k - y_K^2 + 2 \cdot \ln(k+y_K) \cdot (k^2 + k \cdot y_K)}{(k+y_K)} - \right. \\
&\quad \left. - \frac{-y_D \cdot k - y_D^2 + 2 \cdot \ln(k+y_D) \cdot (k^2 + k \cdot y_D)}{(k+y_D)} \right),
\end{aligned}$$

$$\begin{aligned}
E_Y(y^3) &= \frac{(k+d)}{\left(\frac{k+d}{k+y_K}\right) - \left(\frac{k+d}{k+y_D}\right)} \left( \frac{-y_K \cdot k - y_K^2 + 2 \cdot \ln(k+y_K) \cdot (k^2 + k \cdot y_K)}{(k+y_K)} - \right. \\
&\quad \left. - \frac{-y_D \cdot k - y_D^2 + 2 \cdot \ln(k+y_D) \cdot (k^2 + k \cdot y_D)}{(k+y_D)} \right).
\end{aligned}$$

Kai  $\alpha = 2$ , iš (2.11) – (2.13) gauname

$$\mu_Y = \frac{(k+d)^2}{\left(\frac{k+d}{k+y_K}\right)^2 - \left(\frac{k+d}{k+y_D}\right)^2} \left( \frac{k+2 \cdot y_K}{(k+y_K)^2} - \frac{k+2 \cdot y_D}{(k+y_D)^2} \right),$$



$$E_Y(y^2) = \frac{(k+d)^2}{\left(\frac{k+d}{k+y_K}\right)^2 - \left(\frac{k+d}{k+y_D}\right)^2} \left( \frac{3 \cdot k^2 + 4 \cdot y_D \cdot k + 2 \cdot \ln(k+y_D) \cdot (k^2 + 2 \cdot k \cdot y_D - y_D^2)}{(k+y_D)^2} - \frac{3 \cdot k^2 + 4 \cdot y_K \cdot k + 2 \cdot \ln(k+y_K) \cdot (k^2 + 2 \cdot k \cdot y_K - y_K^2)}{(k+y_K)^2} \right),$$

$$E_Y(y^3) = \frac{(k+d)^3}{\left(\frac{k+d}{k+y_K}\right)^3 - \left(\frac{k+d}{k+y_D}\right)^3} \cdot \left( \frac{4 \cdot y_K \cdot k^2 - 4 \cdot y_K^2 \cdot k - 2 \cdot y_K^3 + 5 \cdot k^3 + 6 \cdot \ln(k+y_K) \cdot (k^3 + 2 \cdot k^2 \cdot y_K - k \cdot y_K^2)}{(k+y_K)^2} - \frac{4 \cdot y_D \cdot k^2 - 4 \cdot y_D^2 \cdot k - 2 \cdot y_D^3 + 5 \cdot k^3 + 6 \cdot \ln(k+y_D) \cdot (k^3 + 2 \cdot k^2 \cdot y_D - k \cdot y_D^2)}{(k+y_D)^2} \right).$$

Kai  $\alpha = 3$ , iš (2.11) – (2.13) gauname

$$\mu_Y = \frac{(k+d)^3}{\left(\frac{k+d}{k+y_K}\right)^3 - \left(\frac{k+d}{k+y_D}\right)^3} \frac{1}{2} \left( \frac{k+3 \cdot y_K}{(k+y_K)^3} - \frac{k+3 \cdot y_D}{(k+y_D)^3} \right),$$

$$E_Y(y^2) = \frac{(k+d)^3}{\left(\frac{k+d}{k+y_K}\right)^3 - \left(\frac{k+d}{k+y_D}\right)^3} \left( \frac{k^2 + 3 \cdot y_K \cdot k + 3 \cdot y_K^2}{(k+y_K)^3} - \frac{k^2 + 3 \cdot y_D \cdot k + 3 \cdot y_D^2}{(k+y_D)^3} \right),$$

$$E_Y(y^3) = \frac{(k+d)^3}{\left(\frac{k+d}{k+y_K}\right)^3 - \left(\frac{k+d}{k+y_D}\right)^3} \cdot \left( \frac{1}{2} \left( \frac{11 \cdot k^3 + 27 \cdot y_K \cdot k^2 + 18 \cdot y_K^2 \cdot k + 6 \cdot \ln(k+y_K) \cdot (k^3 + 3 \cdot k^2 \cdot y_K + 3 \cdot k \cdot y_K^2 + y_K^3)}{(k+y_K)^3} - \frac{11 \cdot k^3 + 27 \cdot y_D \cdot k^2 + 18 \cdot y_D^2 \cdot k + 6 \cdot \ln(k+y_D) \cdot (k^3 + 3 \cdot k^2 \cdot y_D + 3 \cdot k \cdot y_D^2 + y_D^3)}{(k+y_D)^3} \right) \right).$$

Kai  $\alpha > 3$ , iš (2.11) – (2.13) gauname

$$\mu_Y = \frac{(k+d)^\alpha}{\left(\frac{k+d}{k+y_K}\right)^\alpha - \left(\frac{k+d}{k+y_D}\right)^\alpha} \frac{1}{\alpha-1} \left( \frac{k+y_K \cdot \alpha}{(k+y_K)^\alpha} - \frac{k+y_D \cdot \alpha}{(k+y_D)^\alpha} \right),$$

$$E_Y(y^2) = \frac{(k+d)^\alpha}{\left(\frac{k+d}{k+y_K}\right)^\alpha - \left(\frac{k+d}{k+y_D}\right)^\alpha} \frac{1}{(\alpha-2)(\alpha-1)} \cdot \left( \frac{y_K^2 \cdot \alpha^2 + 2 \cdot k \cdot y_K \cdot \alpha - y_K^2 \cdot \alpha + 2 \cdot k^2}{(k+y_K)^\alpha} - \frac{y_D^2 \cdot \alpha^2 + 2 \cdot k \cdot y_D \cdot \alpha - y_D^2 \cdot \alpha + 2 \cdot k^2}{(k+y_D)^\alpha} \right),$$

$$E_Y(y^3) = \frac{(k+d)^\alpha}{\left(\frac{k+d}{k+y_K}\right)^\alpha - \left(\frac{k+d}{k+y_D}\right)^\alpha} \frac{1}{(\alpha-3)(\alpha-2)(\alpha-1)} \cdot \left( \frac{6 \cdot k^3 + 6 \cdot k^2 \cdot y_K \cdot \alpha - y_K^2 (3 \cdot k \cdot \alpha + 3 \cdot k \cdot \alpha^2) + y_K^3 (\alpha^3 + 2 \cdot \alpha - 3 \cdot \alpha^2)}{(k+y_K)^\alpha} - \frac{6 \cdot k^3 + 6 \cdot k^2 \cdot y_D \cdot \alpha - y_D^2 (3 \cdot k \cdot \alpha + 3 \cdot k \cdot \alpha^2) + y_D^3 (\alpha^3 + 2 \cdot \alpha - 3 \cdot \alpha^2)}{(k+y_D)^\alpha} \right).$$

Iš pradinių momentų galime rasti dispersijos išraišką:

$$\sigma_Y^2 = \int_{-\infty}^{\infty} (y - E_Y(y))^2 f_Y(y) dy = E_Y(y^2) - (E_Y(y))^2, \quad (2.14)$$

ir asimetriškumo koeficiento išraišką:

$$\gamma_{1Y} = \int_{-\infty}^{\infty} (y - E_Y(y))^3 f_Y(y) dy = \frac{E_Y(y^3) - 3E_Y(y) \cdot \sigma_Y^2 - (E_Y(y))^3}{\sigma_Y^3}. \quad (2.15)$$

Kai  $d = y_K$ , gaunamas nupjautas pastumtas Pareto skirstinys. Šio skirstinio vidurkis pagal (2.11)

$$\mu_Y = \frac{(k+y_K)^\alpha}{1 - \left(\frac{k+y_K}{k+y_D}\right)^\alpha} \frac{1}{\alpha-1} \left( \frac{k+y_K \cdot \alpha}{(k+y_K)^\alpha} - \frac{k+y_D \cdot \alpha}{(k+y_D)^\alpha} \right), \quad (2.16)$$

dispersija pagal (2.14)

$$\sigma_Y^2 = \frac{(k+y_K)^\alpha}{1 - \left(\frac{k+y_K}{k+y_D}\right)^\alpha} \frac{1}{(\alpha-2)(\alpha-1)} \cdot \left( \frac{y_K^2 \cdot \alpha^2 + 2 \cdot k \cdot y_K \cdot \alpha - y_K^2 \cdot \alpha + 2 \cdot k^2}{(k+y_K)^\alpha} - \frac{y_D^2 \cdot \alpha^2 + 2 \cdot k \cdot y_D \cdot \alpha - y_D^2 \cdot \alpha + 2 \cdot k^2}{(k+y_D)^\alpha} \right) - \mu_Y^2 \quad (2.17)$$


ir asimetriškumas pagal (2.15)

$$\begin{aligned}
\gamma_{1Y} = & \left( \frac{(k + y_K)^\alpha}{1 - \left(\frac{k + y_K}{k + y_D}\right)^\alpha} \frac{1}{(\alpha - 3)(\alpha - 2)(\alpha - 1)} \cdot \right. \\
& \cdot \left. \frac{\left( 6 \cdot k^3 + 6 \cdot k^2 \cdot y_K \cdot \alpha - y_K^2 (3 \cdot k \cdot \alpha + 3 \cdot k \cdot \alpha^2) + y_K^3 (\alpha^3 + 2 \cdot \alpha - 3 \cdot \alpha^2) \right)}{(k + y_K)^\alpha} \right. \\
& \left. - \frac{\left( 6 \cdot k^3 + 6 \cdot k^2 \cdot y_D \cdot \alpha - y_D^2 (3 \cdot k \cdot \alpha - 3 \cdot k \cdot \alpha^2) + y_D^3 (\alpha^3 + 2 \cdot \alpha - 3 \cdot \alpha^2) \right)}{(k + y_D)^\alpha} \right) \cdot \\
& \left. - 3\mu_Y \cdot \sigma_Y^2 - \mu_Y^3 \right) \frac{1}{\sigma_Y^3}.
\end{aligned} \tag{2.18}$$

Nupjauto pastumto Pareto skirstinio parametrų parinkimui pasinaudojame momentų metodo, aprašyto **1.4** skyriuje, idėja sulyginti teorinius ir empirinius momentus. Kiekvienai pasėlių kultūrai parametrai  $d = y_K$  ir  $y_D$  parenkami pagal realius duomenis, t.y.  $y_K$  lygus minimaliai duomenų reikšmei,  $y_D$  lygus maksimaliai duomenų reikšmei. Bėlieka parinkti parametrus  $k$  ir  $\alpha$ . Sudarome galimų  $k$  ir  $\alpha$  reikšmių lentelę, kiekvienam  $k$  ir  $\alpha$  reikšmių rinkiniui pagal **(2.16) – (2.18)** apskaičiuojame nupjauto pastumto Pareto skirstinio vidurkį, dispersiją ir asimetriškumą. Tuomet kiekvienam  $k$  ir  $\alpha$  reikšmių rinkiniui įvertiname paklaidą

$$\begin{aligned}
\text{Paklaidos įvertis}(k, \alpha) = & \frac{2 \left| \mu_{\text{Duomenų}} - \mu_{\text{Pareto}} \right|}{\mu_{\text{Duomenų}} + \mu_{\text{Pareto}}} + \left| \varepsilon_{\text{Duomenų}} - \varepsilon_{\text{Pareto}} \right| \\
& + \left| \gamma_{1 \text{ Duomenų}} - \gamma_{1 \text{ Pareto}} \right|,
\end{aligned} \tag{2.19}$$

čia  $\varepsilon = \frac{\sqrt{\sigma^2}}{\mu}$  yra santykinė nuokrypa. Parenkamas toks  $k$  ir  $\alpha$  reikšmių rinkinys, kuriam paklaida yra minimali. Paklaidų paviršiaus pavyzdys pateiktas **2.11 pav.**



**2.11 pav. Kviečių nuostolingumo aproksimavimo nupjautu pastumtu Pareto skirstiniu paklaidų paviršius**

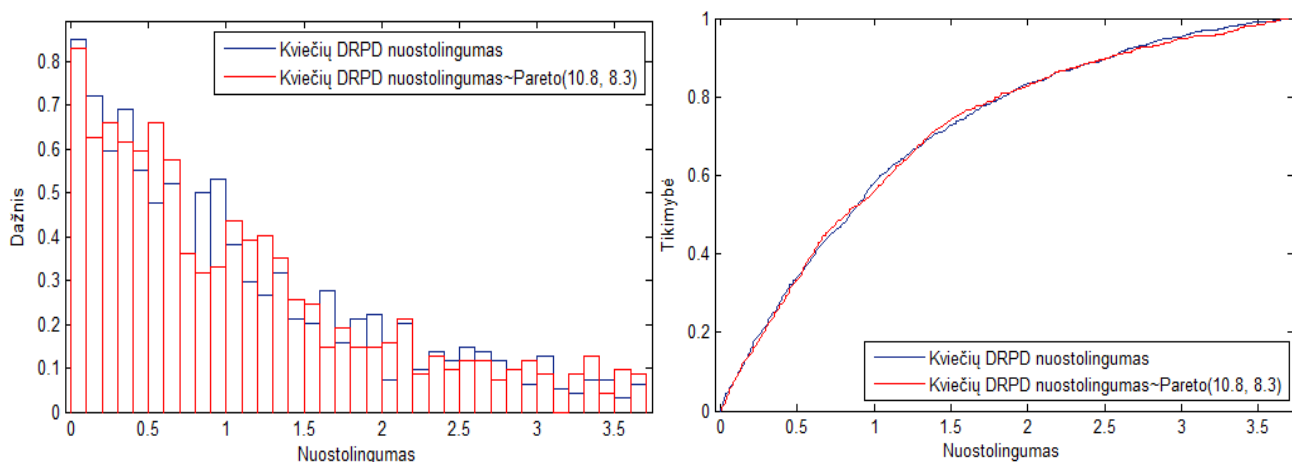
Gauti skirstinio parametrų parinkimo rezultatai pateikti **2.10 lentelėje**.

**2.10 lentelė.**

**Nupjauto pastumto Pareto skirstinio charakteristikos**

	Skirstinio parametrai		Vidurkis	Dispersija	Asimetriškumas
	alfa	k			
<b>Miežių DRPD nuostolingumas</b>	29.9	15.1	1.5520	1.5906	1.0062
<b>Kviečių DRPD nuostolingumas</b>	10.8	8.3	1.0884	0.8381	0.9268
<b>Rapsų DRPD nuostolingumas</b>	3.7	3.1	1.4016	1.7850	1.1954
<b>Bulvių DRPD nuostolingumas</b>	29.5	13.2	2.1688	3.4021	0.9163
<b>Cukrinių runkelių DRPD nuostolingumas</b>	34.9	21.5	1.1810	1.1484	1.1375

**2.12 pav.** pateiktas duomenų ir nupjauto pastumto Pareto skirstinio grafinis palyginimas, o **2.11 lentelėje** pateikti skirtumai tarp nupjauto pastumto Pareto skirstinio ir duomenų charakteristikų. Matome, kad nupjautas pastumtas Pareto skirstinys gana tiksliai atitinka duomenų pasiskirstymą.



**2.12 pav. Kviečių DRPD nuostolingumo ir nupjauto pastumto Pareto atsitiktinių dydžių histogramų ir pasiskirstymo funkcijų grafikai**

**2.11 lentelė.**

**Aproksimavimo paklaidos**

	<b>Skirtumai tarp duomenų ir pastumto nupjauto Pareto skirstinio</b>		
	<b>vidurkio</b>	<b>dispersijos</b>	<b>asimetriškumo</b>
<b>Miežių DRPD nuostolingumas</b>	0.0394	-0.2289	-0.0957
<b>Kviečių DRPD nuostolingumas</b>	-0.0131	-0.0245	0.0187
<b>Rapsų DRPD nuostolingumas</b>	0.0514	-0.4006	-0.0929
<b>Bulvių DRPD nuostolingumas</b>	0.0044	-0.0429	0.1957
<b>Cukrinių runkelių DRPD nuostolingumas</b>	-0.0582	-0.0896	0.0134

Visi paklaidų paviršius, histogramų ir pasiskirstymo funkcijų grafikai pateikti **5 priede**.

### **2.3. DRPD ŽALOS DYDŽIO IR INTENSYVUMO TYRIMAS**

Šioje dalyje tyrėme daugelio rizikų pasėlių draudimo žalų intensyvumą ir žalos dydį vienam hektarui. Pirmiausia iš turimų duomenų apskaičiavome žalų intensyvumą

$$\text{Žalų intensyvumas} = \frac{\text{Polisų, kuriems užfiksuota žala, skaičius}}{\text{Polisų, kuriems sumokėtos įmokos, skaičius}}$$

Taip pat apskaičiavome žalos dydį vienam hektarui. Tuomet kiekvienai pasėlių kultūrai radome žalų intensyvumo ir žalos dydžio 1 ha vidurkį, standartinę nuokrypį ir asimetriškumą. Atskirai apskaičiuojame pilnų duomenų charakteristikas, ir charakteristikas, kai žalų intensyvumas mažesnis nei 1 ir žalų intensyvumas lygus 1. Rezultatai pateikti **2.12 lentelėje**. Matome, kad atskyrus atvejį, kai

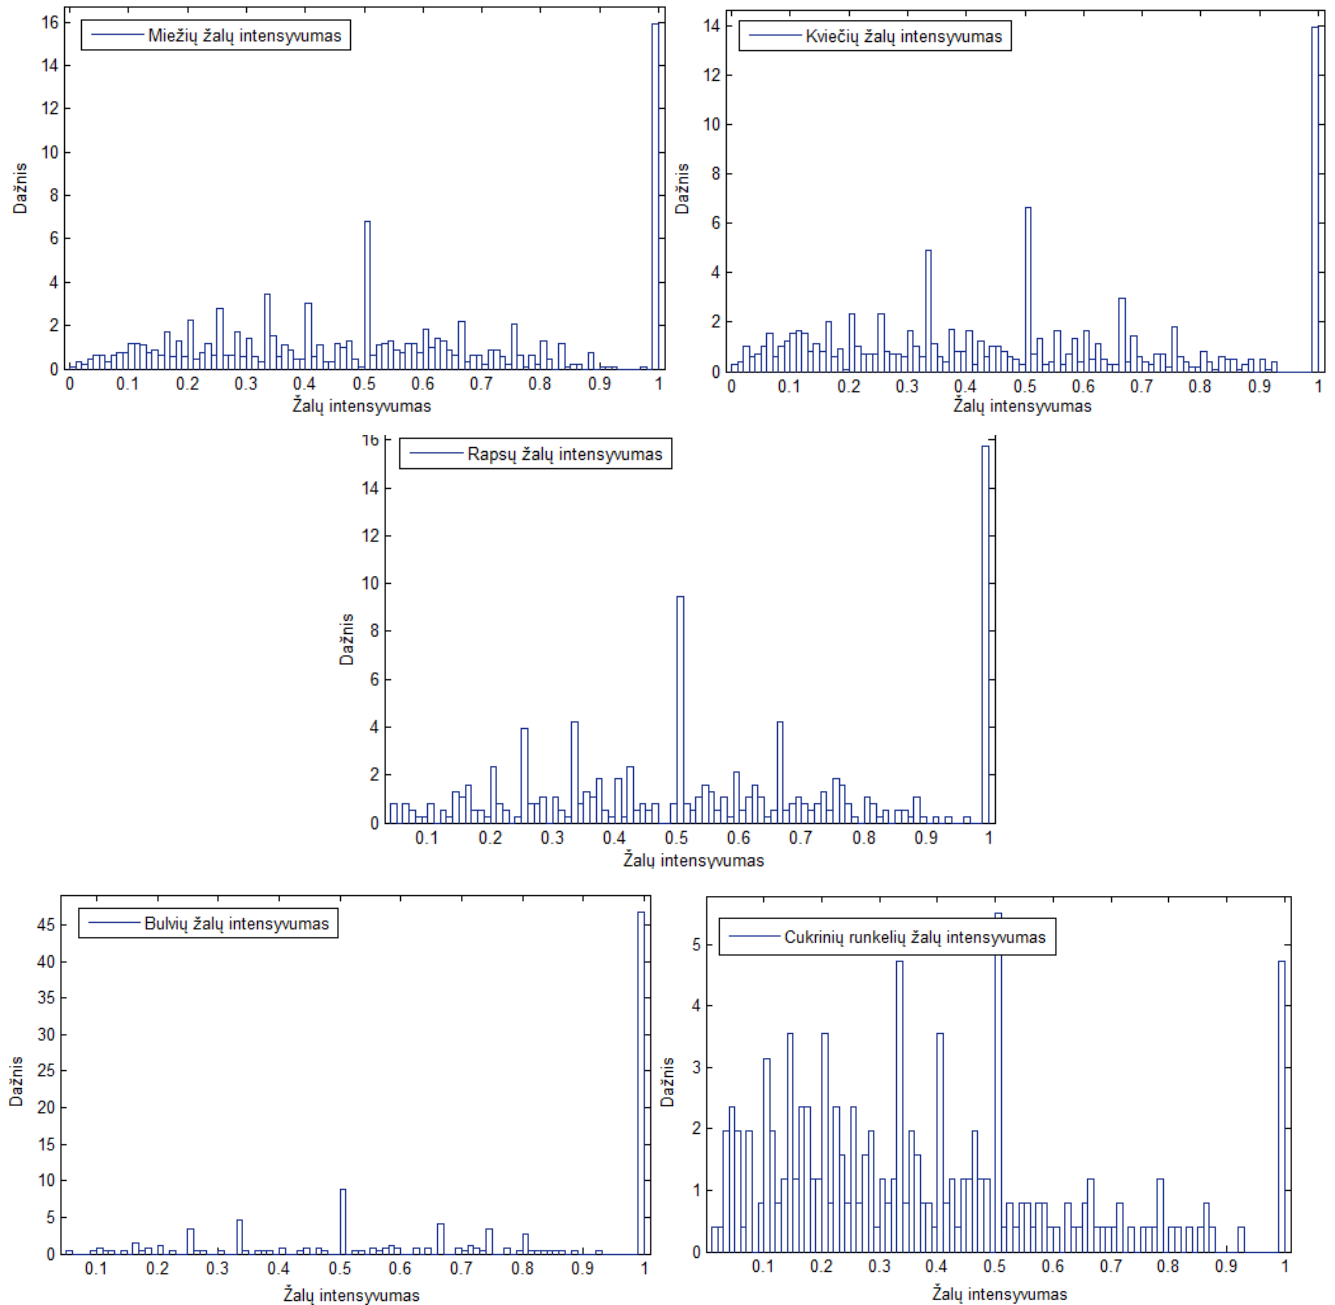
intensyvumas lygus 1, sumažėja intensyvumo asimetriškumas, o santykinis nuokrypis keičiasi nežymiai.

2.12 lentelė.

**Žalų intensyvumo ir žalos dydžio 1 ha charakteristikos**

	Vidurkis			Standartinis nuokrypis		Asimetriškumas	
	Pilni duomenys	Intensyvumas < 1	Intensyvumas = 1	Pilni duomenys	Intensyvumas < 1	Pilni duomenys	Intensyvumas < 1
<b>Miežiai</b>							
<b>Intensyvumas</b>	0.52	0.43		0.29	0.22	0.26	0.08
<b>Žalos dydis 1 ha</b>	58.65	52.38	91.78	47.74	42.72	1.69	2.14
<b>Kviečiai</b>							
<b>Intensyvumas</b>	0.49	0.41		0.30	0.23	0.34	0.22
<b>Žalos dydis 1 ha</b>	41.32	37.24	66.49	42.60	38.56	3.47	4.57
<b>Rapsai</b>							
<b>Intensyvumas</b>	0.56	0.48		0.28	0.22	0.16	0.00
<b>Žalos dydis 1 ha</b>	66.76	63.77	82.77	48.73	47.09	1.43	1.71
<b>Bulvės</b>							
<b>Intensyvumas</b>	0.74	0.51		0.29	0.22	-0.66	-0.17
<b>Žalos dydis 1 ha</b>	667.70	547.63	804.38	590.07	511.06	1.60	2.70
<b>Cukriniai runkeliai</b>							
<b>Intensyvumas</b>	0.25	0.21		0.37	0.34	0.85	0.61
<b>Žalos dydis 1 ha</b>	289.07	287.57	301.71	247.46	273.11	3.93	4.12

Ta duomenų dalis, kuriai intensyvumas lygus 1, turi kitokį pasiskirstymą negu likę duomenys (žr. **2.13 pav.**). Todėl tikslinga šiuos duomenis nagrinėti atskirai.



**2.13 pav. Miežių, kviečių, rapsų, bulvių ir cukrinių runkelių žalų intensyvumo histogramos**


Taip pat apskaičiuojame Spirmeno koreliacijos tarp žalos dydžio 1 ha ir žalų intensyvumo koeficientus, kai naudojami pilni duomenys ir kai žalų intensyvumas mažesnis nei 1. Rezultatai pateikti **2.13 lentelėje**. Matome, kad dydžiai koreliuoti, tačiau Spirmeno koreliacijos koeficientas nenurodo, ar tarp nagrinėjamų dydžių yra tiesinis ar netiesinis ryšys.

2.13 lentelė.

## Spirmeno koreliacijos tarp žalos dydžio 1 ha ir žalų intensyvumo koeficientai

	Miežiai	Kviečiai	Rapsai	Bulvės	Cukriniai runkeliai
<b>Pilni duomenys</b>	0.46502	0.45442	0.40873	0.28514	0.28297
<b>Žalų intensyvumas &lt; 1</b>	0.44875	0.47887	0.47279	0.40852	0.32426


Tikriname, ar tarp žalos dydžio 1 ha ir žalų intensyvumo yra tiesinis ryšys. Taikome regresinę analizę. Ištyrę miežių žalos dydžio ir žalų intensyvumo modelio liekanas, matome, kad liekanų dispersija nėra pastovi. Be to modelio apibrėžtumo koeficientas tik 0.1 (**2.14 pav.**). Panašūs rezultatai gauti ir kitoms tirtoms pasėlių kultūroms. Tai rodo, kad tarp žalos dydžio 1 ha ir žalų intensyvumo nėra tiesinės priklausomybės. Visi regresinės analizės rezultatai pateikti **8 priede**.



2.14 pav. Miežių modelio normuotų liekanų grafikas

Patikrinome, ar yra ilgalaikės žalos dydžio 1 ha ir žalos intensyvumo kitimo tendencijos (žr. **2.15 pav.**). Iki 1999 metų pastebime tiek vidutinės 1 ha žalos, tiek žalos 1 ha standartinio nuokrypio, tiek vidutinio žalų intensyvumo didėjimo tendenciją. Nuo 2000 metų jokios aiškios kitimo tendencijos nematome. Žalų intensyvumo standartinis nuokrypis taip pat neturi aiškios kitimo tendencijos – per visą nagrinėtą laikotarpį keičiasi nežymiai.





**2.15 pav. Žalos dydžio 1 ha ir žalos intensyvumo vidurkio bei standartinio nuokrypio kitimas**

### 3. PROGRAMINĖ REALIZACIJA IR INSTRUKCIJA VARTOTOJUI

Duomenų perrinkimas ir vienmatė bei daugialypė regresinė analizė atlikta su programine įranga SAS. Pasiskirstymo tyrimui, trūkstančių duomenų reikšmių generavimui ir skirstinio parametrų radimui naudota programinė įranga MATLAB.

Paleidus SAS programos rinkmenas OroSalygos.sas ir Draudimas.sas, svarbu nurodyti kur bus saugomos duomenų lentelės ir iš kur bus nuskaitomi duomenys, esantys tekstinėse ir csv rinkmenose. Yra sukurti katalogai: „Meteo“ ir „Draudimas“. Kataloge „Meteo“ yra sudėtos meteorologinių duomenų rinkmenos, kataloge „Draudimas“ – draudimo duomenų rinkmenos. Reikia sukurti katalogą „Duomenys“, kuriame bus saugomos SAS duomenų lentelės. Vieną kartą paleidus programas OroSalygos.sas ir Draudimas.sas, duomenų lentelės bus išsaugotos kataloge „Duomenys“. Atliktas tyrimas penkioms pasėlių kultūroms, todėl kiekvienai iš jų sukurta atskira rinkmena daugialypei regresinei analizei atlikti: Kvieciai.sas, Mieziai.sas, Rapsai.sas, Bulves.sas ir CukrRunkeliai.sas. Paleidus šias rinkmenas, reikia nurodyti katalogą, kuriame išsaugotos duomenų lentelės. Visi rezultatai ir grafikai yra išvedami į išvesties langą.

Paleidus SAS programos rinkmeną ZaluTyrimas.sas, svarbu nurodyti kur išsaugotos duomenų lentelės iš pirmosios tyrimo dalies. Atliktas tyrimas penkioms pasėlių kultūroms. Visi rezultatai ir grafikai yra išvedami į išvesties langą.

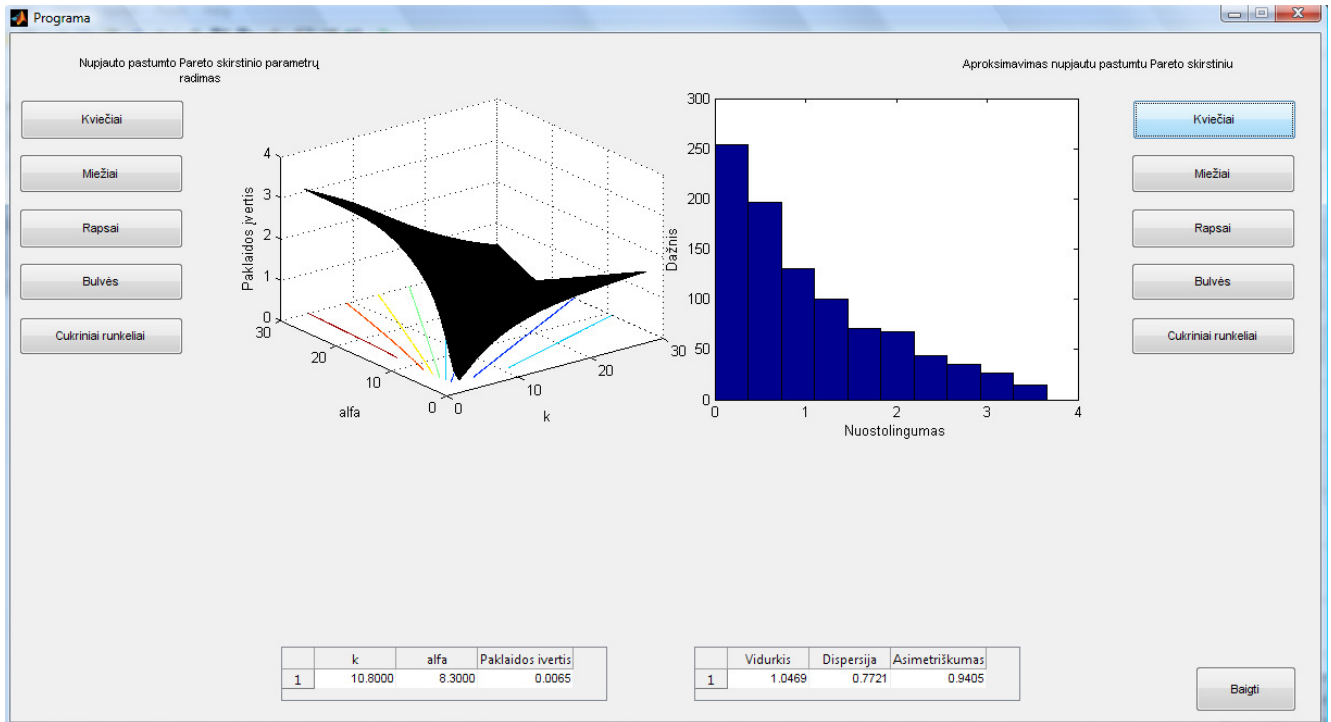
Vartotojo sąsaja yra sukurta naudojant MATLAB 7.8.0 (R2009a) programinį paketą. Sukurta programos rinkmena pavadinimu Programa.m, o programos langas pavadinimu Programa.fig. Vartotojas, norėdamas pradėti darbą su programa, turi nurodyti katalogą, kuriame yra programos rinkmena (angl. Current directory). Vartotojo sąsaja sukurta naudojantis MATLAB modulį „Guide“.



Norint atidaryti programos langą (žr. **3.1 pav.**), MATLAB darbo lauke reikia parašyti žodelį „Programa“ ir paspausti „Enter“.

Dešinėje pusėje galima pasirinkti, kurios pasėlių kultūros nuostolingumo aproksimavimo nupjautu pastumtu Pareto skirstiniu parametrus norima rasti. Braižomas paklaidų įverčio paviršiaus grafikas, o apačioje nurodomos parametrų ir paklaidos įverčio reikšmės paviršiaus minimumo taške. Kairėje pusėje esančiais mygtukais galima pasirinkti, kurios pasėlių kultūros nuostolingumo duomenis norima sugeneruoti. Dydžiai generuojami pagal nupjautą pastumtą Pareto skirstinį. Nubraižoma sugeneruotų dydžių histograma ir apačioje nurodomas sugeneruotų atsitiktinių dydžių vidurkis, dispersija ir asimetriškumas.

Norint detaliau nagrinėti histogramas ar palyginti skirstinio funkcijas, MATLAB darbo lauke reikia įvesti „dfittool“ ir paspausti „Enter“. Atidaromas priemonės „Distribution Fitting Tool“ langas. Jame vartotojas gali pasirinkti, kurių dydžių pasiskirstymo, tankio funkcijas nori peržiūrėti ir analizuoti.



3.1 pav. Programos langas

## DISKUSIJOS

Atliekant tiesinės priklausomybės nuo oro sąlygų modelių tyrimą, gauta, kad modelis galioja tik tuomet, kai nuostolingumo duomenims pritaikoma laipsninė transformacija. Taip yra todėl, kad tiriamame regione draudimo nuostolingumas pasižymi dideliu asimetriškumu ir tiesiogiai taikyti regresinės analizės negalime. Pritaikius transformaciją, gautas normalusis priklausomo kintamojo pasiskirstymas. Tuomet galioja daugialypės regresijos modelis. Tačiau pagal sudarytą modelį negalima prognozuoti nuostolingumo reikšmės. Be to gautas mažas modelių apibrėžtumo koeficientas rodo, kad draudimo nuostolingumą veikia ne tik oro sąlygos, bet ir kiti faktoriai.

Dažnai draudimo duomenų aproksimavimui siūlomi gama, log-normalusis arba Pareto skirstinys. Šiuo atveju gauta, kad tinkamiausias nupjautas pastumtas Pareto skirstinys. Skirstinio parametrai skaičiuoti remiantis momentų metodu. Momentų metodu gauti įverčiai yra suderinti, t.y. didėjant stebėjimų skaičiui, įvertis pagal tikimybę artėja prie tikslios parametro reikšmės. Tai paaiškina, kodėl kai kurioms pasėlių kultūroms gauti tikslesni įverčiai.

## IŠVADOS

- Sudaryti pasirinktų pasėlių kultūrų draudimo nuostolingumo tiesinės priklausomybės nuo oro sąlygų modeliai.
- Gauti maži transformuoto nuostolingumo modelio apibrėžtumo koeficientai rodo, kad nuostolingumas priklauso ne tik nuo oro sąlygų.
- Iš trijų nagrinėtų skirstinių, draudimo nuostolingumo duomenų aproksimavimui geriausiai tinka nupjautas pastumtas Pareto skirstinys.
- Tarp žalos dydžio vienam hektarui ir žalų intensyvumo nėra tiesinės priklausomybės.
- 1995 – 1999 m. tiek vidutinė 1 ha žalos, tiek žalos 1 ha standartinis nuokrypis, tiek vidutinis žalų intensyvumas didėjo. 2000 – 2005 m. aiškios šių dydžių kitimo tendencijos nėra. Žalų intensyvumo standartinis nuokrypis 1995 – 2005 m. keičiasi nežymiai.

## REKOMENDACIJOS

Tolimesniuose tyrimuose galima:

- Sudaryti draudimo nuostolingumo priklausomybės nuo oro sąlygų netiesinį modelį.
- Skirstinių parametrų radimui taikyti maksimalaus tikėtimumo metodą ir palyginti rezultatus su momentų metodo rezultatais.
- Taikyti aproksimavimą skirstinių mišiniais.

## LITERATŪRA

1. Mafoua E. K.;Turvey C. G., Effects of weather events on loss ratios for crop insurance products: a county-level panel data analysis. American Agricultural Economics Association,2004 Annual meeting, August 1-4, Denver, CO, <http://purl.umn.edu/20113>;
2. Risk management agency <http://www.rma.usda.gov/policies/>
3. Rytgaard M., Estimation in the Pareto distribution,  
<http://www.actuaries.org/LIBRARY/ASTIN/vol20no2/201.pdf>
4. Rudzkis R., Kavaliauskas M., Daugiamatė statistinė analizė. Paskaitų konspektas, 2008-04-16.
5. SAS Institute Inc. / SAS OnlineDoc 9.1 <http://support.sas.com/91doc/docMainpage.jsp>
6. Stapleton J.H., Models for probability and statistical inference. Theory and applications., John Wiley & Sons Inc., Hoboken, New Jersey, USA, 2008 m.] 148-150 psl., 167-173 psl.
7. The North Dakota Agricultural Weather Network (NDAWN)  
<http://ndawn.ndsu.nodak.edu/applications.html>
8. Weisber S., Applied linear regression, John Wiley & Sons, Inc., Hoboken, New Jersey, JAV, 2005, 148 psl.
9. Kim K., Tim N., Univariate and multivariate general linear models. Theory and applications with SAS. Chapman & Hall/CRC, USA, 2007.

## **PADĖKOS**

Nuoširdžiai dėkoju savo darbo vadovui doc. dr. G. Račkauskui už patarimus, idėjas, pataisymus. Taip pat draudimo kompanijos atstovams už skirtą laiką konsultacijai ir patarimus.



## PRIEDAI

### 1 PRIEDAS. TRŪKSTAMŲ DUOMENŲ REIKŠMIŲ UŽPILDYMAS


Trūkstamoms reikšmėms meteorologinių duomenų rinkmenose užpildyti buvo pasinaudota programa MATLAB. Pirmiausia buvo pasinaudota priemone Distribution Fitting Tool ir ištirtas kritulių kiekio pasiskirstymo dėsnis. Tuomet buvo sugeneruotas trūkstamas duomenų kiekis, remiantis gautais parametrais. Visų meteorologinių stotelių kritulių kiekio duomenims geriausiai tiko eksponentinis skirstinys.

1. Barnes apygarda. Trūkstami duomenys: 2002 m. rugpjūčio mėn. Kritulių kiekis pasiskirstęs pagal eksponentinį dėsnį su parametru  $\mu = 0.0562969$ .

```
Distribution:      Exponential
Log likelihood:   7446.51
Domain:          0 <= y < Inf
Mean:           0.0562969
Variance:       0.00316935
```

```
Parameter  Estimate  Std. Err.
mu         0.0562969  0.000893828
```

```
Estimated covariance of parameter estimates:
      mu
mu    7.98928e-007
```




2. Richland apygarda. Trūkstami duomenys: 2005 m. gegužės mėn. Kritulių kiekis pasiskirstęs pagal eksponentinį dėsnį su parametru  $\mu = 0.0647103$ .

```
Distribution:      Exponential
Log likelihood:   6899.2
Domain:          0 <= y < Inf
Mean:           0.0647103
Variance:       0.00418743
```

```
Parameter  Estimate  Std. Err.
mu         0.0647103  0.00102702
```

```
Estimated covariance of parameter estimates:
      mu
mu    1.05477e-006
```




3. Steele apygarda. Trūkstami duomenys: 2000 m. rugpjūčio mėn., 2003 m. lapkričio mėn. Kritulių kiekis pasiskirstęs pagal eksponentinį dėsnį su parametru  $\mu = 0.0569588$ .

```
Distribution:      Exponential
Log likelihood:   7269.57
Domain:          0 <= y < Inf
Mean:           0.0569588
Variance:       0.0032443
```

```
Parameter  Estimate  Std. Err.
mu         0.0569588  0.000912421
```

```
Estimated covariance of parameter estimates:
      mu
mu    8.32512e-007
```




4. Towner apygarda. Trūkstami duomenys: 2001 m. gegužės ir gruodžio mėn., 2002 m. kovo mėn., 2004 m. balandžio mėn., 2005 m. vasario mėn. Kritulių kiekis pasiskirstęs pagal eksponentinį dėsnį su parametru  $\mu = 0.0527821$ .

```
Distribution:      Exponential
Log likelihood:   7352.77
Domain:          0 <= y < Inf
Mean:           0.0527821
Variance:       0.00278595
```

```
Parameter  Estimate  Std. Err.
mu         0.0527821  0.000857708
```

```
Estimated covariance of parameter estimates:
      mu
mu    7.35663e-007
```




5. Griggs apygarda. Trūkstami duomenys: 2000 m. balandžio ir gegužės mėn., 2001 m. vasario mėn. Kritulių kiekis pasiskirstęs pagal eksponentinį dėsnį su parametru  $\mu = 0.0623095$ .

```
Distribution:      Exponential
Log likelihood:   6665.76
Domain:          0 <= y < Inf
Mean:           0.0623095
Variance:       0.00388248
```

```
Parameter  Estimate  Std. Err.
mu         0.0623095  0.00101697
```

```
Estimated covariance of parameter estimates:
      mu
mu    1.03422e-006
```




6. Ransom apygarda. Trūkstami duomenys: 1997 m. sausio mėn., 2003 m. spalio mėn., 2004 m. liepos mėn. Kritulių kiekis pasiskirstęs pagal eksponentinį dėsnį su parametru  $\mu = 0.0619081$ .

Distribution: Exponential  
 Log likelihood: 6827.24  
 Domain:  $0 \leq y < \text{Inf}$   
 Mean: 0.0619081  
 Variance: 0.00383262

Parameter	Estimate	Std. Err.
mu	0.0619081	0.00100021

Estimated covariance of parameter estimates:  
 mu  
 mu 1.00042e-006




7. Traill apygarda. Trūkstami duomenys: 2001m. gruodžio mėn., 2002 m. sausio, vasario ir kovo mėn., 2003 m. sausio, vasario ir kovo mėn., 2005 m. lapkričio mėn. Kritulių kiekis pasiskirstęs pagal eksponentinį dėsnį su parametru  $\mu = 0.0674123$ .

Distribution: Exponential  
 Log likelihood: 6288.81  
 Domain:  $0 \leq y < \text{Inf}$   
 Mean: 0.0674123  
 Variance: 0.00454442

Parameter	Estimate	Std. Err.
mu	0.0674123	0.00110735

Estimated covariance of parameter estimates:  
 mu  
 mu 1.22623e-006




8. Sargent apygarda. Trūkstami duomenys: 2000 m. gegužės mėn., 2001 m. rugpjūčio ir lapkričio mėn., 2002 m. sausio ir rugsėjo mėn., 2003 m. vasario, gegužės ir liepos mėn. Kritulių kiekis pasiskirstęs pagal eksponentinį dėsnį su parametru  $\mu = 0.0689903$ .

Distribution: Exponential  
 Log likelihood: 6199.72  
 Domain:  $0 \leq y < \text{Inf}$   
 Mean: 0.0689903  
 Variance: 0.00475966

Parameter	Estimate	Std. Err.
mu	0.0689903	0.00113358

Estimated covariance of parameter estimates:  
 mu  
 mu 1.28501e-006



## 2 PRIEDAS. DUOMENŲ PAVYZDYS

### Draudimo duomenų pavyzdys:

Year	Crop	Pol Sold	PolEarn Prem	Pol Indemn	NetAcres	Subsidy	Liability	TotalPrem	Indemn	LossRatio	County	Coverage
1995	BARLEY	31	31	17	6281	11380	303927	18971	36864	1.943176	Barnes	BUYUP50
1995	BARLEY	49	49	6	7372	13568	397852	22609	11672	0.516255	Cass	BUYUP50
1995	BARLEY	20	20	9	5674	9537	269102	15893	26970	1.696974	Cavalier	BUYUP50
1995	BARLEY	4	4	3	543	951	24241	1585	13686	8.6347	Dickey	BUYUP50
1995	BARLEY	37	37	16	9502	15833	555141	26385	73159	2.77275	Grand Forks	BUYUP50
1995	BARLEY	9	9	1	1178	1804	40646	3006	3833	1.275116	Griggs	BUYUP50
1995	BARLEY	25	25	13	3484	5905	126311	9838	21259	2.160907	Nelson	BUYUP50
1995	BARLEY	34	34	2	5141	9073	287521	15133	5298	0.350096	Pembina	BUYUP50
1995	BARLEY	49	49	9	9849	16217	408841	27034	17628	0.652068	Ramsey	BUYUP50
1995	BARLEY	6	6	2	909	1543	40754	2569	4057	1.579214	Ransom	BUYUP50
1995	BARLEY	14	14	6	1313	2382	63760	3974	5296	1.332662	Richland	BUYUP50
1995	BARLEY	13	13	4	2010	3681	71433	6137	7269	1.184455	Stutsman	BUYUP50
1995	BARLEY	17	17	8	3500	6122	119933	10202	15865	1.555087	Towner	BUYUP50
...	...	...	...	...	...	...	...	...	...	...	...	...

### Meteorologinių duomenų pavyzdys:

Month	Day	Year	Tmax	Tmin	PRCP
1	1	1995	9	-9	0
1	2	1995	11	-10	0
1	3	1995	11	-14	0
1	4	1995	-4	-21	0
1	5	1995	6	-11	0
1	6	1995	19	-11	0
1	7	1995	8	-14	0
1	8	1995	9	-8	0
1	9	1995	8	-10	0

Month	Day	Year	Tmax	Tmin	PRCP
1	10	1995	13	-2	0.1
1	11	1995	20	13	0
...	...	...	...	...	...
2	23	1995	42	24	0
2	24	1995	37	19	0
2	25	1995	36	15	0.03
2	26	1995	21	16	0
...	...	...	...	...	...

### 3 PRIEDAS. JAV PLATINAMI DRAUDIMO PLANAI

Daugumą JAV platinamų draudimo planų galima suskirstyti į dvi grupes: derlingumo ir pajamų draudimus.

Derlingumu paremti draudimo planai:

- **Daugelio rizikų pasėlių draudimas (angl. Multi peril crop insurance, MPCID) arba pasėlių produkcijos istorijos (angl. Actual Production History, APH)** – populiariausias draudimo planas. Ūkininkas apsidraudžia nuo natūralių rizikų (sausros, liūčių, krušos, vėjo ir t.t.) įtakoto derlingumo praradimo. Draudėjas pasirenka padengimo kategoriją – vidutinį derlingumą procentais<sup>12</sup>. Jei derlingumas bus mažesnis nei pasirinktas, ūkininkas gaus draudimo išmoką. Taip pat pasirenka prognozuojamos kainos procentą<sup>13</sup>. Žalos skaičiuojamos dauginant skirtumą tarp prognozuojamos kainos ir kainos po derliaus nuėmimo iš pasirinkto procento.
- **Grupinis draudimo planas (angl. Group Risk Plan, GRP)** – žalų nustatyme naudojamas apygardos indeksas. Jei derlingumas apygardoje būna mažesnis nei ūkininko pasirinktas lygmuo<sup>14</sup>, išmokama draudimo išmoka. Šis draudimo planas pigesnis, tačiau individualūs derliaus praradimai ne visada kompensuojami. Jei visoje apygardoje derlingumas nėra mažesnis nei pasirinkta riba, tuomet ūkininkas negauna išmokos. Šį planą paprastai renkasi tie ūkininkai, kurių ūkių derlingumas artimas apygardos lygiui.
- **„Dolerio” planas (angl. Dollar Plan)** – draudimo sumos nustatymas remiasi pasėlių auginimo kaštais regione. Žala atsiranda tuomet, kai pasėlių derliaus vertė yra mažesnė nei draudimo suma. Ūkininkas gali pasirinkti draudimo sumą, t.y. procentą nuo maksimalios galimos draudimo sumos.
- **Kritulių kiekio indeksas (angl. Rainfall Index, RI)** remiasi meteorologiniais duomenimis, gaunamais iš Klimato prognozavimo centro (angl. NOAA’s Climate Prediction Center). Indeksas atspindi prognozuojamą kritulių kiekį tam tikrame regione per tam tikrą laikotarpį. Šalis dalinama į regionus pagal būtingas oro sąlygas.
- **Vegetacijos indeksas (angl. Vegetation Index, VI)** remiasi U.S. Geological Survey's Earth Resources Observation and Science (EROS) pateikiamu

<sup>12</sup> dažniausiai nuo 50 iki 75 %, bendru atveju nuo 50 iki 85 %, 5 % intervalais.

<sup>13</sup> tarp 55 ir 100 % nuo kainos, kurią kasmet nustato Rizikos valdymo agentūra (angl. Risk Management Agency, RMA)

<sup>14</sup> iki 90 % nuo prognozuojamo apygardos derlingumo.

vegetacijos indeksu, išvedamu pagal ilgalaikius žemės stebėjimus iš palydovų. Fiksuojami žemės žaliųjų plotų pasikeitimai nuo 1989. Šalis dalinama į regionus pagal būdingas oro sąlygas.

Pajamų draudimo planai:


- **Koreguotų bendrųjų pajamų (angl. Adjusted Gross Revenue, AGR)** – draudžiamos viso ūkio pajamos, o ne pajamos iš atskirų pasėlių kultūrų.
- **Pajamų iš pasėlių padengimas (angl. Crop Revenue Coverage, CRC)** – draudžiamos pajamos iš pasėlių auginimo. Remiamasi kainos ir derlingumo prognozėmis. Mokamos draudimo išmokos skaičiuojamos pagal didesniąją iš dviejų kainų: kainos po derliaus nuėmimo arba kainos augimo laikotarpio pradžioje.
- **Grupinis pajamų draudimas (angl. Group Risk Income Protection, GRIP)** – mokama draudimo išmoka, kai apygardoje vidutinės pajamos iš draudžiamos pasėlių kultūros būna mažesnės nei besidraudžiančiojo pasirinktas dydis.
- **Pajamų draudimas (angl. Income Protection, IP)** – draudžiama nuo pajamų sumažėjimo. Jei pasėlių kaina arba derlingumas sumažėja palyginus su prognozuotais dydžiais, tuomet mokama išmoka.
- **Pajamų garantija (angl. Revenue Assurance, RA)** – ūkininkas pasirenka draudimo sumą, lygią 65 – 75 % prognozuojamų pajamų.

Papildomas draudimas – **katastrofinis draudimo padengimas (angl. Catastrophic Coverage, CAT)**. Jei nuostoliai viršija 50%, tuomet tai nuostolių daliai, kuri viršija 50% apmokama 55% nuo nustatytos kainos. Už šį draudimą įmokas sumoka vyriausybė, tačiau ūkininkas turi apmokėti administracines išlaidas. [2]

## 4 PRIEDAS. REGRESIJOS REZULTATAI

### 1. Kviečių nuostolingumo tyrimas (pašalinus išskirtis):

#### a) Tikrasis nuostolingumas



4.1 pav. Kviečių DRPD nuostolingumo histograma

4.1 lentelė.

#### Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	44	303.25643	6.89219	7.27	<.0001
Error	931	882.63525	0.94805		
Corrected Total	975	1185.89168			

4.2 lentelė.

#### Dispersinės analizės rezultatai (2)

Root MSE	0.97368	R-Square	0.2557
Dependent Mean	1.19770	Adj R-Sq	0.2205
Coeff Var	81.29546		

## 4.3 lentelė.

## Parametų įverčių ir hipotezių tikrinimo rezultatai

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
Intercept	-0.86292	2.50671	-0.34	0.7307
BUYUP50	-0.24879	0.08259	-3.01	0.0027
BUYUP55	0.35871	0.15561	2.31	0.0214
BUYUP60	0.14859	0.12490	1.19	0.2345
BUYUP65	-0.32880	0.07475	-4.40	<.0001
BUYUP70	-0.28122	0.08310	-3.38	0.0007
BUYUP75	-0.15760	0.07852	-2.01	0.0450
BUYUP80	0.93500	0.16271	5.75	<.0001
BUYUP85	0.53797	0.14483	3.71	0.0002
CAT50	-0.96386	0.07908	-12.19	<.0001
JanPRCP	-0.22254	0.15773	-1.41	0.1586
FebPRCP	0.01937	0.11140	0.17	0.8620
MarPRCP	0.16170	0.12295	1.32	0.1888
AprPRCP	0.02455	0.21587	0.11	0.9095
MayPRCP	-0.29225	0.19279	-1.52	0.1299
JunPRCP	-0.08906	0.24336	-0.37	0.7145
JulPRCP	0.79672	0.40809	1.95	0.0512
AugPRCP	0.51860	0.29295	1.77	0.0770
SepPRCP	-0.63546	0.34501	-1.84	0.0658
OctPRCP	0.15691	0.20535	0.76	0.4450
NovPRCP	0.12253	0.10549	1.16	0.2457
DecPRCP	-0.02877	0.15956	-0.18	0.8569
JanGDDWB	-0.00660	0.00780	-0.85	0.3978
FebGDDWB	0.00543	0.00276	1.97	0.0492

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
MarGDDWB	0.00102	0.00172	0.60	0.5520
AprGDDWB	-0.00098295	0.00113	-0.87	0.3838
MayGDDWB	-0.00195	0.00136	-1.44	0.1499
JunGDDWB	-0.00245	0.00111	-2.20	0.0284
JulGDDWB	0.00571	0.00179	3.20	0.0014
AugGDDWB	0.00072647	0.00111	0.65	0.5139
SepGDDWB	-0.00200	0.00125	-1.60	0.1094
OctGDDWB	0.00127	0.00112	1.14	0.2560
NovGDDWB	-0.00100	0.00115	-0.87	0.3834
DecGDDWB	0.00221	0.00369	0.60	0.5501
JanPGWB	0.01860	0.00952	1.95	0.0511
FebPGWB	-0.00745	0.00239	-3.12	0.0018
MarPGWB	0.00004002	0.00092411	0.04	0.9655
AprPGWB	0.00026550	0.00063708	0.42	0.6770
MayPGWB	0.00035916	0.00026601	1.35	0.1773
JunPGWB	0.00008525	0.00023965	0.36	0.7221
JulPGWB	-0.00068917	0.00034682	-1.99	0.0472
AugPGWB	-0.00046025	0.00026688	-1.72	0.0849
SepPGWB	0.00061281	0.00042580	1.44	0.1504
OctPGWB	-0.00012494	0.00045329	-0.28	0.7829
NovPGWB	-0.00074439	0.00103	-0.72	0.4697
DecPGWB	-0.00203	0.00491	-0.41	0.6793
RESTRICT	1.04E-12	4.0338E-8	0.00	1.0000*


\* Probability computed using beta distribution.

## 4.4 lentelė.

## Modelio liekanos


Sum of Residuals	6.75508E-12
Sum of Squared Residuals	882.63525
Predicted Residual SS (PRESS)	979.97289





4.2 pav. Kviečių modelio normuotų liekanų grafikas

## b) Transformuotas nuostolingumas:



4.3 pav. Transformuoto kviečių nuostolingumo histograma

4.5 lentelė.

Hipotezės apie transformuoto kviečių nuostolingumo pasiskirstymo normalumą tikrinimas

Test	Statistic		p Value	
Kolmogorov-Smirnov	D	0.02103849	Pr > D	>0.150

4.6 lentelė.

## Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	44	27.26113	0.61957	8.69	<.0001
Error	931	66.40501	0.07133		
Corrected Total	975	93.66614			

## 4.7 lentelė.

## Dispersinės analizės rezultatai (2)

Root MSE	0.26707	R-Square	0.2910
Dependent Mean	0.95227	Adj R-Sq	0.2575
Coeff Var	28.04561		

## 4.8 lentelė.

## Parametru įverčių ir hipotezių tikrinimo rezultatai

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
Intercept	0.41100	0.68756	0.60	0.5501
BUYUP50	-0.06145	0.02265	-2.71	0.0068
BUYUP55	0.05670	0.04268	1.33	0.1844
BUYUP60	0.00177	0.03426	0.05	0.9587
BUYUP65	-0.03813	0.02050	-1.86	0.0632
BUYUP70	-0.03650	0.02279	-1.60	0.1096
BUYUP75	0.00144	0.02154	0.07	0.9467
BUYUP80	0.22353	0.04463	5.01	<.0001
BUYUP85	0.14819	0.03973	3.73	0.0002
CAT50	-0.29556	0.02169	-13.63	<.0001
JanPRCP	-0.07246	0.04326	-1.67	0.0943
FebPRCP	0.00542	0.03056	0.18	0.8591
MarPRCP	0.04874	0.03372	1.45	0.1487
AprPRCP	0.03081	0.05921	0.52	0.6029
MayPRCP	-0.07402	0.05288	-1.40	0.1619
JunPRCP	-0.00869	0.06675	-0.13	0.8964
JulPRCP	0.21195	0.11194	1.89	0.0586
AugPRCP	0.11681	0.08035	1.45	0.1464
SepPRCP	-0.10498	0.09463	-1.11	0.2676
OctPRCP	-0.02227	0.05633	-0.40	0.6927
NovPRCP	0.00958	0.02893	0.33	0.7405
DecPRCP	0.01102	0.04377	0.25	0.8012
JanGDDWB	-0.00217	0.00214	-1.01	0.3106
FebGDDWB	0.00098925	0.00075618	1.31	0.1911


Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
MarGDDWB	-0.00032237	0.00047175	-0.68	0.4945
AprGDDWB	-0.00036878	0.00030945	-1.19	0.2337
MayGDDWB	-0.00029901	0.00037167	-0.80	0.4213
JunGDDWB	-0.00070440	0.00030551	-2.31	0.0213
JulGDDWB	0.00175	0.00049018	3.57	0.0004
AugGDDWB	-0.00014631	0.00030513	-0.48	0.6317
SepGDDWB	-0.00036814	0.00034154	-1.08	0.2814
OctGDDWB	0.00017644	0.00030673	0.58	0.5653
NovGDDWB	-0.00025990	0.00031573	-0.82	0.4106
DecGDDWB	0.00119	0.00101	1.17	0.2407
JanPGWB	0.00441	0.00261	1.69	0.0915
FebPGWB	-0.00208	0.00065448	-3.18	0.0015
MarPGWB	0.00010422	0.00025347	0.41	0.6810
AprPGWB	0.00001574	0.00017474	0.09	0.9282
MayPGWB	0.00008506	0.00007296	1.17	0.2440
JunPGWB	0.00001407	0.00006573	0.21	0.8306
JulPGWB	-0.00017822	0.00009513	-1.87	0.0613
AugPGWB	-0.00009794	0.00007320	-1.34	0.1812
SepPGWB	0.00007226	0.00011679	0.62	0.5362
OctPGWB	0.00010566	0.00012433	0.85	0.3957
NovPGWB	-0.00006120	0.00028232	-0.22	0.8284
DecPGWB	-0.00032637	0.00135	-0.24	0.8085
RESTRICT	5.04206E-13	1.106213E-8	0.00	1.0000*

\* Probability computed using beta distribution.

4.9 lentelė.

## Modelio liekanos

Sum of Residuals	3.7057E-12
Sum of Squared Residuals	66.40501
Predicted Residual SS (PRESS)	73.43086



4.4 pav. Transformuoto kviečių nuostolingumo modelio normuotų liekanų grafikas

4.10 lentelė.

## Hipotezės apie liekanų vidurkio lygybę 0 tikrinimo rezultatai

Test	Statistic		p Value	
Student's t	t	0	Pr >  t	1.0000
Sign	M	10	Pr >=  M	0.5431
Signed Rank	S	2302	Pr >=  S	0.7940


4.11 lentelė.

## Hipotezės apie liekanų pasiskirstymo normalumą tikrinimo rezultatai

Test	Statistic		p Value	
Kolmogorov-Smirnov	D	0.998658	Pr > D	0.6797

## 2. Miežių nuostolingumo tyrimas (pašalinus išskirtis):

### a) Tikrasis nuo nuostolingumas



4.5 pav. Miežių DRPD nuostolingumo histograma

4.12 lentelė.

### Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	29	368.19342	12.69632	7.55	<.0001
Error	878	1475.98212	1.68107		
Corrected Total	907	1844.17554			

4.13 lentelė.

### Dispersinės analizės rezultatai (2)

Root MSE	1.29656	R-Square	0.1997
Dependent Mean	1.69131	Adj R-Sq	0.1732
Coeff Var	76.66038		

4.14 lentelė.

### Parametų įverčių ir hipotezių tikrinimo rezultatai

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
Intercept	-2.83312	3.32482	-0.85	0.3944
BUYUP50	-0.45166	0.12267	-3.68	0.0002
BUYUP55	1.04299	0.31545	3.31	0.0010
BUYUP60	0.09298	0.19265	0.48	0.6295
BUYUP65	-0.24569	0.10360	-2.37	0.0179

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
BUYUP70	-0.30960	0.11775	-2.63	0.0087
BUYUP75	0.02783	0.10671	0.26	0.7943
BUYUP80	0.21815	0.17092	1.28	0.2022
BUYUP85	0.35959	0.18625	1.93	0.0538
CAT50	-0.73460	0.11620	-6.32	<.0001

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
AprPRCP	-0.12524	0.27068	-0.46	0.6437
MayPRCP	0.40178	0.22934	1.75	0.0801
JunPRCP	0.44958	0.32075	1.40	0.1614
JulPRCP	-0.43240	0.53956	-0.80	0.4231
AugPRCP	0.31238	0.35593	0.88	0.3804
SepPRCP	-0.06887	0.42626	-0.16	0.8717
OctPRCP	-0.01751	0.23680	-0.07	0.9411
AprGDDWB	-0.00119	0.00123	-0.96	0.3366
MayGDDWB	-0.00017749	0.00158	-0.11	0.9105
JunGDDWB	0.00236	0.00142	1.67	0.0955
JulGDDWB	0.00513	0.00223	2.30	0.0217


Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
AugGDDWB	-0.00167	0.00139	-1.20	0.2298
SepGDDWB	-0.00310	0.00144	-2.15	0.0315
OctGDDWB	0.00134	0.00124	1.08	0.2800
AprPGWB	0.00114	0.00079829	1.42	0.1554
MayPGWB	-0.00051292	0.00032673	-1.57	0.1168
JunPGWB	-0.00037044	0.00031971	-1.16	0.2469
JulPGWB	0.00037442	0.00046189	0.81	0.4178
AugPGWB	-0.00031930	0.00032727	-0.98	0.3295
SepPGWB	0.00000892	0.00052731	0.02	0.9865
OctPGWB	0.00030302	0.00053048	0.57	0.5680
RESTRICT	8.88139E-13	1.713016E-8	0.00	1.0000*

\* Probability computed using beta distribution.

4.15 lentelė.


### Modelio liekanos

Sum of Residuals	0
Sum of Squared Residuals	1475.98212
Predicted Residual SS (PRESS)	1594.27821



4.6 pav. Miežių modelio normuotų liekanų grafikas

## b) Transformuotas nuostolingumas:



4.7 pav. Transformuoto miežių DRPD nuostolingumo histograma

4.16 lentelė.

## Hipotezės apie transformuoto miežių nuostolingumo pasiskirstymo normalumą tikrinimas

Test	Statistic		p Value	
Kolmogorov-Smirnov	D	0.02577879	Pr > D	0.147

4.17 lentelė.

## Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	29	37.52443	1.29395	10.18	<.0001
Error	878	111.60506	0.12711		
Corrected Total	907	149.12949			

4.18 lentelė.

## Dispersinės analizės rezultatai (2)

Root MSE	0.35653	R-Square	0.2516
Dependent Mean	1.12123	Adj R-Sq	0.2269
Coeff Var	31.79794		

4.19 lentelė.

## Parametrų įverčių ir hipotezių tikrinimo rezultatai

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
Intercept	-1.20668	0.91426	-1.32	0.1872
BUYUP50	-0.12753	0.03373	-3.78	0.0002
BUYUP55	0.12103	0.08674	1.40	0.1633

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
BUYUP60	0.07553	0.05298	1.43	0.1543
BUYUP65	-0.01982	0.02849	-0.70	0.4867
BUYUP70	-0.03631	0.03238	-1.12	0.2625

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
BUYUP75	0.04600	0.02934	1.57	0.1173
BUYUP80	0.07729	0.04700	1.64	0.1004
BUYUP85	0.13479	0.05121	2.63	0.0086
CAT50	-0.27098	0.03195	-8.48	<.0001
AprPRCP	0.02268	0.07443	0.30	0.7607
MayPRCP	0.20715	0.06306	3.28	0.0011
JunPRCP	0.22928	0.08820	2.60	0.0095
JulPRCP	-0.08859	0.14837	-0.60	0.5506
AugPRCP	0.13254	0.09787	1.35	0.1760
SepPRCP	-0.01013	0.11721	-0.09	0.9311
OctPRCP	0.01463	0.06512	0.22	0.8223
AprGDDWB	-0.00035687	0.00033901	-1.05	0.2928
MayGDDWB	0.00032442	0.00043383	0.75	0.4548


Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
JunGDDWB	0.00091774	0.00038969	2.36	0.0187
JulGDDWB	0.00161	0.00061287	2.63	0.0088
AugGDDWB	-0.00046550	0.00038187	-1.22	0.2232
SepGDDWB	-0.00056508	0.00039539	-1.43	0.1533
OctGDDWB	0.00032513	0.00034190	0.95	0.3419
AprPGWB	0.00008437	0.00021952	0.38	0.7008
MayPGWB	-0.00026103	0.00008984	-2.91	0.0038
JunPGWB	-0.00019742	0.00008791	-2.25	0.0250
JulPGWB	0.00008520	0.00012701	0.67	0.5025
AugPGWB	-0.00012456	0.00008999	-1.38	0.1667
SepPGWB	-0.00001977	0.00014500	-0.14	0.8916
OctPGWB	0.00007664	0.00014587	0.53	0.5994
RESTRICT	1.47185E-13	4.710454E-9	0.00	1.0000*

\* Probability computed using beta distribution.

4.20 lentelė.

### Modelio liekanos

Sum of Residuals	0
Sum of Squared Residuals	111.60506
Predicted Residual SS (PRESS)	120.11738



4.8 pav. Transformuoto miežių nuostolingumo modelio normuotų liekanų grafikas

4.21 lentelė.

### Hipotezės apie liekanų vidurkio lygybę 0 tikrinimo rezultatai

Test	Statistic		p Value	
Student's t	t	0	Pr >  t	1.0000
Sign	M	6	Pr >=  M	0.7151
Signed Rank	S	-652	Pr >=  S	0.9343


4.22 lentelė.

### Hipotezės apie liekanų pasiskirstymo normalumą tikrinimo rezultatai

Test	Statistic		p Value	
Kolmogorov-Smirnov	D	0.997466	Pr > D	0.1736

### 3. Rapsų nuostolingumo tyrimas (pašalinus išskirtis):

#### a) Tikrasis nuo nuostolingumas



4.9 pav. Rapsų DRPD nuostolingumo histograma

4.23 lentelė.

### Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	27	282.31241	10.45602	4.19	<.0001
Error	350	874.12677	2.49751		
Corrected Total	377	1156.43917			

4.24 lentelė.

### Dispersinės analizės rezultatai (1)

Root MSE	1.58035	R-Square	0.2441
Dependent Mean	1.76768	Adj R-Sq	0.1858
Coeff Var	89.40233		



4.25 lentelė.

## Parametų įverčių ir hipotezių tikrinimo rezultatai

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
Intercept	-0.59719	5.34669	-0.11	0.9111
BUYUP50	-0.23450	0.20596	-1.14	0.2557
BUYUP55	0.98246	0.49282	1.99	0.0470
BUYUP60	0.36493	0.26975	1.35	0.1770
BUYUP65	-0.03278	0.17818	-0.18	0.8541
BUYUP70	-0.28170	0.19635	-1.43	0.1523
BUYUP75	-0.37201	0.19709	-1.89	0.0599
CAT50	-0.42639	0.23951	-1.78	0.0759
AprPRCP	-1.45244	0.48763	-2.98	0.0031
MayPRCP	0.90711	0.41397	2.19	0.0291
JunPRCP	0.04942	0.55028	0.09	0.9285
JulPRCP	-0.25847	0.87221	-0.30	0.7671
AugPRCP	0.39049	0.49735	0.79	0.4329
SepPRCP	-1.98330	0.94021	-2.11	0.0356
OctPRCP	-0.04449	0.33753	-0.13	0.8952


Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
AprGDDC	-0.00976	0.00347	-2.82	0.0051
MayGDDC	-0.00232	0.00381	-0.61	0.5429
JunGDDC	0.00454	0.00347	1.31	0.1916
JulGDDC	0.00499	0.00482	1.03	0.3017
AugGDDC	0.00230	0.00249	0.92	0.3564
SepGDDC	-0.00727	0.00359	-2.03	0.0435
OctGDDC	0.00015912	0.00318	0.05	0.9601
AprPGC	0.00819	0.00266	3.08	0.0022
MayPGC	-0.00221	0.00098201	-2.25	0.0253
JunPGC	0.00008894	0.00079374	0.11	0.9108
JulPGC	0.00025919	0.00098423	0.26	0.7924
AugPGC	-0.00057841	0.00062393	-0.93	0.3545
SepPGC	0.00363	0.00178	2.04	0.0419
OctPGC	0.00008185	0.00143	0.06	0.9545
RESTRICT	1.42027E-13	.	.	.

\* Probability computed using beta distribution.

4.26 lentelė.


## Modelio liekanos

Sum of Residuals	0
Sum of Squared Residuals	874.12677
Predicted Residual SS (PRESS)	1048.24136



4.10 pav. Rapsų modelio normuotų liekanų grafikas

## b) Transformuotas nuostolingumas:



4.11 pav. Transformuoto rapsų DRPD nuostolingumo histograma

4.27 lentelė.

## Hipotezės apie transformuoto rapsų nuostolingumo pasiskirstymo normalumą tikrinimas

Test	Statistic		p Value	
Kolmogorov-Smirnov	D	0.03641523	Pr > D	>0.150

4.28 lentelė.

## Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	27	7.97646	0.29542	6.01	<.0001
Error	350	17.21662	0.04919		
Corrected Total	377	25.19309			

4.29 lentelė.

## Dispersinės analizės rezultatai (2)

Root MSE	0.22179	R-Square	0.3166
Dependent Mean	1.04537	Adj R-Sq	0.2639
Coeff Var	21.21635		

4.30 lentelė.

## Parametrų įverčių ir hipotezių tikrinimo rezultatai

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
Intercept	0.76898	0.75036	1.02	0.3062
BUYUP50	-0.02710	0.02890	-0.94	0.3491
BUYUP55	0.10399	0.06916	1.50	0.1336

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
BUYUP60	0.01581	0.03786	0.42	0.6765
BUYUP65	0.04634	0.02501	1.85	0.0647
BUYUP70	0.00681	0.02756	0.25	0.8050

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
BUYUP75	0.00587	0.02766	0.21	0.8319
CAT50	-0.15172	0.03361	-4.51	<.0001
AprPRCP	-0.00852	0.00269	-3.16	0.0017
MayPRCP	0.00453	0.00229	1.98	0.0486
JunPRCP	-0.00001228	0.00304	-0.00	0.9968
JulPRCP	-0.00104	0.00482	-0.22	0.8296
AugPRCP	0.00517	0.00275	1.88	0.0609
SepPRCP	-0.01578	0.00519	-3.04	0.0026
OctPRCP	-0.00099169	0.00186	-0.53	0.5952
AprGDDC	-0.00310	0.00087542	-3.54	0.0005
MayGDDC	-0.00103	0.00096364	-1.07	0.2849
JunGDDC	0.00098105	0.00087662	1.12	0.2638


Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
JulGDDC	0.00175	0.00122	1.44	0.1517
AugGDDC	0.00079070	0.00062814	1.26	0.2089
SepGDDC	-0.00237	0.00090617	-2.62	0.0093
OctGDDC	0.00021262	0.00080328	0.26	0.7914
AprPGC	0.00007929	0.00002645	3.00	0.0029
MayPGC	-0.00001971	0.00000977	-2.02	0.0443
JunPGC	0.00000189	0.00000789	0.24	0.8113
JulPGC	0.00000228	0.00000979	0.23	0.8158
AugPGC	-0.00001256	0.00000621	-2.02	0.0437
SepPGC	0.00004873	0.00001768	2.76	0.0062
OctPGC	0.00000828	0.00001425	0.58	0.5614
RESTRICT	-1.0317E-13	.	.	.

\* Probability computed using beta distribution.

4.31 lentelė.

### Modelio liekanos

Sum of Residuals	0
Sum of Squared Residuals	17.21662
Predicted Residual SS (PRESS)	20.29256



4.12 pav. Transformuoto rapsų nuostolingumo modelio normuotų liekanų grafikas

4.32 lentelė.

### Hipotezės apie liekanų vidurkio lygumą 0 tikrinimo rezultatai

Test	Statistic		p Value	
Student's t	t	0.017909	Pr >  t	1.0000
Sign	M	-2	Pr >=  M	0.8774
Signed Rank	S	-573.5	Pr >=  S	0.7877


4.33 lentelė.

### Hipotezės apie liekanų pasiskirstymo normalumą tikrinimo rezultatai

Test	Statistic		p Value	
Kolmogorov-Smirnov	D	0.04521412	Pr > D	0.059

## 4. Bulvių nuostolingumo tyrimas:

### a) Tikrasis nuo nuostolingumas



4.13 pav. Bulvių DRPD nuostolingumo histograma

4.34 lentelė.

### Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	24	396.85626	16.53568	3.19	<.0001
Error	238	1232.79477	5.17981		
Corrected Total	262	1629.65103			

4.35 lentelė.

## Dispersinės analizės rezultatai (2)

Root MSE	2.27592	R-Square	0.2435
Dependent Mean	2.57693	Adj R-Sq	0.1672
Coeff Var	88.31905		

4.36 lentelė.

## Parametrų įverčių ir hipotezių tikrinimo rezultatai

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
Intercept	-1.82417	6.13660	-0.30	0.7665
BUYUP50	-1.04952	0.42522	-2.47	0.0143
BUYUP55	1.08981	0.68751	1.59	0.1143
BUYUP60	-0.61870	0.46809	-1.32	0.1875
BUYUP65	-0.44181	0.29690	-1.49	0.1381
BUYUP70	0.31332	0.37061	0.85	0.3987
BUYUP75	0.76825	0.30714	2.50	0.0130
CAT50	-0.06135	0.58622	-0.10	0.9167
MayPRCP	0.13417	0.57324	0.23	0.8151
JunPRCP	0.64308	0.59273	1.08	0.2790
JulPRCP	-0.50948	1.15307	-0.44	0.6590
AugPRCP	-0.24038	0.64430	-0.37	0.7094
SepPRCP	0.14483	0.96108	0.15	0.8803
OctPRCP	0.24521	0.54017	0.45	0.6503


Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
MayGDDP	0.01389	0.00676	2.05	0.0411
JunGDDP	0.00511	0.00458	1.12	0.2657
JulGDDP	0.00326	0.00700	0.47	0.6417
AugGDDP	-0.00985	0.00362	-2.72	0.0069
SepGDDP	-0.00608	0.00538	-1.13	0.2594
OctGDDP	0.00683	0.00586	1.17	0.2449
MayPGP	-0.00034165	0.00171	-0.20	0.8414
JunPGP	-0.00101	0.00101	-1.00	0.3203
JulPGP	0.00114	0.00155	0.73	0.4640
AugPGP	0.00074695	0.00098963	0.75	0.4511
SepPGP	-0.00001189	0.00222	-0.01	0.9957
OctPGP	-0.00090955	0.00312	-0.29	0.7709
RESTRICT	7.88274E-14	.	.	.

\* Probability computed using beta distribution.

4.37 lentelė.


## Modelio liekanos

Sum of Residuals	0
Sum of Squared Residuals	1232.79477
Predicted Residual SS (PRESS)	1561.29591



4.14 pav. Bulvių modelio normuotų liekanų grafikas

b) Transformuotas nuostolingumas:



4.15 pav. Transformuoto bulvių DRPD nuostolingumo histograma

4.38 lentelė.

Hipotezės apie transformuoto bulvių nuostolingumo pasiskirstymo normalumą tikrinimas

Test	Statistic		p Value	
Kolmogorov-Smirnov	D	0.03273175	Pr > D	>0.150

4.39 lentelė.

#### Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	24	5.51919	0.22997	4.13	<.0001
Error	238	13.25646	0.05570		
Corrected Total	262	18.77565			

## 4.40 lentelė.

## Dispersinės analizės rezultatai (2)

Root MSE	0.23601	R-Square	0.2940
Dependent Mean	1.13234	Adj R-Sq	0.2228
Coeff Var	20.84236		

## 4.41 lentelė.

## Parametru įverčių ir hipotezių tikrinimo rezultatai

Variable	Parameter Estimate	Standard Error	t Value	Pr >  t
Intercept	1.05877	0.63635	1.66	0.0975
BUYUP50	-0.08535	0.04409	-1.94	0.0541
BUYUP55	-0.02648	0.07129	-0.37	0.7106
BUYUP60	-0.07291	0.04854	-1.50	0.1344
BUYUP65	0.00677	0.03079	0.22	0.8261
BUYUP70	0.07683	0.03843	2.00	0.0467
BUYUP75	0.16525	0.03185	5.19	<.0001
CAT50	-0.06411	0.06079	-1.05	0.2926
MayPRCP	-0.05054	0.05944	-0.85	0.3960
JunPRCP	0.02927	0.06146	0.48	0.6344
JulPRCP	-0.02370	0.11957	-0.20	0.8430
AugPRCP	-0.10611	0.06681	-1.59	0.1136
SepPRCP	0.07087	0.09966	0.71	0.4777
OctPRCP	-0.01360	0.05601	-0.24	0.8084


Variable	Parameter Estimate	Standard Error	t Value	Pr >  t
MayGDDP	0.00092273	0.00070118	1.32	0.1895
JunGDDP	0.00031535	0.00047537	0.66	0.5077
JulGDDP	0.00033234	0.00072561	0.46	0.6474
AugGDDP	-0.00127	0.00037488	-3.39	0.0008
SepGDDP	-0.00037085	0.00055742	-0.67	0.5065
OctGDDP	0.00047203	0.00060746	0.78	0.4379
MayPGP	0.00016105	0.00017688	0.91	0.3635
JunPGP	-0.00004481	0.00010514	-0.43	0.6703
JulPGP	0.00007959	0.00016053	0.50	0.6205
AugPGP	0.00020875	0.00010262	2.03	0.0430
SepPGP	-0.00013389	0.00022981	-0.58	0.5607
OctPGP	0.00004964	0.00032358	0.15	0.8782
RESTRICT	2.35631E-14	.	.	.

\* Probability computed using beta distribution.

## 4.42 lentelė.

## Modelio liekanos

Sum of Residuals	0
Sum of Squared Residuals	13.25646
Predicted Residual SS (PRESS)	16.67722



4.16 pav. Transformuoto bulvių nuostolingumo modelio normuotų liekanų grafikas

4.43 lentelė.

#### Hipotezės apie liekanų vidurkio lygbę 0 tikrinimo rezultatai

Test	Statistic		p Value	
Student's t	t	-0.01401	Pr >  t	0.9888
Sign	M	-3.5	Pr >=  M	0.7115
Signed Rank	S	-110	Pr >=  S	0.9292


4.44 lentelė.

#### Hipotezės apie liekanų pasiskirstymo normalumą tikrinimo rezultatai

Test	Statistic		p Value	
Kolmogorov-Smirnov	D	0.03488653	Pr > D	>0.150

### 5. Cukrinių runkelių nuostolingumo tyrimas (pašalinus išskirtis):

#### a) Tikrasis nuo nuostolingumas



4.17 pav. Cukrinių runkelių DRPD nuostolingumo histograma



## 4.45 lentelė.

## Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	29	116.10136	4.00350	3.04	<.0001
Error	220	289.32991	1.31514		
Corrected Total	249	405.43127			

## 4.46 lentelė.

## Dispersinės analizės rezultatai (2)

Root MSE	1.14679	R-Square	0.2864
Dependent Mean	1.25229	Adj R-Sq	0.1923
Coeff Var	91.57581		

## 4.47 lentelė.

## Parametrų įverčių ir hipotezių tikrinimo rezultatai

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
Intercept	0.11467	6.34569	0.02	0.9856
BUYUP50	-0.29960	0.22144	-1.35	0.1775
BUYUP55	-0.67420	0.61970	-1.09	0.2778
BUYUP60	-0.06966	0.37000	-0.19	0.8508
BUYUP65	-0.30171	0.18650	-1.62	0.1072
BUYUP70	0.02705	0.20349	0.13	0.8944
BUYUP75	0.18744	0.18004	1.04	0.2990
BUYUP80	0.47449	0.22423	2.12	0.0355
BUYUP85	1.14803	0.23676	4.85	<.0001
CAT50	-0.49184	0.44283	-1.11	0.2679
AprPRCP	0.72759	0.67620	1.08	0.2831
MayPRCP	0.02589	0.48647	0.05	0.9576
JunPRCP	0.39589	0.47490	0.83	0.4054
JulPRCP	-0.68003	1.18341	-0.57	0.5661
AugPRCP	-0.17895	0.69913	-0.26	0.7982
SepPRCP	0.67417	0.86320	0.78	0.4356


Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
OctPRCP	-0.54816	0.34652	-1.58	0.1151
AprGDDSB	-0.00232	0.00317	-0.73	0.4643
MayGDDSB	0.00282	0.00328	0.86	0.3903
JunGDDSB	0.00152	0.00307	0.50	0.6209
JulGDDSB	-0.00049736	0.00593	-0.08	0.9332
AugGDDSB	-0.00210	0.00264	-0.80	0.4261
SepGDDSB	0.00126	0.00308	0.41	0.6843
OctGDDSB	-0.00336	0.00204	-1.65	0.1013
AprPGSB	-0.00206	0.00224	-0.92	0.3604
MayPGSB	0.00038004	0.00068832	0.55	0.5814
JunPGSB	-0.00024065	0.00049916	-0.48	0.6302
JulPGSB	0.00068000	0.00106	0.64	0.5231
AugPGSB	0.00016955	0.00069038	0.25	0.8062
SepPGSB	-0.00098277	0.00111	-0.88	0.3779
OctPGSB	0.00138	0.00090433	1.53	0.1285
RESTRICT	6.51936E-14	1.125284E-8	0.00	1.0000*

\* Probability computed using beta distribution.

4.48 lentelė.


## Modelio liekanos

Sum of Residuals	0
Sum of Squared Residuals	289.32991
Predicted Residual SS (PRESS)	370.87773



4.18 pav. Cukrinių runkelių modelio normuotų liekanų grafikas

## b) Transformuotas nuostolingumas:



4.19 pav. Transformuoto cukrinių runkelių DRPD nuostolingumo histograma

4.49 lentelė.

Hipotezės apie transformuoto cukrinių runkelių nuostolingumo pasiskirstymo normalumą  
tikrinimas

Test	Statistic		p Value	
Kolmogorov-Smirnov	D	0.03294084	Pr > D	>0.150

## 4.50 lentelė.

## Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	29	5.28766	0.18233	4.10	<.0001
Error	220	9.78521	0.04448		
Corrected Total	249	15.07287			

## 4.51 lentelė.

## Dispersinės analizės rezultatai (2)

Root MSE	0.21090	R-Square	0.3508
Dependent Mean	0.95402	Adj R-Sq	0.2652
Coeff Var	22.10632		

## 4.52 lentelė.

## Parametrų įverčių ir hipotezių tikrinimo rezultatai

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
Intercept	-1.00652	1.16699	-0.86	0.3894
BUYUP50	-0.06553	0.04072	-1.61	0.1090
BUYUP55	-0.10833	0.11396	-0.95	0.3429
BUYUP60	-0.04750	0.06804	-0.70	0.4859
BUYUP65	-0.04192	0.03430	-1.22	0.2229
BUYUP70	0.01305	0.03742	0.35	0.7277
BUYUP75	0.05547	0.03311	1.68	0.0953
BUYUP80	0.10143	0.04124	2.46	0.0147
BUYUP85	0.18254	0.04354	4.19	<.0001
CAT50	-0.08920	0.08144	-1.10	0.2746
AprPRCP	0.29842	0.12435	2.40	0.0172
MayPRCP	0.07590	0.08946	0.85	0.3971
JunPRCP	0.23501	0.08734	2.69	0.0077
JulPRCP	0.00488	0.21763	0.02	0.9821
AugPRCP	-0.01209	0.12857	-0.09	0.9252
SepPRCP	0.17849	0.15874	1.12	0.2621


Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
OctPRCP	-0.10631	0.06373	-1.67	0.0967
AprGDDSB	0.00018808	0.00058220	0.32	0.7470
MayGDDSB	0.00082699	0.00060295	1.37	0.1716
JunGDDSB	0.00102	0.00056543	1.81	0.0716
JulGDDSB	0.00002309	0.00109	0.02	0.9831
AugGDDSB	-0.00009961	0.00048460	-0.21	0.8373
SepGDDSB	0.00044949	0.00056730	0.79	0.4290
OctGDDSB	-0.00089372	0.00037595	-2.38	0.0183
AprPGSB	-0.00080595	0.00041241	-1.95	0.0519
MayPGSB	-0.00003579	0.00012658	-0.28	0.7777
JunPGSB	-0.00020674	0.00009180	-2.25	0.0253
JulPGSB	0.00000936	0.00019552	0.05	0.9619
AugPGSB	0.00002572	0.00012696	0.20	0.8396
SepPGSB	-0.00022139	0.00020456	-1.08	0.2803
OctPGSB	0.00024716	0.00016631	1.49	0.1387
RESTRICT	-2.1049E-14	2.06943E-9	-0.00	1.0000*

\* Probability computed using beta distribution.

4.53 lentelė.

## Modelio liekanos

Sum of Residuals	0
Sum of Squared Residuals	9.78521
Predicted Residual SS (PRESS)	12.74140



4.20 pav. Transformuoto cukrinių runkelių nuostolingumo modelio normuotų liekanų grafikas

4.54 lentelė.

## Hipotezės apie liekanų vidurkio lygybę 0 tikrinimo rezultatai

Test	Statistic		p Value	
	t	0	Pr >  t	1.0000
Student's t	t	0	Pr >  t	1.0000
Sign	M	2	Pr >=  M	0.8496
Signed Rank	S	119.5	Pr >=  S	0.9171

4.55 lentelė.

## Hipotezės apie liekanų pasiskirstymo normalumą tikrinimo rezultatai

Test	Statistic		p Value	
	D	0.03285151	Pr > D	>0.150
Kolmogorov-Smirnov	D	0.03285151	Pr > D	>0.150

## 5 PRIEDAS. SAS PROGRAMŲ TEKSTAI

```

libname Duomenys '.....\Programa'; *nurodyti kur issaugoti duomenis;
/*****WEATHER DATA*****/
data Datasets.ImportWeather; * reads daily meteorological data files;
  infile ".....\Weather???.csv"
  dlm=";";
  eov=beginNewFile;
  input @;
  if      beginNewFile=1 then do;
        beginNewFile=0;
        delete;
      end;
  else input CountyName $ Month Day Year Tmax Tmin PRCP;
  label   Tmax='Maksimali dienos temperatura'
          Tmin='Minimali dienos emperatura'
          PRCP='Dienos krituliu kiekis';

run;
data Datasets.Weather; *Growing degree days calculation and cumulative daily
calculation;
  set Datasets.ImportWeather;
  if CountyName='County' then delete;
  if PRCP='.' then PRCP=0;
  format County $35.;
  if CountyName='Grand' then County='Grand Forks'; else
County=CountyName;
  Tmin=(Tmin-32)*5/9; Tmax=(Tmax-32)*5/9; PRCP=PRCP*25.4;
  if Tmin<0 then TminWB=0; else TminWB=Tmin;
  if Tmax<0 then TmaxWB=0; else if Tmax>35 then TmaxWB=35; else
TmaxWB=Tmax;
  GDD_WB=(TminWB+TmaxWB)/2; *Calculates growing degree days for wheat and
barley;
  if Tmin<5 then TminC=5; else TminC=Tmin; if Tmax<5 then TmaxC=5; else
TmaxC=Tmax;
  GDD_C=(TminC+TmaxC)/2-5; *Calculates growing degree days for canola;
  if Tmin<1.1 then TminSB=1.1; else TminSB=Tmin;
  if Tmax<1.1 then TmaxSB=1.1; else if Tmax>30 then TmaxSB=30; else
TmaxSB=Tmax;
  GDD_SB=(TminSB+TmaxSB)/2-1.1; *Calculates growing degree days for sugar
beets;
  IF Tmin<8 then TminP=8; else TminP=Tmin; if Tmax<8 then TmaxP=8; else
TmaxP=Tmax;
  GDD_P=(TminP+TmaxP)/2-8; *Calculates growing degree days for potatoes;
drop TminWB TmaxWB TminC TmaxC TminSB TmaxSB TminP TmaxP;
  if Day=1 then CuSumPRCP=0; CuSumPRCP+PRCP; *Calculates cumulative
precipitation of a month;
  if Day=1 then do; CuSumGDDWB=0; end;
  CuSumGDDWB+GDD_WB; *Calculates cumulative growing degree days of a
month for wheat and barley;
  if Day=1 then CuSumGDDC=0;
  CuSumGDDC+GDD_C; *Calculates cumulative growing degree days of a month
for canola;
  if Day=1 then CuSumGDDSB=0;
  CuSumGDDSB+GDD_SB; *Calculates cumulative growing degree days of a
month for sugar beets;
  if Day=1 then CuSumGDDP=0;
  CuSumGDDP+GDD_P; *Calculates cumulative growing degree days of a month
for potatoes;
drop Tmax Tmin PRCP GDD_WB GDD_C GDD_SB GDD_P CountyName;

run;
data Datasets.CumWeather; *Cumulative monthly results;
  set Datasets.Weather;
  if Day=day(intnx('day',intnx('Month',mdy(Month,Day,Year),1),-1));

```

```

drop Day;

run;
data Datasets.CumPRCPGDD; *cumulative results by month;
set Datasets.CumWeather;
if Month=1 then do;
    JanPRCP=CuSumPRCP; JanGDDWB=CuSumGDDWB; JanGDDC=CuSumGDDC;
    JanGDDP=CuSumGDDP; JanGDDSB=CuSumGDDSB; end;
else do; JanPRCP=0; JanGDDWB=0; JanGDDC=0; JanGDDP=0; JanGDDSB=0; end;
if Month=2 then do;
    FebPRCP=CuSumPRCP; FebGDDWB=CuSumGDDWB; FebGDDC=CuSumGDDC;
    FebGDDP=CuSumGDDP; FebGDDSB=CuSumGDDSB; end;
else do; FebPRCP=0; FebGDDWB=0; FebGDDC=0; FebGDDP=0; FebGDDSB=0; end;
if Month=3 then do;
    MarPRCP=CuSumPRCP; MarGDDWB=CuSumGDDWB; MarGDDC=CuSumGDDC;
    MarGDDP=CuSumGDDP; MarGDDSB=CuSumGDDSB; end;
else do; MarPRCP=0; MarGDDWB=0; MarGDDC=0; MarGDDP=0; MarGDDSB=0; end;
if Month=4 then do;
    AprPRCP=CuSumPRCP; AprGDDWB=CuSumGDDWB; AprGDDC=CuSumGDDC;
    AprGDDP=CuSumGDDP; AprGDDSB=CuSumGDDSB; end;
else do; AprPRCP=0; AprGDDWB=0; AprGDDC=0; AprGDDP=0; AprGDDSB=0; end;
if Month=5 then do;
    MayPRCP=CuSumPRCP; MayGDDWB=CuSumGDDWB; MayGDDC=CuSumGDDC;
    MayGDDP=CuSumGDDP; MayGDDSB=CuSumGDDSB; end;
else do; MayPRCP=0; MayGDDWB=0; MayGDDC=0; MayGDDP=0; MayGDDSB=0; end;
if Month=6 then do;
    JunPRCP=CuSumPRCP; JunGDDWB=CuSumGDDWB; JunGDDC=CuSumGDDC;
    JunGDDP=CuSumGDDP; JunGDDSB=CuSumGDDSB; end;
else do; JunPRCP=0; JunGDDWB=0; JunGDDC=0; JunGDDP=0; JunGDDSB=0; end;
if Month=7 then do;
    JulPRCP=CuSumPRCP; JulGDDWB=CuSumGDDWB; JulGDDC=CuSumGDDC;
    JulGDDP=CuSumGDDP; JulGDDSB=CuSumGDDSB; end;
else do; JulPRCP=0; JulGDDWB=0; JulGDDC=0; JulGDDP=0; JulGDDSB=0; end;
if Month=8 then do;
    AugPRCP=CuSumPRCP; AugGDDWB=CuSumGDDWB; AugGDDC=CuSumGDDC;
    AugGDDP=CuSumGDDP; AugGDDSB=CuSumGDDSB; end;
else do; AugPRCP=0; AugGDDWB=0; AugGDDC=0; AugGDDP=0; AugGDDSB=0; end;
if Month=9 then do;
    SepPRCP=CuSumPRCP; SepGDDWB=CuSumGDDWB; SepGDDC=CuSumGDDC;
    SepGDDP=CuSumGDDP; SepGDDSB=CuSumGDDSB; end;
else do; SepPRCP=0; SepGDDWB=0; SepGDDC=0; SepGDDP=0; SepGDDSB=0; end;
if Month=10 then do;
    OctPRCP=CuSumPRCP; OctGDDWB=CuSumGDDWB; OctGDDC=CuSumGDDC;
    OctGDDP=CuSumGDDP; OctGDDSB=CuSumGDDSB; end;
else do; OctPRCP=0; OctGDDWB=0; OctGDDC=0; OctGDDP=0; OctGDDSB=0; end;
if Month=11 then do;
    NovPRCP=CuSumPRCP; NovGDDWB=CuSumGDDWB; NovGDDC=CuSumGDDC;
    NovGDDP=CuSumGDDP; NovGDDSB=CuSumGDDSB; end;
else do; NovPRCP=0; NovGDDWB=0; NovGDDC=0; NovGDDP=0; NovGDDSB=0; end;
if Month=12 then do;
    DecPRCP=CuSumPRCP; DecGDDWB=CuSumGDDWB; DecGDDC=CuSumGDDC;
    DecGDDP=CuSumGDDP; DecGDDSB=CuSumGDDSB; end;
else do; DecPRCP=0; DecGDDWB=0; DecGDDC=0; DecGDDP=0; DecGDDSB=0; end;

run;
proc report data=Datasets.CumPRCPGDD out=Datasets.ReportCumW; *Main cumulative
weather data;
column County Year JanPRCP JanGDDWB FebPRCP FebGDDWB MarPRCP
MarGDDWB
AprPRCP AprGDDWB AprGDDC AprGDDSB MayPRCP MayGDDWB MayGDDC
MayGDDP MayGDDSB
JunPRCP JunGDDWB JunGDDC JunGDDP JunGDDSB JulPRCP JulGDDWB
JulGDDC JulGDDP JulGDDSB
AugPRCP AugGDDWB AugGDDC AugGDDP AugGDDSB SepPRCP SepGDDWB
SepGDDC SepGDDP SepGDDSB

```

```

OctPRCP OctGDDWB OctGDDC OctGDDP OctGDDSB NovPRCP NovGDDWB
DecPRCP DecGDDWB;
  define County/group; define Year /group;
  define JanPRCP /max; define JanGDDWB/max; define FebPRCP /max; define
FebGDDWB/max;
  define MarPRCP /max; define MarGDDWB/max;
  define AprPRCP /max; define AprGDDWB/max; define AprGDDC /max;
      define AprGDDSB/max;
  define MayPRCP /max; define MayGDDWB/max; define MayGDDC /max; define
MayGDDP /max; define MayGDDSB/max;
  define JunPRCP /max; define JunGDDWB/max; define JunGDDC /max; define
JunGDDP /max; define JunGDDSB/max;
  define JulPRCP /max; define JulGDDWB/max; define JulGDDC /max; define
JulGDDP /max; define JulGDDSB/max;
  define AugPRCP /max; define AugGDDWB/max; define AugGDDC /max; define
AugGDDP /max; define AugGDDSB/max;
  define SepPRCP /max; define SepGDDWB/max; define SepGDDC /max; define
SepGDDP /max; define SepGDDSB/max;
  define OctPRCP /max; define OctGDDWB/max; define OctGDDC /max; define
OctGDDP /max; define OctGDDSB/max;
  define NovPRCP /max; define NovGDDWB/max;
  define DecPRCP /max; define DecGDDWB/max;

run;
data Datasets.Meteo;
  set Datasets.ReportCumW;
  drop _BREAK_;
  OctPRCP=lag(OctPRCP);NovPRCP=lag(NovPRCP);DecPRCP=lag(DecPRCP);
  OctGDDWB=lag(OctGDDWB);NovGDDWB=lag(NovGDDWB);DecGDDWB=lag(DecGDDWB);
  JanPGWB=JanPRCP*JanGDDWB; FebPGWB=FebPRCP*FebGDDWB;
  MarPGWB=MarPRCP*MarGDDWB; AprPGWB=AprPRCP*AprGDDWB;
  MayPGWB=MayPRCP*MayGDDWB; JunPGWB=JunPRCP*JunGDDWB;
  JulPGWB=JulPRCP*JulGDDWB; AugPGWB=AugPRCP*AugGDDWB;
  SepPGWB=SepPRCP*SepGDDWB; OctPGWB=OctPRCP*OctGDDWB;
  NovPGWB=NovPRCP*NovGDDWB; DecPGWB=DecPRCP*DecGDDWB;
  AprPGC=AprPRCP*AprGDDC; MayPGC=MayPRCP*MayGDDC; JunPGC=JunPRCP*JunGDDC;
  JulPGC=JulPRCP*JulGDDC;
  AugPGC=AugPRCP*AugGDDC; SepPGC=SepPRCP*SepGDDC; OctPGC=OctPRCP*OctGDDC;
  AprPGSB=AprPRCP*AprGDDSB; MayPGSB=MayPRCP*MayGDDSB;
  JunPGSB=JunPRCP*JunGDDSB; JulPGSB=JulPRCP*JulGDDSB;
  AugPGSB=AugPRCP*AugGDDSB; SepPGSB=SepPRCP*SepGDDSB;
  OctPGSB=OctPRCP*OctGDDSB;
  MayPGP=MayPRCP*MayGDDP; JunPGP=JunPRCP*JunGDDP; JulPGP=JulPRCP*JulGDDP;
  AugPGP=AugPRCP*AugGDDP; SepPGP=SepPRCP*SepGDDP; OctPGP=OctPRCP*OctGDDP;
  if Year=1994 then delete;

run;
/*****INSURANCE DATA*****/
data Duomenys.Importsum; *reads insurance data files;
  infile ".....SOBCOV???.txt"
  dlm="|"
  eov=beginNewFile;
  input @;
  if beginNewFile=1 then do;
      beginNewFile=0;
      delete;
  end;
  else input Year StateCode $ State $ CountyCode $ CountyN $ CropCode $
Crop $ InsurPlanCode $ InsurPlan $ CoverageCat $ CoverageLvl DeliveryId $ PolSold
PolEarnPrem PolIndemn NetAcres Subsidy Liability TotalPrem Indemn LossRatio;
  label StateCode='Valstijos kodas'
State='Valstija'
Crop='Paseliu kultura'
CountyCode='Apygardos kodas'
CountyN='Apygarda '
CropCode='Paseliu kulturos kodas'

```

```

        InsurPlanCode='Draudimo plano kodas'
        InsurPlan='Draudimo planas'
        CoverageCat='Padengimo kategorija'
        CoverageLvl='Padengimo lygis'
        PolSold='Parduota polisu'
        PolEarnPrem='Polisai (imokos sumoketos)'
        PolIndemn='Polisai (patirta zala)'
        NetAcres='Plotas akrais'
        Liability='Isipareigojimai'
        Subsidy='Subsidijos'
        TotalPrem='Imokos'
        Indemn='Zala'
        LossRatio='Nuostolingumas'
        Year='Metai';

run;
proc gchart data=duomenys.importsum;
    vbar insurplan /      subgroup = year
                        sumvar = polearnprem;
    title 'skirstingu planu galiojanciu polisu skaicius pagal metus';
run;
proc gchart data=duomenys.importsum;
    vbar state /        subgroup = year
                  sumvar = polindemn;
    title1 'polisu, kuriems fiksuota zala skaicius';
    title2 'skirtingose valstijose pagal metus';
run;
data Duomenys.Datasum;
    set Duomenys.Importsum;
    format County $35.;
    if CountyN='Grand' then County='Grand Forks'; else County=CountyN;
    drop CountyN;
    if InsurPlan = 'APH';
    if State = 'ND';
    if County = 'Towner' or County = 'Cavalier' or County = 'Pembina' or
County = 'Ramsey' or
County = 'Nelson' or County = 'Grand Forks' or County =
'Foster' or
County = 'Griggs' or County = 'Steele' or County = 'Traill'
or
County = 'Stutsman' or County = 'Barnes' or County = 'Cass'
or
County = 'Ransom' or County = 'Richland' or County = 'Dickey'
or
County = 'Sargent'
    if Crop = 'WHEAT' or Crop = 'BARLEY' or Crop = 'POTATOES' or Crop =
'SUGAR BE'
    or Crop = 'CANOLA';
    drop StateCode State CountyCode CropCode InsurPlanCode InsurPlan
DeliveryId;
    if CoverageLvl>0;
    if PolIndemn ne 0;
    Coverage=cats(CoverageCat,CoverageLvl);
    LossRatio=Indemn/TotalPrem;
    if Coverage='BUYUP50' then BUYUP50=1; else BUYUP50=0;
    if Coverage='BUYUP55' then BUYUP55=1; else BUYUP55=0;
    if Coverage='BUYUP60' then BUYUP60=1; else BUYUP60=0;
    if Coverage='BUYUP65' then BUYUP65=1; else BUYUP65=0;
    if Coverage='BUYUP70' then BUYUP70=1; else BUYUP70=0;
    if Coverage='BUYUP75' then BUYUP75=1; else BUYUP75=0;
    if Coverage='BUYUP80' then BUYUP80=1; else BUYUP80=0;
    if Coverage='BUYUP85' then BUYUP85=1; else BUYUP85=0;
    if Coverage='CAT50' then CAT50=1; else CAT50=0;
    label Coverage='Padengimo kategorija';
run;

```



```

proc sort data=Duomenys.Datasum;
    by County Year;
run;
proc sort data=Duomenys.Meteo;
    by County Year;
run;
data Duomenys.Full;
    merge Duomenys.Datasum Duomenys.Meteo;
    by County Year;
run;
proc sort data=Duomenys.Full;
    by Crop County Coverage Year;
run;
proc report data=Duomenys.Full out=Duomenys.ReportPol;
    column County Year Crop /*CoverageCat*/ PolSold PolEarnPrem ;
    define County/group; define Year /group; define Crop/group; *define
CoverageCat/group;
    define PolSold /analysis sum; define PolEarnPrem/analysis sum;
run;
data Duomenys.Policies;
    set Duomenys.ReportPol;
    UncolPol=PolSold-PolEarnPrem;
run;
proc sort data=Duomenys.Full;
    by Crop Coverage County ;
run;
/*****BARLEY*****/
data Duomenys.Mieziai(where=(Crop='BARLEY' and Indemn ne 0));
    set Duomenys.Full;
run;
proc univariate data=Duomenys.Mieziai(where=(LossRatio lt 9.25));
    var Lossratio;
    histogram/ vaxislabel ='Daznis %' endpoints=0 to 10 by 0.5;
    inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
    title 'Mieziu DRPD nuostolingumo histograma';
run;
proc reg data=Duomenys.Mieziai(where=(LossRatio lt 9.25)) corr alpha=0.05;
    model LossRatio=BUYUP50 BUYUP55 BUYUP60 BUYUP65 BUYUP70 BUYUP75 BUYUP80
BUYUP85 CAT50
    AprPRCP MayPRCP JunPRCP JulPRCP AugPRCP SepPRCP OctPRCP
    AprGDDWB MayGDDWB JunGDDWB JulGDDWB AugGDDWB SepGDDWB OctGDDWB
    AprPGWB MayPGWB JunPGWB JulPGWB AugPGWB SepPGWB OctPGWB
    / p clm cli stb /*influence tol vif collin*/ ;
    restrict
BUYUP50+BUYUP55+BUYUP60+BUYUP65+BUYUP70+BUYUP75+BUYUP80+BUYUP85+CAT50=0;
    output out=Duomenys.MieziaiLiek p=yhat student=resid r=residual;
    label yhat='Nuostolingumo prognoze'
        resid='Standartizuota liekana';
    title 'Mieziu DRPD nuostolingumo regresijos modelis';
run;
proc gplot data=Duomenys.MieziaiLiek;
    plot resid*yhat;
    title 'Modelio tyrimas - Standartizuotos liekanos ir nuostolingumo
prognoze';
run;
proc univariate normal plot data=Duomenys.MieziaiLiek;
    var resid residual;
    histogram/normal vaxislabel ='Daznis %';
    inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
    title 'Modelio tyrimas - Liekanu pasiskirstymo tyrimas';
run;
proc transreg data=Duomenys.Mieziai(where=(LossRatio lt 9.25));

```

```

model BoxCox (LossRatio/lambda=0 to 0.5 by 0.005 )= class(coverage)
identity(AprPRCP) identity(MayPRCP) identity(JunPRCP)
identity(JulPRCP)
identity(AugPRCP) identity(SepPRCP) identity(OctPRCP)
identity(AprGDDWB) identity(MayGDDWB) identity(JunGDDWB)
identity(JulGDDWB)
identity(AugGDDWB) identity(SepGDDWB) identity(OctGDDWB)
identity(AprPGWB) identity(MayPGWB) identity(JunPGWB)
identity(JulPGWB)
identity(AugPGWB) identity(SepPGWB) identity(OctPGWB);

run;
data Duomenys.Mieziai ;
set Duomenys.Mieziai;
TLR=LossRatio**0.35;
label TLR = 'Nuostolingumas (po laipsnines transformacijos)';

run;
proc univariate data=Duomenys.Mieziai(where=(LossRatio lt 9.25));
var TLR;
histogram/normal vaxislabel ='Daznis %';
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title1 'Mieziu DRPD transformuoto nuostolingumo histograma';

run;
proc reg data=Duomenys.Mieziai (where=(LossRatio lt 9.25)) corr alpha=0.05;
model TLR=BUYUP50 BUYUP55 BUYUP60 BUYUP65 BUYUP70 BUYUP75 BUYUP80
BUYUP85 CAT50
AprPRCP MayPRCP JunPRCP JulPRCP AugPRCP SepPRCP OctPRCP
AprGDDWB MayGDDWB JunGDDWB JulGDDWB AugGDDWB SepGDDWB OctGDDWB
AprPGWB MayPGWB JunPGWB JulPGWB AugPGWB SepPGWB OctPGWB
/ p clm cli stb /*influence tol vif collin*/;
restrict
BUYUP50+BUYUP55+BUYUP60+BUYUP65+BUYUP70+BUYUP75+BUYUP80+BUYUP85+CAT50=0;
output out=Duomenys.MieziaiLiekT p=yhat student=resid r=residual;
label yhat='Transformuoto nuostolingumo prognoze'
resid='Standartizuota liekana';
title 'Mieziu DRPD transformuoto nuostolingumo regresijos modelis';

run;
proc gplot data=Duomenys.MieziaiLiekT;
plot resid*yhat;
title 'Modelio tyrimas - Standartizuotos liekanos ir transformuoto nuostolingumo
prognoze';

run;
proc univariate normal plot data=Duomenys.MieziaiLiekT;
var resid residual;
histogram/normal vaxislabel ='Daznis %';
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title 'Modelio tyrimas - Liekanu pasiskirstymo tyrimas';

run;
/*****WHEAT*****/
data Duomenys.Kvieciai(where=(Crop='WHEAT' and Indemn ne 0));
set Duomenys.Full;

run;
proc univariate data=Duomenys.Kvieciai(where=(LossRatio lt 6.2));
var Lossratio;
histogram/ vaxislabel ='Daznis %' endpoints=0 to 7 by 0.5;
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title1 'Kvieciu DRPD nuostolingumo histograma';

run;
proc reg data=Duomenys.Kvieciai(where=(LossRatio lt 6.2)) corr alpha=0.05;
model LossRatio=BUYUP50 BUYUP55 BUYUP60 BUYUP65 BUYUP70 BUYUP75 BUYUP80
BUYUP85 CAT50

```

```

JanPRCP FebPRCP MarPRCP AprPRCP MayPRCP JunPRCP JulPRCP AugPRCP SepPRCP
OctPRCP NovPRCP DecPRCP
JanGDDWB FebGDDWB MarGDDWB AprGDDWB MayGDDWB JunGDDWB JulGDDWB AugGDDWB
SepGDDWB OctGDDWB NovGDDWB DecGDDWB
JanPGWB FebPGWB MarPGWB AprPGWB MayPGWB JunPGWB JulPGWB AugPGWB SepPGWB
OctPGWB NovPGWB DecPGWB
/ p clm cli stb /*influence tol vif collin*/ ;
restrict
BUYUP50+BUYUP55+BUYUP60+BUYUP65+BUYUP70+BUYUP75+BUYUP80+BUYUP85+CAT50=0;
output out=Duomenys.KvieciaiLiek p=yhat student=resid r=residual;
label      yhat='Nuostolingumo prognoze'
           resid='Standartizuota liekana';
title 'Kvieciu DRPD nuostolingumo regresijos modelis';

run;
proc gplot data=Duomenys.KvieciaiLiek;
plot resid*yhat;
title 'Modelio tyrimas - Standartizuotos liekanos ir nuostolingumo
prognoze';
run;
proc univariate normal plot data=Duomenys.KvieciaiLiek;
var resid residual;
histogram/normal vaxislabel ='Daznis %';
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title 'Modelio tyrimas - Liekanu pasiskirstymo tyrimas';

run;
proc transreg data=Duomenys.Kvieciai(where=(LossRatio lt 6.2));
model BoxCox (LossRatio/lambda=0 to 0.5 by 0.005 )= class(coverage)
identity(JanPRCP)      identity(FebPRCP)      identity(MarPRCP)
identity(AprPRCP)
identity(MayPRCP)      identity(JunPRCP)      identity(JulPRCP)
identity(AugPRCP)
identity(SepPRCP)      identity(OctPRCP)      identity(NovPRCP)
identity(DecPRCP)
identity(JanGDDWB)    identity(FebGDDWB)    identity(MarGDDWB)
identity(AprGDDWB)
identity(MayGDDWB)    identity(JunGDDWB)    identity(JulGDDWB)
identity(AugGDDWB)
identity(SepGDDWB)    identity(OctGDDWB)    identity(NovGDDWB)
identity(DecGDDWB)
identity(JanPGWB)     identity(FebPGWB)     identity(MarPGWB)
identity(AprPGWB)
identity(MayPGWB)     identity(JunPGWB)     identity(JulPGWB)
identity(AugPGWB)
identity(SepPGWB)     identity(OctPGWB)     identity(NovPGWB)
identity(DecPGWB);

run;
data Duomenys.Kvieciai;
set Duomenys.Kvieciai;
TLR=LossRatio**0.3;
label TLR = 'Nuostolingumas (po laipsnines transformacijos)';

run;
proc univariate data=Duomenys.Kvieciai(where=(LossRatio lt 6.2));
var TLR;
histogram/normal vaxislabel ='Daznis %';
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title 'Kvieciu DRPD transformuoto nuostolingumo histograma';

run;
proc reg data=Duomenys.Kvieciai(where=(LossRatio lt 6.2)) corr alpha=0.05;
model TLR=BUYUP50 BUYUP55 BUYUP60 BUYUP65 BUYUP70 BUYUP75 BUYUP80
BUYUP85 CAT50
JanPRCP FebPRCP MarPRCP AprPRCP MayPRCP JunPRCP JulPRCP AugPRCP SepPRCP
OctPRCP NovPRCP DecPRCP

```

```

JanGDDWB FebGDDWB MarGDDWB AprGDDWB MayGDDWB JunGDDWB JulGDDWB AugGDDWB
SepGDDWB OctGDDWB NovGDDWB DecGDDWB
JanPGWB FebPGWB MarPGWB AprPGWB MayPGWB JunPGWB JulPGWB AugPGWB SepPGWB
OctPGWB NovPGWB DecPGWB
/ p clm cli stb /*influence tol vif collin*/;
restrict
BUYUP50+BUYUP55+BUYUP60+BUYUP65+BUYUP70+BUYUP75+BUYUP80+BUYUP85+CAT50=0;
output out=Duomenys.KvieciaiLiekT p=yhat student=resid r=residual;
label      yhat='Transformuoto nuostolingumo prognoze'
           resid='Standartizuota liekana';
title 'Kvieciu DRPD transformuoto nuostolingumo regresijos modelis';
run;
proc gplot data=Duomenys.KvieciaiLiekT;
plot resid*yhat;
title 'Modelio tyrimas - Standartizuotos liekanos ir transformuoto nuostolingumo
prognoze';
run;
proc univariate normal plot data=Duomenys.KvieciaiLiekT;
var resid residual;
histogram/normal vaxislabel ='Daznis %';
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title 'Modelio tyrimas - Liekanu pasiskirstymo tyrimas';
run;
/*****CANOLA*****/
data Duomenys.Rapsai(where=(Crop='CANOLA' and Indemn ne 0));
set Duomenys.Full;
run;
proc univariate data=Duomenys.Rapsai(where=(LossRatio lt 9.4));
var Lossratio;
histogram/ vaxislabel ='Daznis %' endpoints=0 to 10 by 0.5;
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title 'Rapsu DRPD nuostolingumo histograma';
run;
proc reg data=Duomenys.Rapsai(where=(LossRatio lt 9.4)) corr alpha=0.05;
model LossRatio=BUYUP50 BUYUP55 BUYUP60 BUYUP65 BUYUP70 BUYUP75 CAT50
AprPRCP MayPRCP JunPRCP JulPRCP AugPRCP SepPRCP OctPRCP
AprGDDC MayGDDC JunGDDC JulGDDC AugGDDC SepGDDC OctGDDC
AprPGC MayPGC JunPGC JulPGC AugPGC SepPGC OctPGC
/ p clm cli stb /*influence tol vif collin*/ ;
restrict BUYUP50+BUYUP55+BUYUP60+BUYUP65+BUYUP70+BUYUP75+CAT50=0;
output out=Duomenys.RapsaiLiek p=yhat student=resid r=residual;
label      yhat='Nuostolingumo prognoze'
           resid='Standartizuota liekana';
title 'Rapsu DRPD nuostolingumo regresijos modelis';
run;
proc gplot data=Duomenys.RapsaiLiek;
plot resid*yhat;
title 'Modelio tyrimas - Standartizuotos liekanos ir nuostolingumo
prognoze';
run;
proc univariate normal plot data=Duomenys.RapsaiLiek;
var resid residual;
histogram/normal vaxislabel ='Daznis %';
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title 'Modelio tyrimas - Liekanu pasiskirstymo tyrimas';
run;
proc transreg data=Duomenys.Rapsai(where=(LossRatio lt 9.4));
model BoxCox (LossRatio/lambda=0 to 0.5 by 0.005 )= class(coverage)
identity(AprPRCP)      identity(MayPRCP)      identity(JunPRCP)
identity(JulPRCP)
identity(AugPRCP)      identity(SepPRCP)      identity(OctPRCP)

```

```

        identity(AprGDDC)      identity(MayGDDC)      identity(JunGDDC)
        identity(JulGDDC)
        identity(AugGDDC)     identity(SepGDDC)     identity(OctGDDC)
        identity(AprPGC)     identity(MayPGC)     identity(JunPGC)
        identity(JulPGC)
        identity(AugPGC)     identity(SepPGC)     identity(OctPGC)      ;
run;
data Duomenys.Rapsai;
    set Duomenys.Rapsai;
    TLR=LossRatio**0.23;
    label TLR = 'Nuostolingumas (po laipsnines transformacijos)';
run;
proc univariate data=Duomenys.Rapsai(where=(LossRatio lt 9.4));
    var TLR;
    histogram/normal vaxislabel = 'Daznis %';
    inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
    title1 'Rapsu DRPD transformuoto nuostolingumo histograma';
run;
proc reg data=Duomenys.Rapsai(where=(LossRatio lt 9.4)) corr alpha=0.05;
    model TLR=BUYUP50 BUYUP55 BUYUP60 BUYUP65 BUYUP70 BUYUP75 CAT50
    AprPRCP MayPRCP JunPRCP JulPRCP AugPRCP SepPRCP OctPRCP
    AprGDDC MayGDDC JunGDDC JulGDDC AugGDDC SepGDDC OctGDDC
    AprPGC MayPGC JunPGC JulPGC AugPGC SepPGC OctPGC
    / p clm cli stb /*influence tol vif collin*/;
    restrict BUYUP50+BUYUP55+BUYUP60+BUYUP65+BUYUP70+BUYUP75+CAT50=0;
    output out=Duomenys.RapsaiLiekt p=yhat student=resid r=residual;
    label      yhat='Transformuoto nuostolingumo prognoze'
              resid='Standartizuota liekana';
    title 'Rapsu DRPD transformuoto nuostolingumo regresijos modelis';
run;
proc gplot data=Duomenys.RapsaiLiekt;
    plot resid*yhat;
    title 'Modelio tyrimas - Standartizuotos liekanos ir transformuoto
    nuostolingumo prognoze';
run;
proc univariate normal plot data=Duomenys.RapsaiLiekt;
    var resid residual;
    histogram/normal vaxislabel = 'Daznis %';
    inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
    title 'Modelio tyrimas - Liekanu pasiskirstymo tyrimas';
run;
/*****POTATOES*****/
data Duomenys.Bulves(where=(Crop='POTATOES' and Indemn ne 0));
    set Duomenys.Full;
run;
proc univariate data=Duomenys.Bulves(where=(LossRatio lt 12.9));
    var Lossratio;
    histogram/ vaxislabel = 'Daznis %' endpoints=0 to 13 by 0.5;
    inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
    title1 'Bulviu DRPD nuostolingumo histograma';
run;
proc reg data=Duomenys.Bulves(where=(LossRatio lt 12.9)) corr alpha=0.05;
    model LossRatio=BUYUP50 BUYUP55 BUYUP60 BUYUP65 BUYUP70 BUYUP75 CAT50
    MayPRCP JunPRCP JulPRCP AugPRCP SepPRCP OctPRCP
    MayGDDP JunGDDP JulGDDP AugGDDP SepGDDP OctGDDP
    MayPGP JunPGP JulPGP AugPGP SepPGP OctPGP
    / p clm cli stb /*influence tol vif collin*/ ;
    restrict BUYUP50+BUYUP55+BUYUP60+BUYUP65+BUYUP70+BUYUP75+CAT50=0;
    output out=Duomenys.BulvesLiekt p=yhat student=resid r=residual;
    label      yhat='Nuostolingumo prognoze'
              resid='Standartizuota liekana';

```

```

        title 'Bulviu DRPD nuostolingumo regresijos modelis';
run;
proc gplot data=Duomenys.BulvesLiek;
plot resid*yhat;
title 'Modelio tyrimas - Standartizuotos liekanos ir nuostolingumo
prognoze';
run;
proc univariate normal plot data=Duomenys.BulvesLiek;
var resid residual;
histogram/normal vaxislabel ='Daznis %';
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title 'Modelio tyrimas - Liekanu pasiskirstymo tyrimas';
run;
proc transreg data=Duomenys.Bulves(where=(LossRatio lt 12.9));
model BoxCox (LossRatio/lambda=0 to 0.5 by 0.005 )= class(coverage)
identity(MayPRCP) identity(JunPRCP) identity(JulPRCP)
identity(AugPRCP) identity(SepPRCP) identity(OctPRCP)
identity(MayGDDP) identity(JunGDDP) identity(JulGDDP)
identity(AugGDDP) identity(SepGDDP) identity(OctGDDP)
identity(MayPGP) identity(JunPGP) identity(JulPGP)
identity(AugPGP) identity(SepPGP) identity(OctPGP);
run;
data Duomenys.Bulves;
set Duomenys.Bulves;
TLR=LossRatio**0.22;
label TLR = 'Nuostolingumas (po laipsnines transformacijos)';
run;
proc univariate data=Duomenys.Bulves(where=(LossRatio lt 12.9));
var TLR;
histogram/normal vaxislabel ='Daznis %';
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title 'Bulviu DRPD transformuoto nuostolingumo histograma';
run;
proc reg data=Duomenys.Bulves(where=(LossRatio lt 12.9)) corr alpha=0.05;
model TLR=BUYUP50 BUYUP55 BUYUP60 BUYUP65 BUYUP70 BUYUP75 CAT50
MayPRCP JunPRCP JulPRCP AugPRCP SepPRCP OctPRCP
MayGDDP JunGDDP JulGDDP AugGDDP SepGDDP OctGDDP
MayPGP JunPGP JulPGP AugPGP SepPGP OctPGP
/ p clm cli stb /*influence tol vif collin*/;
restrict BUYUP50+BUYUP55+BUYUP60+BUYUP65+BUYUP70+BUYUP75+CAT50=0;
output out=Duomenys.BulvesLiekT p=yhat student=resid r=residual;
label yhat='Transformuoto nuostolingumo prognoze'
resid='Standartizuota liekana';
title 'Bulviu DRPD transformuoto nuostolingumo regresijos modelis';
run;
proc gplot data=Duomenys.BulvesLiekT;
plot resid*yhat;
title 'Modelio tyrimas - Standartizuotos liekanos ir transformuoto nuostolingumo
prognoze';
run;
proc univariate normal plot data=Duomenys.BulvesLiekT;
var resid residual;
histogram/normal vaxislabel ='Daznis %';
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title 'Modelio tyrimas - Liekanu pasiskirstymo tyrimas';
run;
/*****SUGAR BEETS*****/
data Duomenys.CukrRunkeliai(where=(Crop='SUGAR BE' and Indemn ne 0));
set Duomenys.Full;
run;
proc univariate data=Duomenys.CukrRunkeliai(where=(LossRatio lt 7.3));

```

```

var Lossratio;
histogram/ vaxislabel ='Daznis %' endpoints=0 to 8 by 0.5;
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title1 'Cukriniu runkeliu DRPD nuostolingumo histograma';
run;
proc reg data=Duomenys.CukrRunkeliai(where=(LossRatio lt 7.3)) corr alpha=0.05;
model LossRatio=BUYUP50 BUYUP55 BUYUP60 BUYUP65 BUYUP70 BUYUP75 BUYUP80
BUYUP85 CAT50
AprPRCP MayPRCP JunPRCP JulPRCP AugPRCP SepPRCP OctPRCP
AprGDDSB MayGDDSB JunGDDSB JulGDDSB AugGDDSB SepGDDSB OctGDDSB
AprPGSB MayPGSB JunPGSB JulPGSB AugPGSB SepPGSB OctPGSB
/ p clm cli stb /*influence tol vif collin*/ ;
restrict
BUYUP50+BUYUP55+BUYUP60+BUYUP65+BUYUP70+BUYUP75+BUYUP80+BUYUP85+CAT50=0;
output out=Duomenys.CukrRunkeliaiLiek p=yhat student=resid r=residual;
label yhat='Nuostolingumo prognoze'
resid='Standartizuota liekana';
title 'Cukriniu runkeliu DRPD nuostolingumo regresijos modelis';
run;
proc gplot data=Duomenys.CukrRunkeliaiLiek;
plot resid*yhat;
title 'Modelio tyrimas - Standartizuotos liekanos ir nuostolingumo
prognoze';
run;
proc univariate normal plot data=Duomenys.CukrRunkeliaiLiek;
var resid residual;
histogram/normal vaxislabel ='Daznis %';
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title 'Modelio tyrimas - Liekanu pasiskirstymo tyrimas';
run;
proc transreg data=Duomenys.CukrRunkeliai(where=(LossRatio lt 7.3));
model BoxCox (LossRatio/lambda=0 to 0.5 by 0.005 )= class(coverage)
identity(AprPRCP) identity(MayPRCP) identity(JunPRCP)
identity(JulPRCP)
identity(AugPRCP) identity(SepPRCP) identity(OctPRCP)
identity(AprGDDSB) identity(MayGDDSB) identity(JunGDDSB)
identity(JulGDDSB)
identity(AugGDDSB) identity(SepGDDSB) identity(OctGDDSB)
identity(AprPGSB) identity(MayPGSB) identity(JunPGSB)
identity(JulPGSB)
identity(AugPGSB) identity(SepPGSB) identity(OctPGSB);
run;
data Duomenys.CukrRunkeliai ;
set Duomenys.CukrRunkeliai;
TLR=LossRatio**0.22;
label TLR = 'Nuostolingumas (po laipsnines transformacijos)';
run;
proc univariate data=Duomenys.CukrRunkeliai(where=(LossRatio lt 7.3));
var TLR;
histogram/normal vaxislabel ='Daznis %';
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title1 'Cukriniu runkeliu DRPD transformuoto nuostolingumo histograma';
run;
proc reg data=Duomenys.CukrRunkeliai (where=(LossRatio lt 7.3)) corr alpha=0.05;
model TLR=BUYUP50 BUYUP55 BUYUP60 BUYUP65 BUYUP70 BUYUP75 BUYUP80
BUYUP85 CAT50
AprPRCP MayPRCP JunPRCP JulPRCP AugPRCP SepPRCP OctPRCP
AprGDDSB MayGDDSB JunGDDSB JulGDDSB AugGDDSB SepGDDSB OctGDDSB
AprPGSB MayPGSB JunPGSB JulPGSB AugPGSB SepPGSB OctPGSB
/ p clm cli stb /*influence tol vif collin*/;

```

```

        restrict
BUYUP50+BUYUP55+BUYUP60+BUYUP65+BUYUP70+BUYUP75+BUYUP80+BUYUP85+CAT50=0;
        output out=Duomenys.CukrRunkeliaiLiekT p=yhat student=resid r=residual;
        label      yhat='Transformuoto nuostolingumo prognoze'
                 resid='Standartizuota liekana';
        title 'Cukriniu runkeliu DRPD transformuoto nuostolingumo regresijos
modelis';
run;
proc gplot data=Duomenys.CukrRunkeliaiLiekT;
plot resid*yhat;
title 'Modelio tyrimas - Standartizuotos liekanos ir transformuoto nuostolingumo
prognoze';
run;
proc univariate normal plot data=Duomenys.CukrRunkeliaiLiekT;
var resid residual;
histogram/normal vaxislabel ='Daznis %';
inset mean='Vidurkis' std='Stand.Nuokrypis'
skewness='Asimetriskumas'/position=ne;
title 'Modelio tyrimas - Liekanu pasiskirstymo tyrimas';
run;

```

---

```

libname Duomenys .....\\Programa'; *nurodyti kur issaugoti duomenys;
data Duomenys.MieziaiMod;
set Duomenys.Mieziai;
Daznis=PolIndemn/PolEarnPrem;
ZalaHa=Indemn/((NetAcres*0.404685642/PolEarnPrem)*PolIndemn);
run;
proc corr data=Duomenys.MieziaiMod spearman; *koreliacija tarp zalos dydzio 1 ha
ir zalu intensyvumo;
var ZalaHa Daznis;
run;
proc univariate data=Duomenys.MieziaiMod;
var ZalaHa Daznis;
run;
proc corr data=Duomenys.MieziaiMod (where=(Daznis ne 1)) spearman; *koreliacija
tarp zalos dydzio 1 ha ir zalu intensyvumo, kai daznis <1;
var ZalaHa Daznis;
run;
proc univariate data=Duomenys.MieziaiMod (where=(Daznis ne 1));
var ZalaHa Daznis;
run;
proc univariate data=Duomenys.MieziaiMod (where=(Daznis eq 1));
var ZalaHa;
run;
proc reg data=Duomenys.MieziaiMod (where=(Daznis ne 1))corr;
model ZalaHa=Daznis/p clm cli;
plot ZalaHa*Daznis/ conf pred;
plot student.*p.;
output out=MieziaiModLiek p=yhat student=resid;
run;

data Duomenys.KvieciaiMod;
set Duomenys.Kvieciai;
Daznis=PolIndemn/PolEarnPrem;
ZalaHa=Indemn/((NetAcres*0.404685642/PolEarnPrem)*PolIndemn);
run;
proc corr data=Duomenys.KvieciaiMod spearman; *koreliacija tarp zalos dydzio 1 ha
ir zalu intensyvumo;
var ZalaHa Daznis;
run;
proc univariate data=Duomenys.KvieciaiMod;
var ZalaHa Daznis;
run;

```



```

proc corr data=Duomenys.KvieciaiMod (where=(Daznis ne 1)) spearman; *koreliacija
tarp zalos dydzio 1 ha ir zalu intensyvumo, kai danzis <1;
    var ZalaHa Daznis;
run;
proc univariate data=Duomenys.KvieciaiMod (where=(Daznis ne 1));
    var ZalaHa Daznis;
run;
proc univariate data=Duomenys.KvieciaiMod (where=(Daznis eq 1));
    var ZalaHa;
run;
proc reg data=Duomenys.KvieciaiMod (where=(Daznis ne 1))corr;
    model ZalaHa=Daznis/p clm cli;
    plot ZalaHa*Daznis/ conf pred;
    plot student.*p.;
    output out=KvieciaiModLiek p=yhat student=resid;
run;

data Duomenys.RapsaiMod;
    set Duomenys.Rapsai;
    if NetAcres ne 0;
    Daznis=PolIndemn/PolEarnPrem;
    ZalaHa=Indemn/((NetAcres*0.404685642/PolEarnPrem)*PolIndemn);
run;
proc corr data=Duomenys.RapsaiMod spearman; *koreliacija tarp zalos dydzio 1 ha ir
zalu intensyvumo;
    var ZalaHa Daznis;
run;
proc univariate data=Duomenys.RapsaiMod;
    var ZalaHa Daznis;
run;
proc corr data=Duomenys.RapsaiMod (where=(Daznis ne 1)) spearman; *koreliacija
tarp zalos dydzio 1 ha ir zalu intensyvumo, kai danzis <1;
    var ZalaHa Daznis;
run;
proc univariate data=Duomenys.RapsaiMod (where=(Daznis ne 1));
    var ZalaHa Daznis;
run;
proc univariate data=Duomenys.RapsaiMod (where=(Daznis eq 1));
    var ZalaHa;
run;
proc reg data=Duomenys.RapsaiMod (where=(Daznis ne 1))corr;
    model ZalaHa=Daznis/p clm cli;
    plot ZalaHa*Daznis/ conf pred;
    plot student.*p.;
    output out=RapsaiModLiek p=yhat student=resid;
run;

data Duomenys.BulvesMod;
    set Duomenys.Bulves;
    Daznis=PolIndemn/PolEarnPrem;
    ZalaHa=Indemn/((NetAcres*0.404685642/PolEarnPrem)*PolIndemn);
run;
proc corr data=Duomenys.BulvesMod spearman; *koreliacija tarp zalos dydzio 1 ha ir
zalu intensyvumo;
    var ZalaHa Daznis;
run;
proc univariate data=Duomenys.BulvesMod;
    var ZalaHa Daznis;
run;
proc corr data=Duomenys.BulvesMod (where=(Daznis ne 1)) spearman; *koreliacija
tarp zalos dydzio 1 ha ir zalu intensyvumo, kai danzis <1;
    var ZalaHa Daznis;
run;
proc univariate data=Duomenys.BulvesMod (where=(Daznis ne 1));

```

```




        var ZalaHa Daznis;
run;
proc univariate data=Duomenys.BulvesMod (where=(Daznis eq 1));
    var ZalaHa;
run;
proc reg data=Duomenys.BulvesMod (where=(Daznis ne 1))corr;
    model ZalaHa=Daznis/p clm cli;
    plot ZalaHa*Daznis/ conf pred;
    plot student.*p.;
    output out=BulvesModLiek p=yhat student=resid;
run;

data Duomenys.CukrRunkeliaiMod;
    set Duomenys.CukrRunkeliai;
    Daznis=PolIndemn/PolEarnPrem;
    ZalaHa=Indemn/((NetAcres*0.404685642/PolEarnPrem)*PolIndemn);
run;
proc corr data=Duomenys.CukrRunkeliaiMod spearman; *koreliacija tarp zalos dydzio
1 ha ir zalu intensyvumo;
    var ZalaHa Daznis;
run;
proc univariate data=Duomenys.CukrRunkeliaiMod;
    var ZalaHa Daznis;
run;
proc corr data=Duomenys.CukrRunkeliaiMod (where=(Daznis ne 1)) spearman;
*koreliacija tarp zalos dydzio 1 ha ir zalu intensyvumo, kai daznis <1;
    var ZalaHa Daznis;
run;
proc univariate data=Duomenys.CukrRunkeliaiMod (where=(Daznis ne 1));
    var ZalaHa Daznis;
run;
proc univariate data=Duomenys.CukrRunkeliaiMod (where=(Daznis eq 1));
    var ZalaHa;
run;
proc reg data=Duomenys.CukrRunkeliaiMod (where=(Daznis ne 1))corr;
    model ZalaHa=Daznis/p clm cli;
    plot ZalaHa*Daznis/ conf pred;
    plot student.*p.;
    output out=CukrRunkeliaiModLiek p=yhat student=resid;
run;




```

## 6 PRIEDAS. DUOMENŲ APROKSIMAVIMAS NUPJAUTU PASTUMTU PARETO SKIRSTINIŲ




1. Paklaidų paviršius ir nupjauto pastumto Pareto skirstinio parametrai kviečių DRPD nuostolingumui bei tankio ir pasiskirstymo funkcijų palyginimas:






2. Paklaidų paviršius ir nupjauto pastumto Pareto skirstinio parametrai miežių DRPD nuostolingumui bei tankio ir pasiskirstymo funkcijų palyginimas:



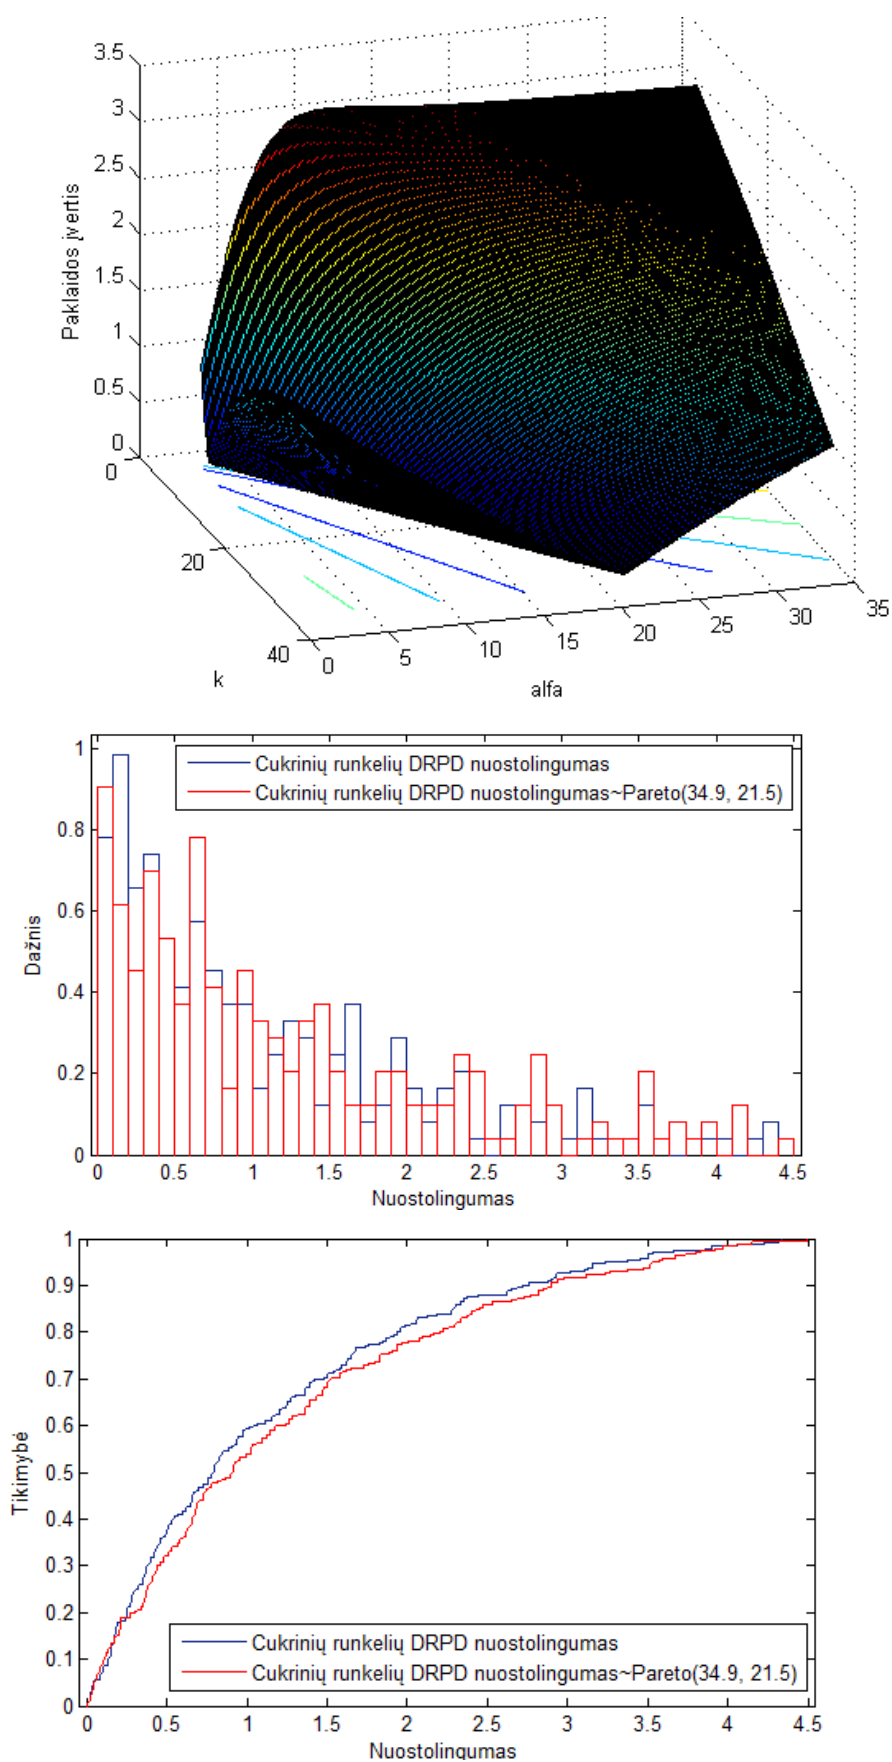
3. Paklaidų paviršius ir nupjauto pastumto Pareto skirstinio parametrai rapsų DRPD nuostolingumui bei tankio ir pasiskirstymo funkcijų palyginimas:



4. Paklaidų paviršius ir nupjauto pastumto Pareto skirstinio parametrai bulvių DRPD nuostolingumui bei tankio ir pasiskirstymo funkcijų palyginimas:



5. Paklaidų paviršius ir nupjauto pastumto Pareto skirstinio parametrai cukrinių runkelių DRPD nuostolingumui bei tankio ir pasiskirstymo funkcijų palyginimas:



## 7 PRIEDAS. MATLAB M RINKMENOS TEKSTAS

```

function varargout = Programa(varargin)
    gui_Singleton = 1;
    gui_State = struct('gui_Name',       mfilename, ...
                       'gui_Singleton',  gui_Singleton, ...
                       'gui_OpeningFcn', @Programa_OpeningFcn, ...
                       'gui_OutputFcn',  @Programa_OutputFcn, ...
                       'gui_LayoutFcn',  [] , ...
                       'gui_Callback',   []);
    if nargin && ischar(varargin{1})
        gui_State.gui_Callback = str2func(varargin{1});
    end

    if nargout
        [varargout{1:nargout}] = gui_mainfcn(gui_State, varargin{:});
    else
        gui_mainfcn(gui_State, varargin{:});
    end
function Programa_OpeningFcn(hObject, eventdata, handles, varargin)
    handles.output = hObject;
    axes(handles.axes1);
    cla
    load duomenys.mat;
    guidata(hObject, handles);
function varargout = Programa_OutputFcn(hObject, eventdata, handles)
    varargout{1} = handles.output;
function pushbutton1_Callback(hObject, eventdata, handles)
    % kviečiai
    axes(handles.axes1);
    cla
    x0=0.0021; x1=3.7; vidurkis=1.0752; dispersija=0.813604;
    asimetriskumas=0.9455;
    d=x0;
    paklaida=ones([270 270]);
    [alfa,k]=meshgrid(3.1:0.1:30, 3.1:0.1:30);
    alfa=3.1:0.1:30;
    k=3.1:0.1:30;
    for i=1:270;
        for j=1:270;
            F=((k(j)+d)^alfa(i))/(1-((k(j)+d)/(k(j)+x1))^alfa(i));
            F1=F/(alfa(i)-1);
            F2=F/((alfa(i)-1)*(alfa(i)-2));
            F3=F/((alfa(i)-3)*(alfa(i)-2)*(alfa(i)-1));
            v1=(k(j)+x0)^alfa(i);
            v2=(k(j)+x1)^alfa(i);
            vidSP=F1*((k(j)+x0*alfa(i))/v1-(k(j)+x1*alfa(i))/v2);
            dispSP=F2*((x0^2*alfa(i)^2+2*k(j)*x0*alfa(i)-
x0^2*alfa(i)+2*k(j)^2)/v1-(x1^2*alfa(i)^2+2*k(j)*x1*alfa(i)-
x1^2*alfa(i)+2*k(j)^2)/v2)-vidSP^2;
            asimSP=(F3*((6*k(j)^3+6*k(j)^2*x0*alfa(i)-
3*k(j)*x0^2*alfa(i)+3*k(j)*x0^2*alfa(i)^2+x0^3*alfa(i)^3+2*x0^3*alfa(i)-
3*x0^3*alfa(i)^2)/v1-(6*k(j)^3+6*k(j)^2*x1*alfa(i)-
3*k(j)*x1^2*alfa(i)+3*k(j)*x1^2*alfa(i)^2+x1^3*alfa(i)^3+2*x1^3*alfa(i)-
3*x1^3*alfa(i)^2)/v2)-3*vidSP*dispSP-vidSP^3)/dispSP^(3/2);
            paklaida(i,j)=2*abs(vidurkis-
vidSP)/(vidurkis+vidSP)+abs(sqrt(dispersija)/vidurkis-
sqrt(dispSP)/vidSP)+abs(asimetriskumas-asimSP);
        end
    end
    surf(k, alfa, paklaida)
    rotate3d on

```



```

xlabel('k');
ylabel('alfa');
zlabel('Paklaidos įvertis');
hold on;
[m,I]=min(min(paklaida));
kest=k(1,I);
paklaida=paklaida';
[m,I]=min(min(paklaida));
alfaest=alfa(1,I);
dat=[kest alfaest m];
cnames = {'k','alfa','Paklaidos įvertis'};
t = uitable('Data',dat,'ColumnName',cnames,'Position',[250 20 300 50]);
function pushbutton2_Callback(hObject, eventdata, handles)
% miežiai
axes(handles.axes1);
cla
x0=0.0034; x1=5.4; vidurkis=1.5614; dispersija=1.361656;
asimetriskumas=0.9105;
d=x0;
paklaida=ones([270 270]);
[alfa,k]=meshgrid(3.1:0.1:30, 3.1:0.1:30);
alfa=3.1:0.1:30;
k=3.1:0.1:30;
for i=1:270;
    for j=1:270;
        F=((k(j)+d)^alfa(i))/(1-((k(j)+d)/(k(j)+x1))^alfa(i));
        F1=F/(alfa(i)-1);
        F2=F/((alfa(i)-1)*(alfa(i)-2));
        F3=F/((alfa(i)-3)*(alfa(i)-2)*(alfa(i)-1));
        v1=(k(j)+x0)^alfa(i);
        v2=(k(j)+x1)^alfa(i);
        vidSP=F1*((k(j)+x0*alfa(i))/v1-(k(j)+x1*alfa(i))/v2);
        dispSP=F2*((x0^2*alfa(i)^2+2*k(j)*x0*alfa(i)-
x0^2*alfa(i)+2*k(j)^2)/v1-(x1^2*alfa(i)^2+2*k(j)*x1*alfa(i)-
x1^2*alfa(i)+2*k(j)^2)/v2)-vidSP^2;
        asimSP=(F3*((6*k(j)^3+6*k(j)^2*x0*alfa(i)-
3*k(j)*x0^2*alfa(i)+3*k(j)*x0^2*alfa(i)^2+x0^3*alfa(i)^3+2*x0^3*alfa(i)-
3*x0^3*alfa(i)^2)/v1-(6*k(j)^3+6*k(j)^2*x1*alfa(i)-
3*k(j)*x1^2*alfa(i)+3*k(j)*x1^2*alfa(i)^2+x1^3*alfa(i)^3+2*x1^3*alfa(i)-
3*x1^3*alfa(i)^2)/v2)-3*vidSP*dispSP-vidSP^3)/dispSP^(3/2);
        paklaida(i,j)=2*abs(vidurkis-
vidSP)/(vidurkis+vidSP)+abs(sqrt(dispersija)/vidurkis-
sqrt(dispSP)/vidSP)+abs(asimetriskumas-asimSP);
    end
end
end
surf(k,alfa,paklaida)
rotate3d on
xlabel('k');
ylabel('alfa');
zlabel('Paklaidos įvertis');
hold on;
[m,I]=min(min(paklaida));
kest=k(1,I);
paklaida=paklaida';
[m,I]=min(min(paklaida));
alfaest=alfa(1,I);
dat=[kest alfaest m];
cnames = {'k','alfa','Paklaidos įvertis'};
t = uitable('Data',dat,'ColumnName',cnames,'Position',[250 20 300 50]);
function pushbutton3_Callback(hObject, eventdata, handles)
% runkeliai
axes(handles.axes1);
cla

```

```

x0=0.0037; x1=4.4; vidurkis=1.1228; dispersija=1.058841;
asimetriskumas=1.1509;
d=x0;
paklaida=ones([270 270]);
[alfa,k]=meshgrid(3.1:0.1:30, 3.1:0.1:30);
alfa=3.1:0.1:30;
k=3.1:0.1:30;
for i=1:270;
    for j=1:270;
        F=((k(j)+d)^alfa(i))/(1-((k(j)+d)/(k(j)+x1))^alfa(i));
        F1=F/(alfa(i)-1);
        F2=F/((alfa(i)-1)*(alfa(i)-2));
        F3=F/((alfa(i)-3)*(alfa(i)-2)*(alfa(i)-1));
        v1=(k(j)+x0)^alfa(i);
        v2=(k(j)+x1)^alfa(i);
        vidSP=F1*((k(j)+x0*alfa(i))/v1-(k(j)+x1*alfa(i))/v2);
        dispSP=F2*((x0^2*alfa(i)^2+2*k(j)*x0*alfa(i)-
x0^2*alfa(i)+2*k(j)^2)/v1-(x1^2*alfa(i)^2+2*k(j)*x1*alfa(i)-
x1^2*alfa(i)+2*k(j)^2)/v2)-vidSP^2;
        asimSP=(F3*((6*k(j)^3+6*k(j)^2*x0*alfa(i)-
3*k(j)*x0^2*alfa(i)+3*k(j)*x0^2*alfa(i)^2+x0^3*alfa(i)^3+2*x0^3*alfa(i)-
3*x0^3*alfa(i)^2)/v1-(6*k(j)^3+6*k(j)^2*x1*alfa(i)-
3*k(j)*x1^2*alfa(i)+3*k(j)*x1^2*alfa(i)^2+x1^3*alfa(i)^3+2*x1^3*alfa(i)-
3*x1^3*alfa(i)^2)/v2)-3*vidSP*dispSP-vidSP^3)/dispSP^(3/2);
        paklaida(i,j)=2*abs(vidurkis-
vidSP)/(vidurkis+vidSP)+abs(sqrt(dispersija)/vidurkis-
sqrt(dispSP)/vidSP)+abs(asimetriskumas-asimSP);
    end
end
surf(k, alfa, paklaida)
rotate3d on
xlabel('k');
ylabel('alfa');
zlabel('Paklaidos ivertis');
hold on;
[m,I]=min(min(paklaida));
kest=k(1,I);
paklaida=paklaida';
[m,I]=min(min(paklaida));
alfaest=alfa(1,I);
dat=[kest alfaest m];
cnames = {'k', 'alfa', 'Paklaidos ivertis'};
t =uitable('Data', dat, 'ColumnName', cnames, 'Position', [250 20 300 50]);
function pushbutton4_Callback(hObject, eventdata, handles)
% bulvès
axes(handles.axes1);
cla
x0=0.028; x1=7.7; vidurkis=2.1732; dispersija=3.359156; asimetriskumas=1.112;
d=x0;
paklaida=ones([270 270]);
[alfa,k]=meshgrid(3.1:0.1:30, 3.1:0.1:30);
alfa=3.1:0.1:30;
k=3.1:0.1:30;
for i=1:270;
    for j=1:270;
        F=((k(j)+d)^alfa(i))/(1-((k(j)+d)/(k(j)+x1))^alfa(i));
        F1=F/(alfa(i)-1);
        F2=F/((alfa(i)-1)*(alfa(i)-2));
        F3=F/((alfa(i)-3)*(alfa(i)-2)*(alfa(i)-1));
        v1=(k(j)+x0)^alfa(i);
        v2=(k(j)+x1)^alfa(i);
        vidSP=F1*((k(j)+x0*alfa(i))/v1-(k(j)+x1*alfa(i))/v2);

```

```

dispSP=F2*((x0^2*alfa(i)^2+2*k(j)*x0*alfa(i)-
x0^2*alfa(i)+2*k(j)^2)/v1-(x1^2*alfa(i)^2+2*k(j)*x1*alfa(i)-
x1^2*alfa(i)+2*k(j)^2)/v2)-vidSP^2;
asimSP=(F3*((6*k(j)^3+6*k(j)^2*x0*alfa(i)-
3*k(j)*x0^2*alfa(i)+3*k(j)*x0^2*alfa(i)^2+x0^3*alfa(i)^3+2*x0^3*alfa(i)-
3*x0^3*alfa(i)^2)/v1-(6*k(j)^3+6*k(j)^2*x1*alfa(i)-
3*k(j)*x1^2*alfa(i)+3*k(j)*x1^2*alfa(i)^2+x1^3*alfa(i)^3+2*x1^3*alfa(i)-
3*x1^3*alfa(i)^2)/v2)-3*vidSP*dispSP-vidSP^3)/dispSP^(3/2);
paklaida(i,j)=2*abs(vidurkis-
vidSP)/(vidurkis+vidSP)+abs(sqrt(dispersija)/vidurkis-
sqrt(dispSP)/vidSP)+abs(asimetriskumas-asimSP);
end
end
surfc(k,alfa,paklaida)
rotate3d on
xlabel('k');
ylabel('alfa');
zlabel('Paklaidos ivertis');
hold on;
[m,I]=min(min(paklaida));
kest=k(1,I);
paklaida=paklaida';
[m,I]=min(min(paklaida));
alfaest=alfa(1,I);
dat=[kest alfaest m];
cnames = {'k','alfa','Paklaidos ivertis'};
t =uitable('Data',dat,'ColumnName',cnames,'Position',[250 20 300 50]);
function pushbutton5_Callback(hObject, eventdata, handles)
% rapsai
axes(handles.axes1);
cla
x0=0.0101; x1=5.51; vidurkis=1.453; dispersija=1.384388;
asimetriskumas=1.1025;
d=x0;
paklaida=ones([320 320]);
[alfa,k]=meshgrid(3.1:0.1:35, 3.1:0.1:35);
alfa=3.1:0.1:35;
k=3.1:0.1:35;
for i=1:320;
for j=1:320;
F=((k(j)+d)^alfa(i))/(1-((k(j)+d)/(k(j)+x1))^alfa(i));
F1=F/(alfa(i)-1);
F2=F/((alfa(i)-1)*(alfa(i)-2));
F3=F/((alfa(i)-3)*(alfa(i)-2)*(alfa(i)-1));
v1=(k(j)+x0)^alfa(i);
v2=(k(j)+x1)^alfa(i);
vidSP=F1*((k(j)+x0*alfa(i))/v1-(k(j)+x1*alfa(i))/v2);
dispSP=F2*((x0^2*alfa(i)^2+2*k(j)*x0*alfa(i)-
x0^2*alfa(i)+2*k(j)^2)/v1-(x1^2*alfa(i)^2+2*k(j)*x1*alfa(i)-
x1^2*alfa(i)+2*k(j)^2)/v2)-vidSP^2;
asimSP=(F3*((6*k(j)^3+6*k(j)^2*x0*alfa(i)-
3*k(j)*x0^2*alfa(i)+3*k(j)*x0^2*alfa(i)^2+x0^3*alfa(i)^3+2*x0^3*alfa(i)-
3*x0^3*alfa(i)^2)/v1-(6*k(j)^3+6*k(j)^2*x1*alfa(i)-
3*k(j)*x1^2*alfa(i)+3*k(j)*x1^2*alfa(i)^2+x1^3*alfa(i)^3+2*x1^3*alfa(i)-
3*x1^3*alfa(i)^2)/v2)-3*vidSP*dispSP-vidSP^3)/dispSP^(3/2);
paklaida(i,j)=2*abs(vidurkis-
vidSP)/(vidurkis+vidSP)+abs(sqrt(dispersija)/vidurkis-
sqrt(dispSP)/vidSP)+abs(asimetriskumas-asimSP);
end
end
surfc(k,alfa,paklaida)
rotate3d on
xlabel('k');
ylabel('alfa');

```

```

        xlabel('Paklaidos įvertis');
    hold on;
    [m,I]=min(min(paklaida));
    kest=k(1,I);
    paklaida=paklaida';
    [m,I]=min(min(paklaida));
    alfaest=alfa(1,I);
    dat=[kest alfaest m];
    cnames = {'k','alfa','Paklaidos įvertis'};
    t = uitable('Data',dat,'ColumnName',cnames,'Position',[250 20 300 50]);
% -----%
function pushbutton11_Callback(hObject, eventdata, handles)
% kviečiai
axes(handles.axes3);
x0=0.0021; x1=3.7; k = 10.8; alfa = 8.3; d=x0;
LRWPar=ones([942 1]);
for i=1:942
    LRWPar(i)=(k+d)/((1-unifrnd(0,1,1,1)).^(1/alfa))-k);
    while LRWPar(i)>x1; LRWPar(i)=(k+d)/((1-unifrnd(0,1,1,1)).^(1/alfa))-k);
    end;
end;
LRWPar=sort(LRWPar);
dat=[mean(LRWPar) var(LRWPar) skewness(LRWPar)];
cnames = {'Vidurkis','Dispersija','Asimetriškumas'};
t = uitable('Data',dat,'ColumnName',cnames,'Position',[630 20 300 50]);
hist(LRWPar);
xlabel('Nuostolingumas');
ylabel('Dažnis');
function pushbutton12_Callback(hObject, eventdata, handles)
% miežiai
axes(handles.axes3);
x0=0.0034; x1=5.5; k=29.9; alfa=15.1; d=x0;
LRBPar=ones([886 1]);
for i=1:886
    LRBPar(i)=(k+d)/((1-unifrnd(0,1,1,1)).^(1/alfa))-k);
    while LRBPar(i)>x1; LRBPar(i)=(k+d)/((1-unifrnd(0,1,1,1)).^(1/alfa))-k);
    end;
end;
LRBPar=sort(LRBPar);
dat=[mean(LRBPar) var(LRBPar) skewness(LRBPar)];
cnames = {'Vidurkis','Dispersija','Asimetriškumas'};
t = uitable('Data',dat,'ColumnName',cnames,'Position',[630 20 300 50]);
hist(LRBPar);
xlabel('Nuostolingumas');
ylabel('Dažnis');
function pushbutton13_Callback(hObject, eventdata, handles)
% rapsai
axes(handles.axes3);
x0=0.0101; x1=5.6; k=3.7; alfa=3.1; d=x0;
LRCPPar=ones([357 1]);
for i=1:357
    LRCPPar(i)=(k+d)/((1-unifrnd(0,1,1,1)).^(1/alfa))-k);
    while LRCPPar(i)>x1; LRCPPar(i)=(k+d)/((1-unifrnd(0,1,1,1)).^(1/alfa))-k);
    end;
end;
LRCPPar=sort(LRCPPar);
dat=[mean(LRCPPar) var(LRCPPar) skewness(LRCPPar)];
cnames = {'Vidurkis','Dispersija','Asimetriškumas'};
t = uitable('Data',dat,'ColumnName',cnames,'Position',[630 20 300 50]);
hist(LRCPPar);
xlabel('Nuostolingumas');
ylabel('Dažnis');
function pushbutton14_Callback(hObject, eventdata, handles)
% bulvės

```

```

axes(handles.axes3);
x0=0.028; x1=7.8; k = 29.5; alfa = 13.2; d = x0;
LRPPar=ones([249 1]);
for i=1:249
    LRPPar(i)=(k+d)/((1-unifrnd(0,1,1,1)).^(1/alfa))-k;
    while LRPPar(i)>x1; LRPPar(i)=(k+d)/((1-unifrnd(0,1,1,1)).^(1/alfa))-k;
    end;
end;
LRPPar=sort(LRPPar);
dat=[mean(LRPPar) var(LRPPar) skewness(LRPPar)];
cnames = {'Vidurkis','Dispersija','Asimetriškumas'};
t = uitable('Data',dat,'ColumnName',cnames,'Position',[630 20 300 50]);
hist(LRPPar);
xlabel('Nuostolingumas');
ylabel('Dažnis');
function pushbutton15_Callback(hObject, eventdata, handles)
% runkeliai
axes(handles.axes3);
x0=0.0037; x1=4.5; k = 34.9; alfa =21.5; d=x0;
LRSPPar=ones([243 1]);
for i=1:243
    LRSPPar(i)=(k+d)/((1-unifrnd(0,1,1,1)).^(1/alfa))-k;
    while LRSPPar(i)>x1; LRSPPar(i)=(k+d)/((1-unifrnd(0,1,1,1)).^(1/alfa))-
k);
    end;
end;
LRSPPar=sort(LRSPPar);
dat=[mean(LRSPPar) var(LRSPPar) skewness(LRSPPar)];
cnames = {'Vidurkis','Dispersija','Asimetriškumas'};
t = uitable('Data',dat,'ColumnName',cnames,'Position',[630 20 300 50]);
hist(LRSPPar);
xlabel('Nuostolingumas');
ylabel('Dažnis');
function pushbutton16_Callback(hObject, eventdata, handles)
exit;

```

## 8 PRIEDAS. ŽALOS DYDŽIO 1 HA REGRESINĖ ANALIZĖ

### 1. Miežiai:

8.156 lentelė.

#### Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	141182	141182	85.84	<.0001
Error	774	1273051	1644.76894		
Corrected Total	775	1414233			

8.2 lentelė.

#### Dispersinės analizės rezultatai (2)

Root MSE	40.55575	R-Square	0.0998
Dependent Mean	52.37746	Adj R-Sq	0.0987
Coeff Var	77.42978		

8.3 lentelė.


#### Parametų įverčių ir hipotezių tikrinimo rezultatai

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
Intercept	1	25.95080	3.20243	8.10
Daznis	1	61.10152	6.59501	9.26

8.4 lentelė.

#### Modelio liekanos

Sum of Residuals	0
Sum of Squared Residuals	1273051
Predicted Residual SS (PRESS)	1279264



8.1 pav. Miežių modelio normuotų liekanų grafikas

## 2. Kviečiai:

8.5 lentelė.

## Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	91906	91906	66.64	<.0001
Error	842	1161318	1379.23718		
Corrected Total	843	1253224			

8.6 lentelė.

## Dispersinės analizės rezultatai (2)

Root MSE	37.13808	R-Square	0.0733
Dependent Mean	37.23822	Adj R-Sq	0.0722
Coeff Var	99.73109		

8.7 lentelė.


## Parametrų įverčių ir hipotezių tikrinimo rezultatai

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
Intercept	1	19.09042	2.56449	7.44
Daznis	1	44.78512	5.48632	8.16

8.8 lentelė.

## Modelio liekanos

Sum of Residuals	0
Sum of Squared Residuals	1161318
Predicted Residual SS (PRESS)	1166524



8.2 pav. Kviečių modelio normuotų liekanų grafikas

3. Rapsai:

8.9 lentelė.

Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	99448	99448	51.98	<.0001
Error	319	610251	1913.01199		
Corrected Total	320	709698			

8.10 lentelė.

Dispersinės analizės rezultatai (2)

Root MSE	43.73799	R-Square	0.1401
Dependent Mean	63.76752	Adj R-Sq	0.1374
Coeff Var	68.58976		

8.11 lentelė.


Parametrų įverčių ir hipotezių tikrinimo rezultatai

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
Intercept	1	25.04015	5.90004	4.24
Daznis	1	81.37119	11.28580	7.21

8.12 lentelė.

Modelio liekanos

Sum of Residuals	0
Sum of Squared Residuals	610251
Predicted Residual SS (PRESS)	616908



8.3 pav. Rapsų modelio normuotų liekanų grafikas



## 4. Bulvės:

8.13 lentelė.

## Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	2433783	2433783	9.92	0.0020
Error	138	33870518	245439		
Corrected Total	139	36304301			

8.14 lentelė.

## Dispersinės analizės rezultatai (2)

Root MSE	495.41754	R-Square	0.0670
Dependent Mean	547.62523	Adj R-Sq	0.0603
Coeff Var	90.46653		

8.15 lentelė.


## Parametrų įverčių ir hipotezių tikrinimo rezultatai

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
Intercept	1	240.76214	106.06291	2.27
Daznis	1	604.59011	191.99569	3.15

8.16 lentelė.

## Modelio liekanos

Sum of Residuals	0
Sum of Squared Residuals	33870518
Predicted Residual SS (PRESS)	34700371



8.4 pav. Bulvių modelio normuotų liekanų grafikas

## 5. Cukriniai runkeliai:

8.17 lentelė.

## Dispersinės analizės rezultatai (1)

Source	DF	Sum of Squares	Mean Square	F Value	Pr > F
Model	1	1816247	1816247	24.06	<.0001
Error	240	18113624	75473		
Corrected Total	241	19929871			

8.18 lentelė.

## Dispersinės analizės rezultatai (2)

Root MSE	274.72429	R-Square	0.0911
Dependent Mean	273.10671	Adj R-Sq	0.0873
Coeff Var	100.59229		

8.19 lentelė.


## Parametrų įverčių ir hipotezių tikrinimo rezultatai

Variable	Param. Estimate	Stand. Error	t Value	Pr >  t
Intercept	1	134.79949	33.26811	4.05
Daznis	1	406.90866	82.94812	4.91

8.20 lentelė.

## Modelio liekanos

Sum of Residuals	0
Sum of Squared Residuals	18113624
Predicted Residual SS (PRESS)	18396864



8.5 pav. Cukrinių runkelių modelio normuotų liekanų grafikas