

LOGISTINĖ REGRESIJA

Logistic Regression

TRUMPAI

Dvireikšmė (*binary*) logistinė regresija
– toks modelis, kai vienam
(priklausomam) **dvireikšmiui**
kintamajam daro įtaką vienas ar
keletas (nepriklausomų, aiškinamųjų)
kintamųjų.

**Yra ir daugelio kintamųjų logistinė
regresija. Jos nenagrinėsime.**

PAVYZDŽIAI

- Pagal paciento svorį ir kraujo tyrimus reikia nustatyti tikimybę susirgti diabetu.
- Pagal testų rezultatus siekiama nustatyti, ar reiks kompiuteriui garantinio remonto.
- Aiškinamasi, ar žinant rinkėjo pajamas ir amžių galima numatyti, balsuos jis už kandidatą ar nebalsuos.

KINTAMIEJI

- Priklausomas kintamasis Y – dvireikšmis (0 arba 1).
- Aiškinamieji kintamieji (X) – intervaliniai arba pseudokintamieji.
- Jei Y įgyja kitokias dvi reikšmes – jis perkoduojamas.
- Vienetai (nuliai) sudaro ne daugiau kaip 80 % Y stebėjimų.

Modelis:

$$P(Y = 1) = \frac{e^{z(x)}}{1 + e^{z(x)}};$$

čia

$$z(x) = \alpha + \beta_1 x_1 + \dots + \beta_k x_k.$$

Kitas modelio užrašas

$$\ln \frac{P(Y = 1)}{P(Y = 0)} = z(\mathbf{x});$$

čia

$$z(\mathbf{x}) = \alpha + \beta_1 x_1 + \dots + \beta_k x_k.$$

Tikslai

- Rasti parametrų $\alpha, \beta_1, \dots, \beta_K$ verčius $\hat{\alpha}, \hat{\beta}_1, \dots, \hat{\beta}_K$.
- Išsiaiškinti, kaip gerai modelis tinka duomenims.
- Gebėti modelį pritaikyti prognozėms.

Šiek tiek terminų

Tikimybių santykis

$$\frac{P(Y = 1)}{1 - P(Y = 1)}$$

vadinamas įvykio $Y = 1$ galimybe (*odds*).

Galimybių santykis

Koeficiento β_k eksponentė $\exp\{\beta_k\}$ dar vadinama **galimybių santykiu** (*odds ratio*).

Galimybių santykis parodo, kaip keičiasi **$Y=1$** galimybė, kai **x_k** padidėja vienetu (kiti x nekinta).

Logistinės regresijos pavyzdys

Norėdamas sužinoti, ar inkubacinės aplinkos temperatūra turi įtakos vėžliukų lyčiai, Ajovos universiteto profesorius K. Koehler tyrė, kiek kokios lyties vėžliukų išsiritu iš skirtingose temperatūrose laikytų vėžlio kiaušinių.

Duomenys

Temperatūra Vėžliukai Vėžliukės

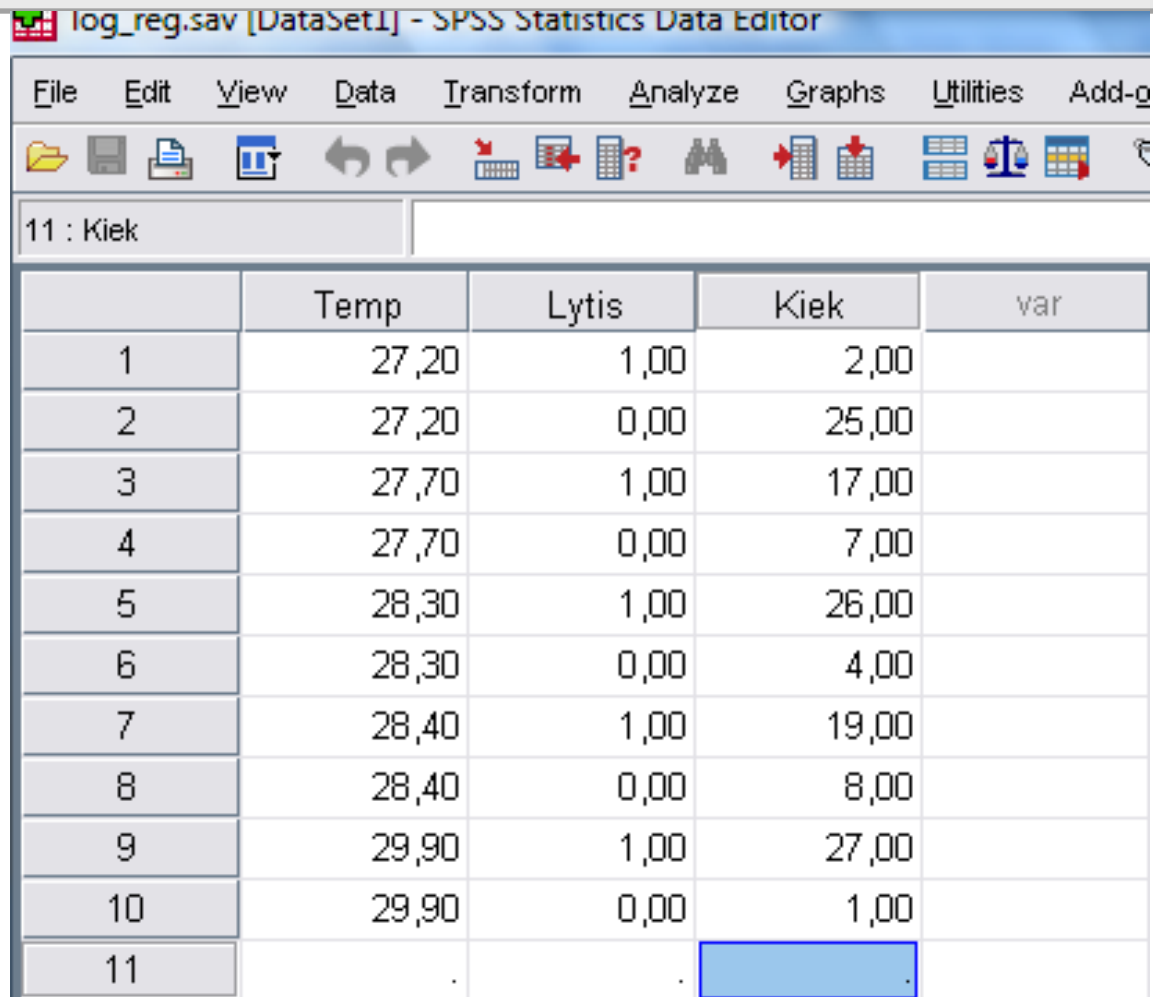
27,2 C ⁰	2	25
27,7 C ⁰	17	7
28,3 C ⁰	26	4
28,4 C ⁰	19	8
28,9 C ⁰	27	1

LOGISTINĖ REGRESIJA naudojant **SPSS** programą

Duomenų įvedimas

Duomenis galima įvesti keliais skirtingais būdais. Pateikiame vieną iš jų. Pagal **SPSS** taisyklės kiekvienam subjektui (individui, vėžliukui(ei)) skiriama viena duomenų eilutė. Kadangi informacija kartojasi, naudojame svorius.

Duomenys atrodo taip



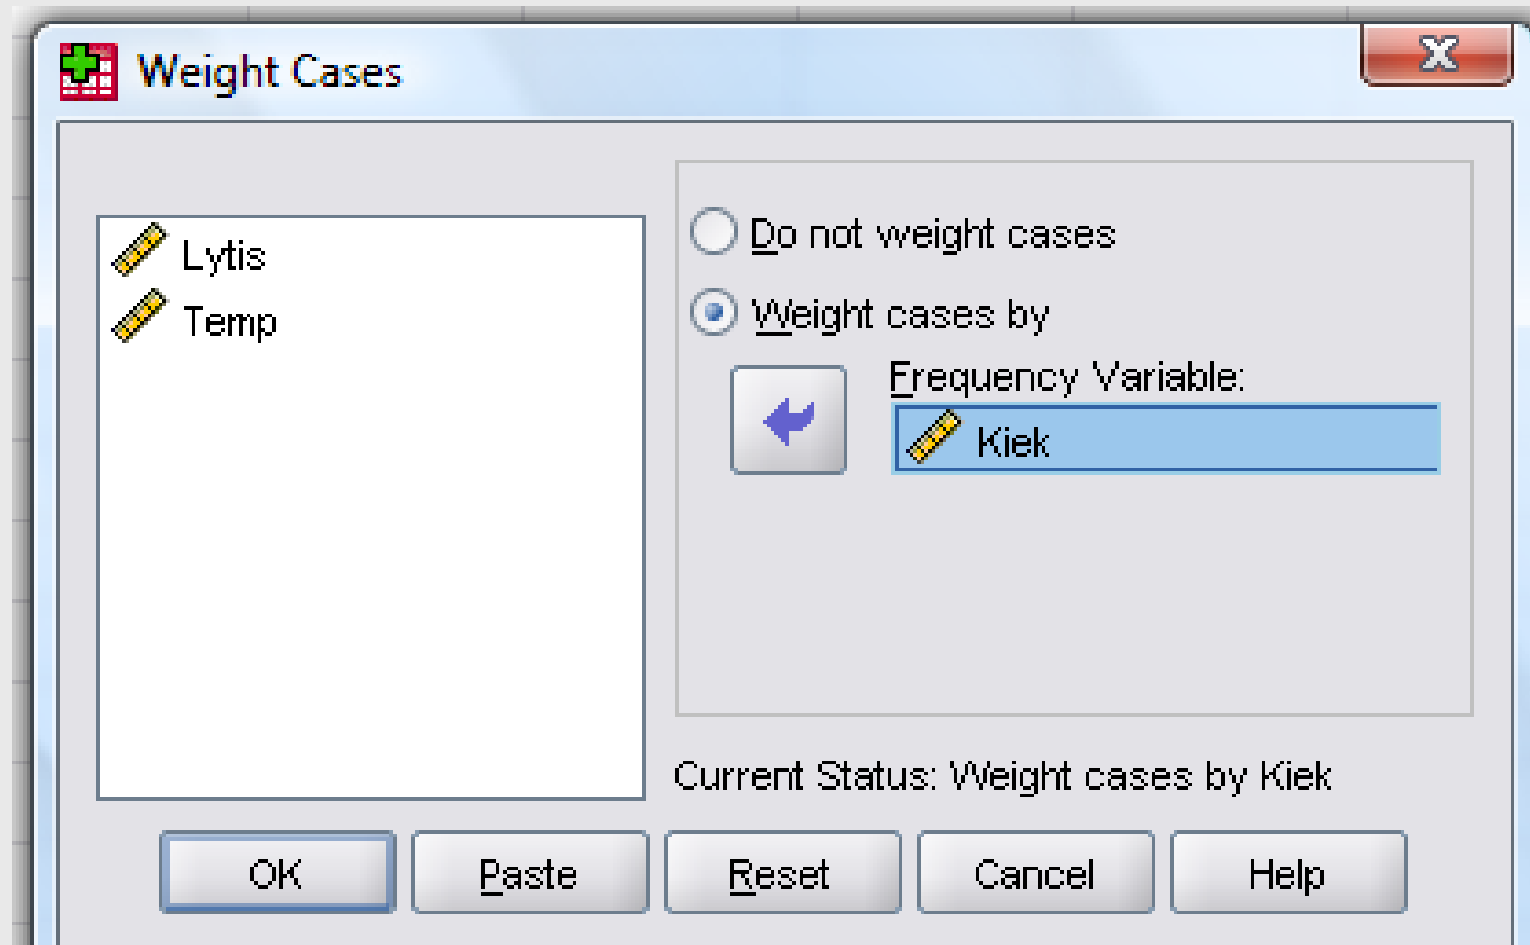
log_reg.sav [DataSet1] - SPSS Statistics Data Editor

File Edit View Data Transform Analyze Graphs Utilities Add-on

11 : Kiek

	Temp	Lytis	Kiek	var
1	27,20	1,00	2,00	
2	27,20	0,00	25,00	
3	27,70	1,00	17,00	
4	27,70	0,00	7,00	
5	28,30	1,00	26,00	
6	28,30	0,00	4,00	
7	28,40	1,00	19,00	
8	28,40	0,00	8,00	
9	29,90	1,00	27,00	
10	29,90	0,00	1,00	
11	.	.	.	

Nepamirštame pasverti



Logistinę regresiją SPSS programa galima atlikti dviem būdais

- Naudojantis parinktimi *Binary logistic*.
- Nagrinėjant kaip atskirą GLM atvejį.

Visi rezultatai sutaps, tačiau pirmuoju atveju papildomai gausime klasifikavimo lentelę, o antruoju – deviaciją.

PROCEDŪRA

BINARY LOGISTIC

SPSS programa

Logistinė regresija su *Binary Logistic*

The screenshot shows the SPSS Statistics Data Editor interface. The 'Analyze' menu is open, and the 'Regression' option is selected. The 'Binary Logistic...' option is highlighted in the sub-menu. A yellow speech bubble with the text 'Čia' (Here) points to the 'Binary Logistic...' option.

Statistics Data Editor

Form Analyze Graphs Utilities Add-ons Window Help

Lyti

Reports

Descriptive Statistics

Tables

RFM Analysis

Compare Means

General Linear Model

Generalized Linear Models

Mixed Models

Correlate

Regression

Loglinear

Neural Networks

Classify

Dimension Reduction

Linear...

Curve Estimation...

Partial Least Squares...

Binary Logistic...

Čia

Logistinė regresija su *Binary Logistic*

The image shows a screenshot of the SPSS 'Binary Logistic' dialog box. The window title is 'Logis...'. On the left, a list of variables includes 'Kiek' and 'Temp'. The 'Dependent:' field contains 'Lytis'. The 'Covariates:' field contains 'Temp'. The 'Method:' dropdown is set to 'Enter'. The 'Selection Variable:' field is empty. On the right, there are buttons for 'Categorical...', 'Save...', and 'Options...'. At the bottom, there are buttons for 'OK', 'Paste', 'Reset', 'Cancel', and 'Help'. Three yellow speech bubbles with Lithuanian text are overlaid on the dialog:

- 'Priklausomas' (Dependent) points to the 'Lytis' variable in the 'Dependent:' field.
- 'Aiškinamasis' (Covariate) points to the 'Temp' variable in the 'Covariates:' field.
- 'Po to čia' (After this) points to the 'Options...' button.

Logistinė regresija su *Binary Logistic*

Varnelė

Logistic Regression: Options

Statistics and Plots

- Classification plots
- Hosmer-Lemeshow goodness-of-fit
- Casewise listing of residuals
- Outliers outside 2 std. dev.
- All cases
- Correlations of estimates
- Iteration history
- CI for exp(B): 95 %

Display

- At each step
- At last step

Probability for Stepwise

Entry: 0,05 Removal: 0,10

Classification cutoff: 0,5

Maximum iterations: 20

Include constant in model

Continue Cancel Help

Po to čia

Logistinė regresija su *Binary Logistic*

The screenshot shows the 'Logistic Regression' dialog box. On the left, a list of variables includes 'Kiek' and 'Temp'. The 'Dependent' field contains 'Lytis'. The 'Covariates' list contains 'Temp'. The 'Method' dropdown is set to 'Enter'. The 'Selection Variable' field is empty. The 'OK' button is highlighted by a yellow speech bubble containing the text 'Po to čia'.

Svarbi pastaba

Jeigu turėtume kategorinių kintamųjų, tai juos įtrauktume į *Covariates* ir į *Categorical*. SPSS automatiškai kiekvieną kategorinį kintamąjį modelyje pakeis reikiamu kiekiu dvireikšmių pseudokintamųjų.



Logistinė regresija su *Binary Logistic*

Dependent Variable Encoding

Original Value	Internal Value
mot	0
vyr	1

Kintamojo kodai

Kintamojo kodai sutapo su modelio kodais. Taip bus ne visada. Modelio vienetu visada tampa didesnioji Y reikšmė.

Klasifikavimo lentelė

Classification Table^a

Duomenys		Predicted		Percentage Correct
		mot	vyr	
Step 1	Observed Lytis	mot	vyr	
		32	13	71,1
		19	72	79,1
	Overall Percentage			76,5

Prognozė

Duomenys

Teisinga prognozė

a. The cut value is ,500

Klasifikavimo lentelė

Classification Table^a

Observed		Predicted		Percentage Correct
		Lytis		
		mot	vvr	
Step 1	Lytis			
	<u>mot</u>	32	13	71,1
	vyr	19	72	79,1
	Overall Percentage			76,5

a. The cut value is ,500

Klaidos

Klasifikavimo lentelė

Classification Table^a

Observed		Predicted		Percentage Correct
		Lytis		
		mot	vyr	
Step 1	Lytis			
	mot	32	13	71,1
	vyr	19	72	79,1
	Overall Percentage			76,5

a. The cut value is ,500

Teisingų prognozių procentai

Išvados, žvelgiant į klasifikavimo lentelę

Matome, kad modelį taikant turimiems duomenims teisingai klasifikuojama per 70 % vėžlių.

Tai labai svarbus modelio tinkamumo rodiklis. **Jeigu teisingai klasifikuojama nedaug turimos imties objektų, tai logistinės regresijos modelis duomenims netinka.** Ir visai nesvarbu, jeigu kiti rodikliai rodytų priešingai.

Pastabos

- Neužtenka gero **bendrojo** teisingo klasifikavimo procento.
- Nė viena iš dviejų Y reikšmių neturi kartotis daugiau kaip 80% kartų.
- Geras klasifikavimas yra būtina, bet nepakankama sąlyga, kad tiktų logistinės regresijos modelis.

χ^2 kriterijus

- Tikrina hipotezę:
 H_0 : visi $\beta_m = 0$,
 H_1 : ne visi $\beta_m = 0$.
- Kitais žodžiais:
 H_0 : Y nepriklauso nuo x,
 H_1 : Y priklauso nuo x.
- Tik nežinome, nuo kurių x.

Statistinės išvados atsižvelgiant į p reikšmę

H_0 atmetame (logistinė regresija galbūt tinka), jei

$$p < \alpha$$

H_0 neatmetame (logistinė regresija netinka), jei

$$p \geq \alpha$$

Čia α – reikšmingumo lygmuo.

χ^2 kriterijus

Matome, kad p reikšmė maža ($p < 0,05$).
Taigi negalima iškart atmesti modelio,
kaip netinkamo.

Omnibus Tests of Model Coefficients

	Chi-square	df	Sig.
Step 1 Step	49,566	1	,000
Block	49,566	1	,000
Model	49,566	1	,000

Hosmerio - Lemešou χ^2 kriterijus

Šis kriterijus – alternatyva anksčiau aptartajam χ^2 kriterijui. Hosmerio - Lemešou kriterijus aprašytas knygoje *Statistika ir jos taikymai. II* (p. 190).

Modelis **nelabai tinka** duomenims, kai p reikšmė maža ($p < 0,05$).

Hosmerio - Lemešou χ^2 kriterijus

Matome, kad p reikšmė maža ($p < 0,05$).
Darome išvadą, kad modelio
tinkamumas duomenims nėra labai
geras.

Hosmer and Lemeshow Test

Step	Chi-square	df	Sig.
1	14,952	3	,002

PASTABA

Taikant χ^2 ir Hosmerio - Lemešou kriterijus gautos visiškai priešingos išvados apie modelio tinkamumą. Šiuo atveju, ko gero labiau reikėtų tikėti Hosmerio - Lemešou kriterijumi, nes duomenų nėra daug ir p reikšmė netapo maža vien dėl labai didelės imties.

Taigi modelis nėra labai tinkamas duomenims. Vis dėlto nekeisdami modelio aptarsime ir kitus rodiklius.

Voldo testai koeficientams β_m

- Ieškome nesvarbių x-ų.
- Kiekvienam daugikliui β_m tikrinama:
 $H_0: \beta_m = 0,$
 $H_1: \beta_m \neq 0.$
- Jei nulinės hipotezės neatmetame – tai kintamasis modelyje galbūt nereikalingas. Reikia patikrinti modelį be šio kintamojo.

Statistinės išvados, atsižvelgiant į p reikšmę

H_0 atmetame (kintamasis modeliui tinka),
jei

$$p < \alpha.$$

H_0 neatmetame (kintamasis „įtartinas“, jei

$$p \geq \alpha.$$

Čia α – reikšmingumo lygmuo.

Ką daryti su „įtartinais“ kintamaisiais

- Pakartojame regresijos modelį be tokio kintamojo.
- Tiriame klasifikavimo lentelę.
- Jei klasifikavimo tikslumas praktiškai nepakito – kintamąjį šaliname.

Dažniausiai, modelio konstantos Voldo kriterijaus p reikšmės net nenagrinėjame, nebent mums labai svarbu, ar konstanta nelygi nuliui.

Voldo testai SPSS

Kintamojo *Temp* Voldo kriterijaus p reikšmė maža. Kintamasis modelyje reikalingas.

Kintamasis

Variables in the Equation

	B	S.E.	Wald	df	Sig.	Exp(B)
Step 1 ^a Temp	2,211	,431	26,335	1	,000	9,125
Constant	-61,318	12,022	26,013	1	,000	,000

a. Variable(s) entered on step 1: Temp.

Parametrų įverčiai **SPSS**

$$\hat{\alpha} = -61,32$$

$$\hat{\beta}_1 = 2,21$$

$$\hat{z}(x) = -61,32 + 2,21 \cdot \text{Temp.}$$

Kintamasis

Variables in the Equation

		B	S.E.	Wald	df	Sig.	Exp(B)
Step 1 ^a	Temp	2,211	,431	26,335	1	,000	9,125
	Constant	-61,318	,022	26,013	1	,000	,000

a. Variable(s) entered on step 1: Temp.

Daugiklio įvertis

Prognozavimas

Konkreiems x_m galima apskaičiuoti

$$\hat{z}(x) = \hat{\alpha} + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_k x_k$$

ir rasti $P(Y = 1)$ įvertį.

Prognozavimas

Prognozuojama tik tada, kai regresijos modelis duomenims tinka. Taikoma formulė

$$\hat{P}(Y = 1) = \frac{e^{\hat{z}(x)}}{1 + e^{\hat{z}(x)}}.$$

Prognozavimo pavyzdys

Kai temperatūra yra 27,5 C⁰, tai

$$\hat{z}(x) = -61,32 + 2,21 \cdot 27,5 = -0,545,$$

$$\hat{P}(Y = 1) = \frac{e^{-0,545}}{1 + e^{-0,545}} = 0,367.$$

Prognozavimo pavyzdys

Žinome, kad $Y=1$ atitinka teiginį išsiris vėžliukas. Todėl gautąjį rezultatą interpretuojame taip: esant $27,5\text{ C}^0$ temperatūrai, tikimybės išsiristi vėžliukui įvertis yra $0,367$. Tikimybė išsiristi vėžliukei lygi $1 - 0,367 = 0,633$.

Galimybės įvertis

Apskaičiuojame

$$\frac{\hat{P}(Y = 1)}{1 - \hat{P}(Y = 1)} = \frac{0,367}{0,633} = 0,58.$$

Darome išvada, kad esant 27,5 C⁰ temperatūrai beveik dukart tikėtiniau, kad išsiris vėžliukė nei vėžliukas (tiksliau 100/58 karto tikėtiniau).

Galimybių santykis

Daugiklis $\text{Exp}(2,211) = 9,125$ rodo, kaip keičiasi galimybių santykis, temperatūrai pakilus vienu laipsniu.

Variables in the Equation

	B	S.E.	Wald	df	Sig.	Exp(B)
Step 1 ^a Temp	2,211	,431	26,335	1	,000	9,125
Constant	-61,318	12,022	26,013	1	,000	,000

a. Variable(s) entered on step 1: Temp.

Galimybių santykis

Galimybių santykį **$\text{Exp}(2,211) = 9,125$** interpretuojame taip: temperatūrai padidėjus vienu laipsniu, galimybė išsiristi vėžliukui padidėja 9,125 karto.

Pastaba. Galimybė – nėra tikimybė, vieneta viršyti gali.

Galimybių santykio taikymas

Apskaičiuojame, kaip pasikeis galimybė temperatūrai nuo $27,5\text{ C}^0$ pakilus iki $28,5\text{ C}^0$:

$$0,58 \cdot 9,125 = 5,29.$$

Darome išvadą, kad esant $28,5\text{ C}^0$ **penkis kartus labiau tikėtina**, kad išsiris vėžliukas, o ne vėžliukė.

Determinacijos koeficientai

- Jų yra net keli. Dažniausiai naudojami Kokso - Snelo arba Nagelkerkės determinacijos koeficientai.
- Kuo R^2 didesnis (arčiau vieneto), tuo modelis geresnis.
- Mažas R^2 rodo, kad logistinės regresijos modelis duomenims nelabai tinka.
- Nurodant koeficientą, **būtina** parašyti autoriaus vardą, pvz. *Nagelkerkės R^2* .

Determinacijos koeficientai

Nagelkerkės determinacijos koeficientas lygus 0,425. Tai – vidutinis didumas, rodantis neblogą modelio tinkamumą duomenims.

Model Summary

Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	123,101 ^a	,305	,425

a. Estimation terminated at iteration number 6 because parameter estimates changed by less than ,001.

Rodikliai

Išrikiuokime modelio tinkamumą atspindinčius rodiklius pagal svarbą:

- Klasifikavimo lentelė.
- χ^2 kriterijus ir Hosmerio - Lemeshou kriterijus.
- Voldo kriterijus „įtartiniems“ aiškinamiesiems kintamiesiems rasti.
- Determinacijos koeficientai.

PASTABA

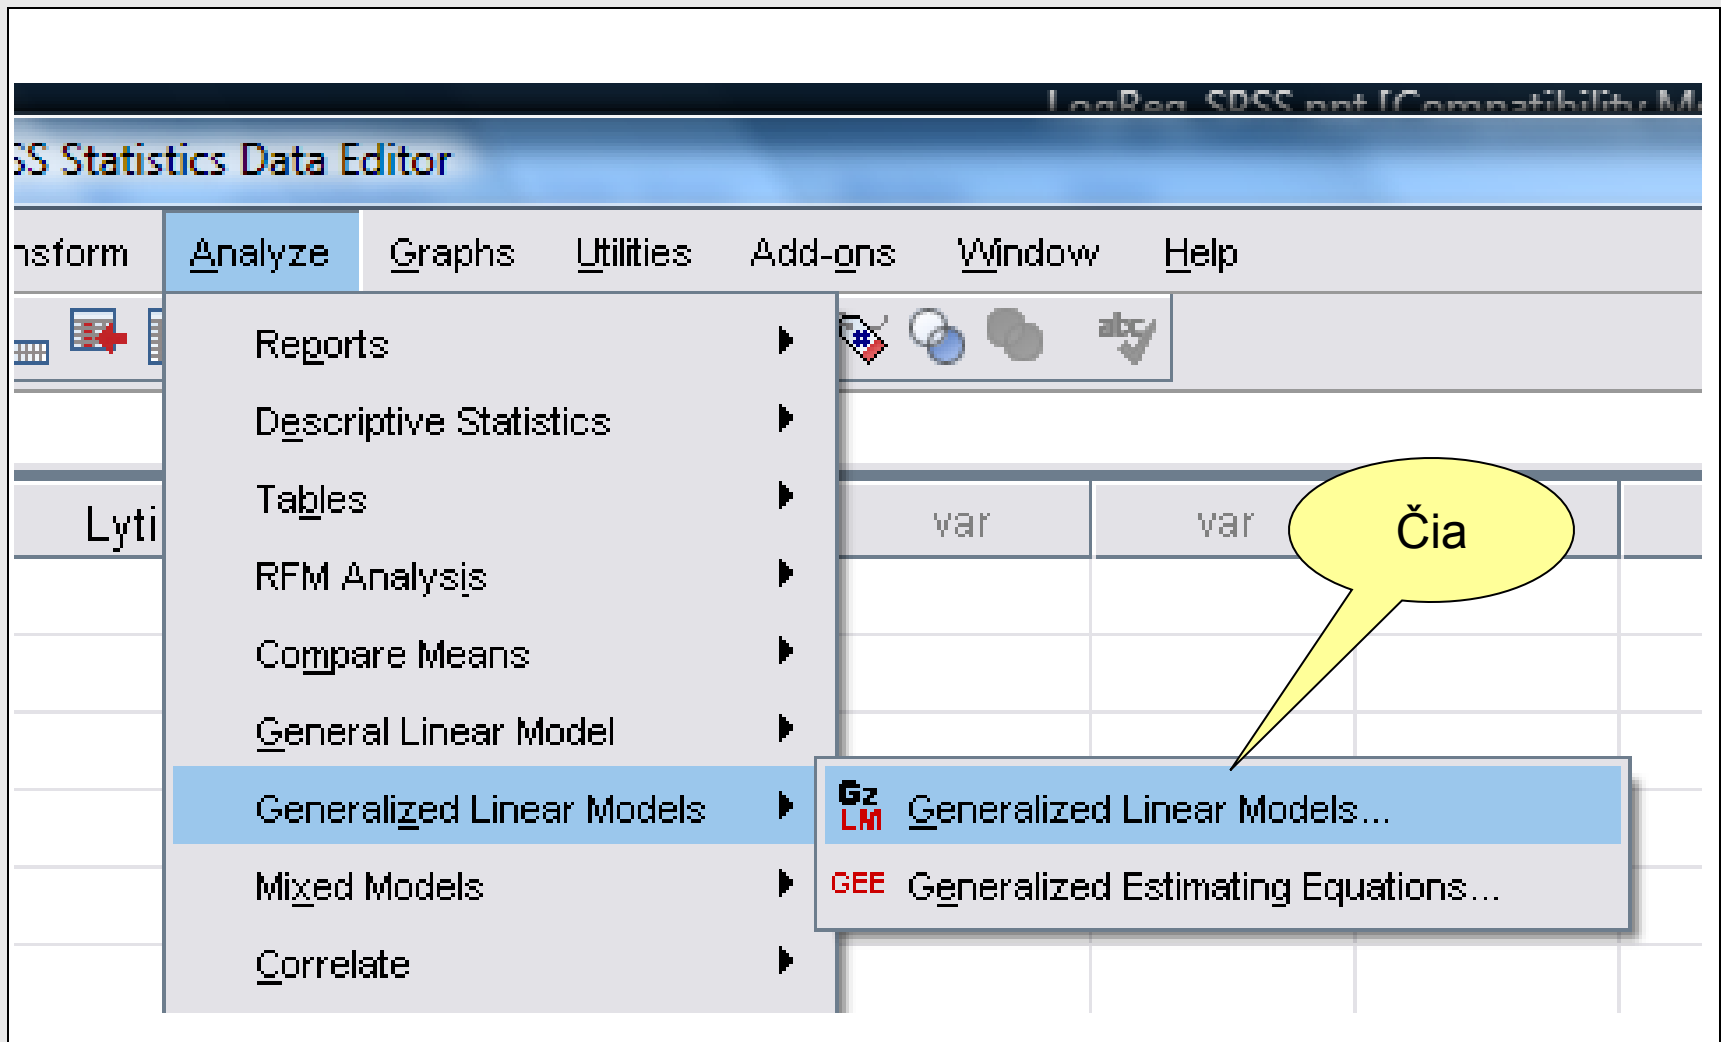
Taikydami parinktą *Binary Logistic* negavome labai svarbaus rodiklio – deviacijos.

Ją galima rasti, nagrinėjant logistinę regresiją, kaip dalinį apibendrintų jų tiesinių modelių atvejį.

***GLM* PROCEDŪRA**

SPSS programa

GLM – *Generalized Linear Model*



Logistinė regresija su *GLM*

Type of Model

Po to čia

Generalized Linear Models

Type of Model | Response | Predictors | Model | Estimation | Statistics | EM Means | Save | Export

Choose one of the model types listed below or specify a custom combination of distribution and link function.

Scale Response

- Linear
- Gamma with log link

Ordinal Response

- Ordinal logistic
- Ordinal probit

Counts

- Poisson loglinear
- Negative binomial with log link

Binary Response or Events/Trials Data

- Binary logistic
- Binary probit

Taškas

Logistinė regresija su *GLM*

Po to čia

Įkeliame priklausomą kintamąjį

The image shows a screenshot of the SPSS 'Linear Models' dialog box. The 'Response' tab is selected. The 'Dependent Variable' field contains 'Lytis'. A yellow callout bubble points to the 'Response' tab with the text 'Po to čia'. Another yellow callout bubble points to the 'Lytis' variable in the 'Dependent Variable' field with the text 'Įkeliame priklausomą kintamąjį'. The dialog box has several tabs: 'Response', 'Predictors', 'Model', 'Estimation', 'Statistics', and 'EM Means'. Below the 'Dependent Variable' field, there is a 'Category order (multinomial only):' section and a 'Type of Dependent Variable (Binomial L' section.

Logistinė regresija su *GLM*

Po to čia

Predictors Model Estimation Statistics EM Means Save Export

Factors:

Options...

Covariates:

Temp

Jeigu būtų kategorinių aiškinamųjų kintamųjų

Intervalinis aiškinamasis kintamasis

The screenshot shows the SPSS 'Logistic Regression: Model' dialog box. The 'Estimation' tab is selected. The 'Factors' list is empty. The 'Covariates' list contains 'Temp'. A yellow speech bubble points to the 'Factors' list with the text 'Jeigu būtų kategorinių aiškinamųjų kintamųjų'. Another yellow speech bubble points to the 'Covariates' list with the text 'Intervalinis aiškinamasis kintamasis'. A third yellow speech bubble points to the 'Estimation' tab with the text 'Po to čia'.

Logistinė regresija su *GLM*

Generalized Linear Models

Po to čia

Type of Model | Response | Predictors | **Model** | Estimation | Statistics

Specify Model Effects

Factors and Covariates:

Temp

Model:

Temp

Build Term(s)

Type:

Main effects ▼

←

Įkeliamo

Logistinė regresija su *GLM*

Print

- Case processing summary
- Descriptive statistics
- Model information
- Goodness of fit statistics
- Model summary statistics
- Parameter estimates
- Include exponential parameter estimates
- Covariance matrix for parameter estimates
- Correlation matrix for parameter estimates
- Contrast coefficient (L) matrices
- General estimable functions
- Lagrange multiplier test of scale parameter or negative binomial ancillary parameter

Pažymėta pagal nutylėjimą

Papildoma varnelė

OK Paste Reset Cancel Help

OK

Logistinė regresija su *GLM*

Reikšmė $Y=1$ atitinka įvykį *išsiriti vėžliukė*. Logistinės regresijos modelis bus sudarytas tikimybei, kad išsiris vėžliukė.

Model Information

Dependent Variable	Lytis ^a
Probability Distribution	Binomial
Link Function	Logit

a. The procedure models *not* as the response, treating vyr as the reference category.

Modelio tinkamumas duomenims

Modelis gerai tinka duomenims, jeigu deviacijos ir laisvės laipsnių santykis mažesnis už vieneta.

Modelis neblogai tinka duomenims, jeigu deviacijos ir laisvės laipsnių santykis nedaug viršija vieneta (pvz., lygus 1,2).

Jeigu santykis daug viršija vieneta, modelis ne itin gerai tinka duomenims.

Modelio tinkamumas duomenims

Modelis ne itin gerai tinka duomenims, nes deviacijos ir laisvės laipsnių santykis daug didesnis už vieneta (lygus 4,954).

Goodness of Fit^b

	Value	df	Value/df
Deviance	14,863	3	4,954
Scaled Deviance	14,863	3	
Pearson Chi-Square	14,952	3	4,984
Scaled Pearson Chi-Square	14,952	3	
Log Likelihood ^a	-61,550		
Akaike's Information Criterion (AIC)	127,101		

PASTABOS

- Modelį reikėtų tobulinti.
- Viena iš galimų didelės deviacijos priežasčių yra labai negausus skirtingų *Temp* reikšmių skaičius. Jų buvo tik penkios.
- Skaičiuojant laisvės laipsnius, įtakos turi skirtingų aiškinamųjų kintamųjų reikšmių skaičius. Įprastinė GLM formulė $(n-K-1)$ netaikoma.
- Toliau aptarsime likusius rezultatus.

χ^2 kriterijus

Matome, kad p reikšmė maža ($p < 0,05$).
Statistikos reikšmė nesiskiria nuo
gautos, naudojant parinktą *Binary
Logistic*.

Omnibus Test^a

Likelihood Ratio Chi- Square	df	Sig.
49,566	1	,000

Dependent variable: Lytis
Model: (Intercept), Temp

a. Compares the fitted model against
the intercept-only model.

Voldo testai SPSS

Kintamojo *Temp* Voldo kriterijaus p reikšmė maža. Kintamasis modelyje reikalingas.

Parameter	B	Std. Error	95% Wald Confidence Interval		Hypothesis Test		
			Lower	Upper	Wald Chi-Square	df	Sig.
(Intercept)	61,318	12,0224	37,755	84,882	26,013	1	,000
Temp (Scale)	-2,211 1 ^a	,4309	-3,055	-1,367	26,335	1	,000

Kintamasis

Parametru įverčiai **SPSS**

$$\hat{\alpha} = 61,32$$

$$\hat{\beta}_1 = -2,21$$

$$\hat{z}(x) = 61,32 - 2,21 \cdot \text{Temp.}$$

Parameter	B	Std. Error	95% Wald Confidence Interval		Hypothesis Test		
			Lower	Upper	Wald Chi-Square	df	Sig.
(Intercept)	61,318	12,0224	37,755	84,882	26,013	1	,000
Temp (Scale)	-2,2111 ^a	,4309	-3,055	-1,367	26,335	1	,000

Pastaba

Naudodami parinktą *Binary Logistic*, gavome priešingus ženklus prie parametrų įverčių. Taip įvyko todėl, kad tada modeliavome *vėžliuko* išsiritimo tikimybę, o dabar modeliuojame *vėžliukės* išsiritimo tikimybę.

Prognozavimas

- Konkrečiai temperatūrai galima apskaičiuoti

$$\hat{z}(x) = 61,32 - 2,21 \cdot \text{Temp.}$$

ir rasti tikimybės, kad išsiris vėžliukė, įvertį

$$\hat{P}(Y = 1) = \frac{e^{\hat{z}(x)}}{1 + e^{\hat{z}(x)}}.$$

Prognozavimo pavyzdys

Kai temperatūra yra $27,5 \text{ C}^0$, tai

$$\hat{z}(x) = 61,32 - 2,21 \cdot 27,5 = 0,545,$$

$$\hat{P}(Y = 1) = \frac{e^{0,545}}{1 + e^{0,545}} = 0,633.$$

Galimybės

Galimybės ir jų santykiai interpretuojami taip, kaip aptarta nagrinėjant parinkties *Binary Logistic* atvejį.

Parameter	B	Std. Error	95% Wald Confidence Interval		Hypothesis Test			Exp(B)
			Lower	Upper	Wald Chi-Square	df	Sig.	
(Intercept)	61,318	12,0224	37,755	84,882	26,013	1	,000	1,000E26
Temp (Scale)	-2,211 1 ^a	,4309	-3,055	-1,367	26,335	1	,000	,110

Kiti rodikliai

Determinacijos koeficientų negauname, tačiau tarp rezultatų yra informaciniai indeksai (Akaikės ir pan.). Juos galima naudoti, kai turime daug aiškinamųjų kintamųjų ir norime dalies jų atsisakyti.

Sudarome naują modelį ir lyginame su ankstesniuoju. Geresnis tas modelis, kurio informaciniai indeksai mažesni.

Metodinės pastabos

Iš pradžių logistinę regresiją reikėtų daryti naudojant parinktį *Binary Logistic*.

Po to dar padaryti ją kaip GLM atskirą atvejį ir patikrinti, ar deviacijos ir jos laisvės laipsnių santykis daug neviršija vieneto.