

Regresní analýza

Organizačně

- Do 13:30
 - Co je to regresní analýza?
 - Kdy se používá?
 - Na jaké otázky může nabídnout odpověď?
 - Základní principy
- Přestávka
- Praktické procvičení

- **KDYŽ NĚČEMU NERPOROZUMÍTE, OZVĚTE SE !!!**

Použití

- TESTOVÁNÍ TEORIÍ !!!
- Zjištění vlivu nezávisle proměnné na závisle proměnnou
 - Při kontrole dalších možných faktorů
 - (predikce: jakou hodnotu bude mít závisle proměnná při určité kombinaci nezávisle proměnných)

Příklady otázek ze závěrečných prací v ISu

- Existuje vztah mezi kvalitou a náročností výuky a mírou stresu u studentů?
 - Studenti vyšších ročníků zažívají menší míru stresu oproti studentům nižších ročníků
 - Kvalita online výuky má kladný vliv na míru stresu
 - nároky vyučujících mají vliv opačný
- Jak závisí stupeň glomerulární filtrace na biochemických, demografických a antropometrických údajích pacientů?
 - Mezi nezávislé faktory asociované s nižší glomerulární filtrací patří vyšší hladina sérového kreatininu, vyšší věk, ženské pohlaví, jiný než Afroamerický etnický původ, vyšší koncentrace sérové urey a nižší koncentrace sérového albuminu
- Jak závisí rychlost plavání na stylu?

Příklady otázek ze závěrečných politologických prací v ISu

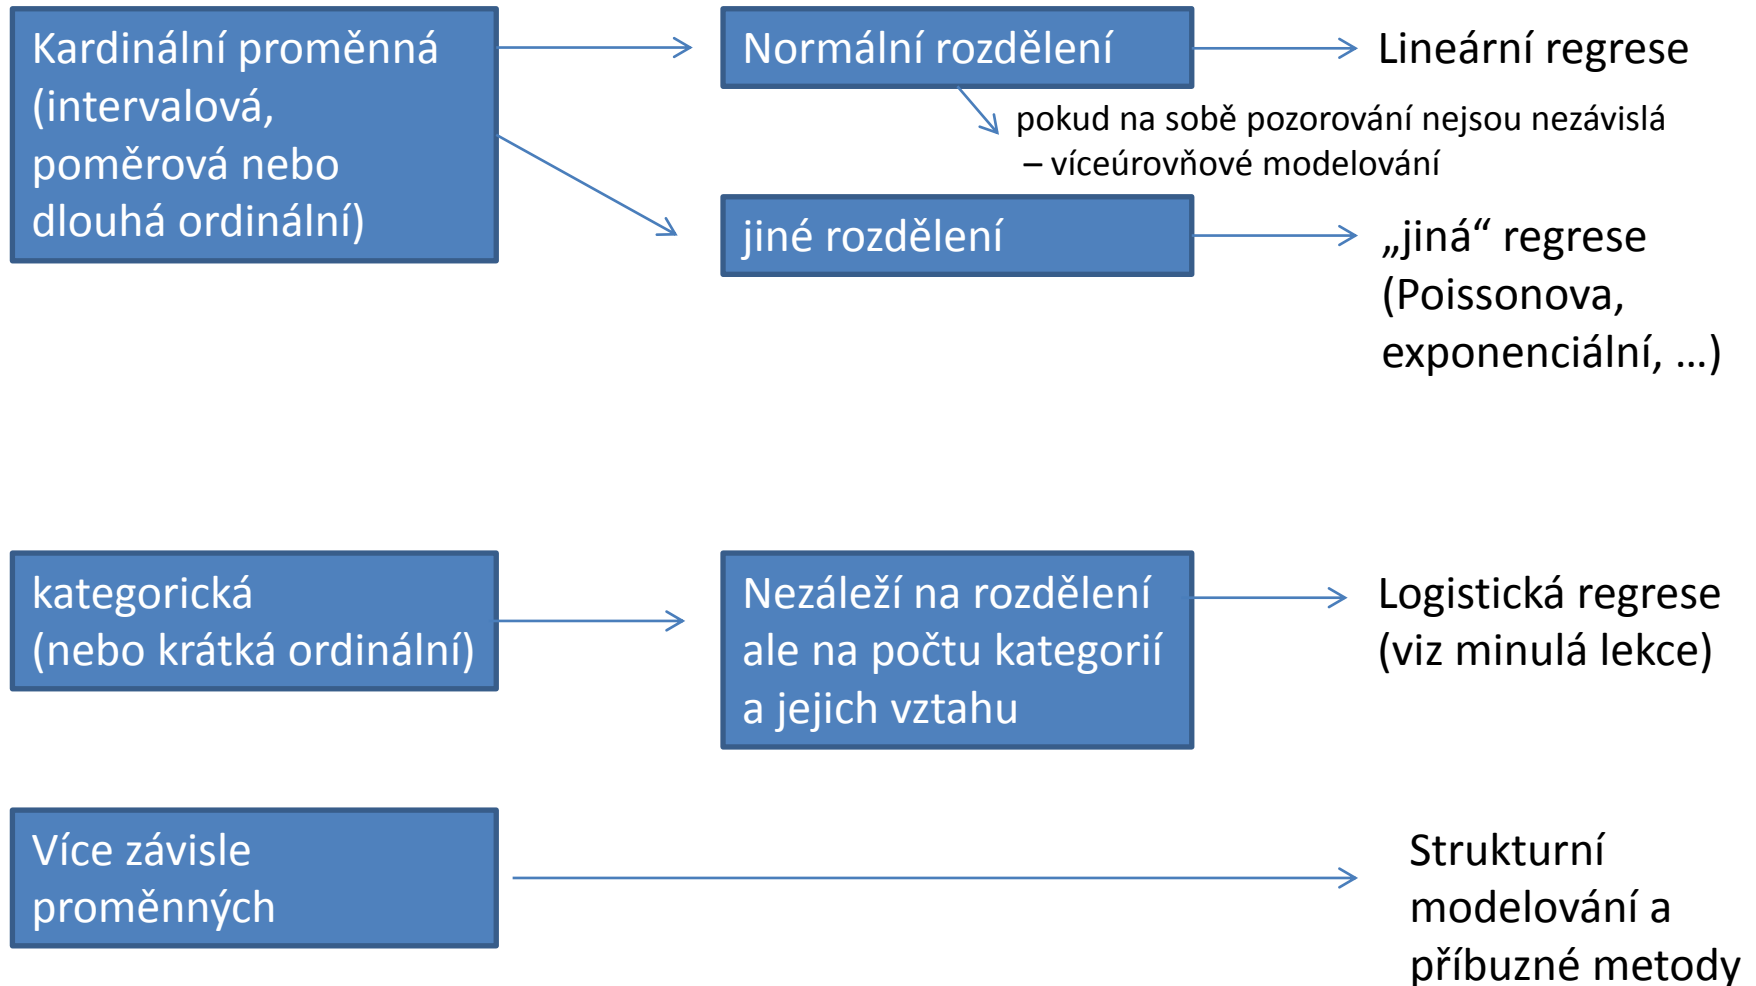
- Desítky volebně-geografických prací
- Co ovlivňuje jednotu českých poslaneckých klubů?
 - H1a: Jednotnost hlasování je vyšší u vládních stran.
 - H1b: Jednotnost hlasování vládní strany je vyšší, čím těsnější je většina, kterou disponuje.
- Je míra korupce ovlivněna i používaným volebním systémem?
 - 1) Korupce roste s rostoucími volebními obvody v systémech s otevřenými kandidátkami.
 - 2) Korupce klesá s rostoucími volebními obvody v systémech s uzavřenými kandidátkami.
- Co ovlivňuje (ne)účast poslanců na hlasování v Poslanecké sněmovně PČR?
 - účast na hlasování se bude zvyšovat s rostoucí pravděpodobností, že daný poslanec, či poslankyně bude pivotálním ... hlasem ...
 - poslanci ze vzdálenějších obvodů budou mít vyšší míru absencí při hlasováních ve Sněmovně než poslanci, kteří jsou přímo z Prahy, nebo blízkého okolí

Podmínky

- Jedna závisle proměnná
 - + Jedna nebo více nezávisle proměnných
- Normálně rozdělená závisle proměnná
 - Rozdělení a typ nezávisle proměnné může být jakékoli
 - Ve skutečnosti se podmínka týká rozdělení reziduí
 - To ale před provedením analýzy neznáme
- Několik dalších různě důležitých podmínek
 - Nezávislost pozorování
 - Předpoklad lineárního vztahu

 - Nezávislost nezávisle proměnných mezi sebou
 - Homogenní rozptyl reziduí

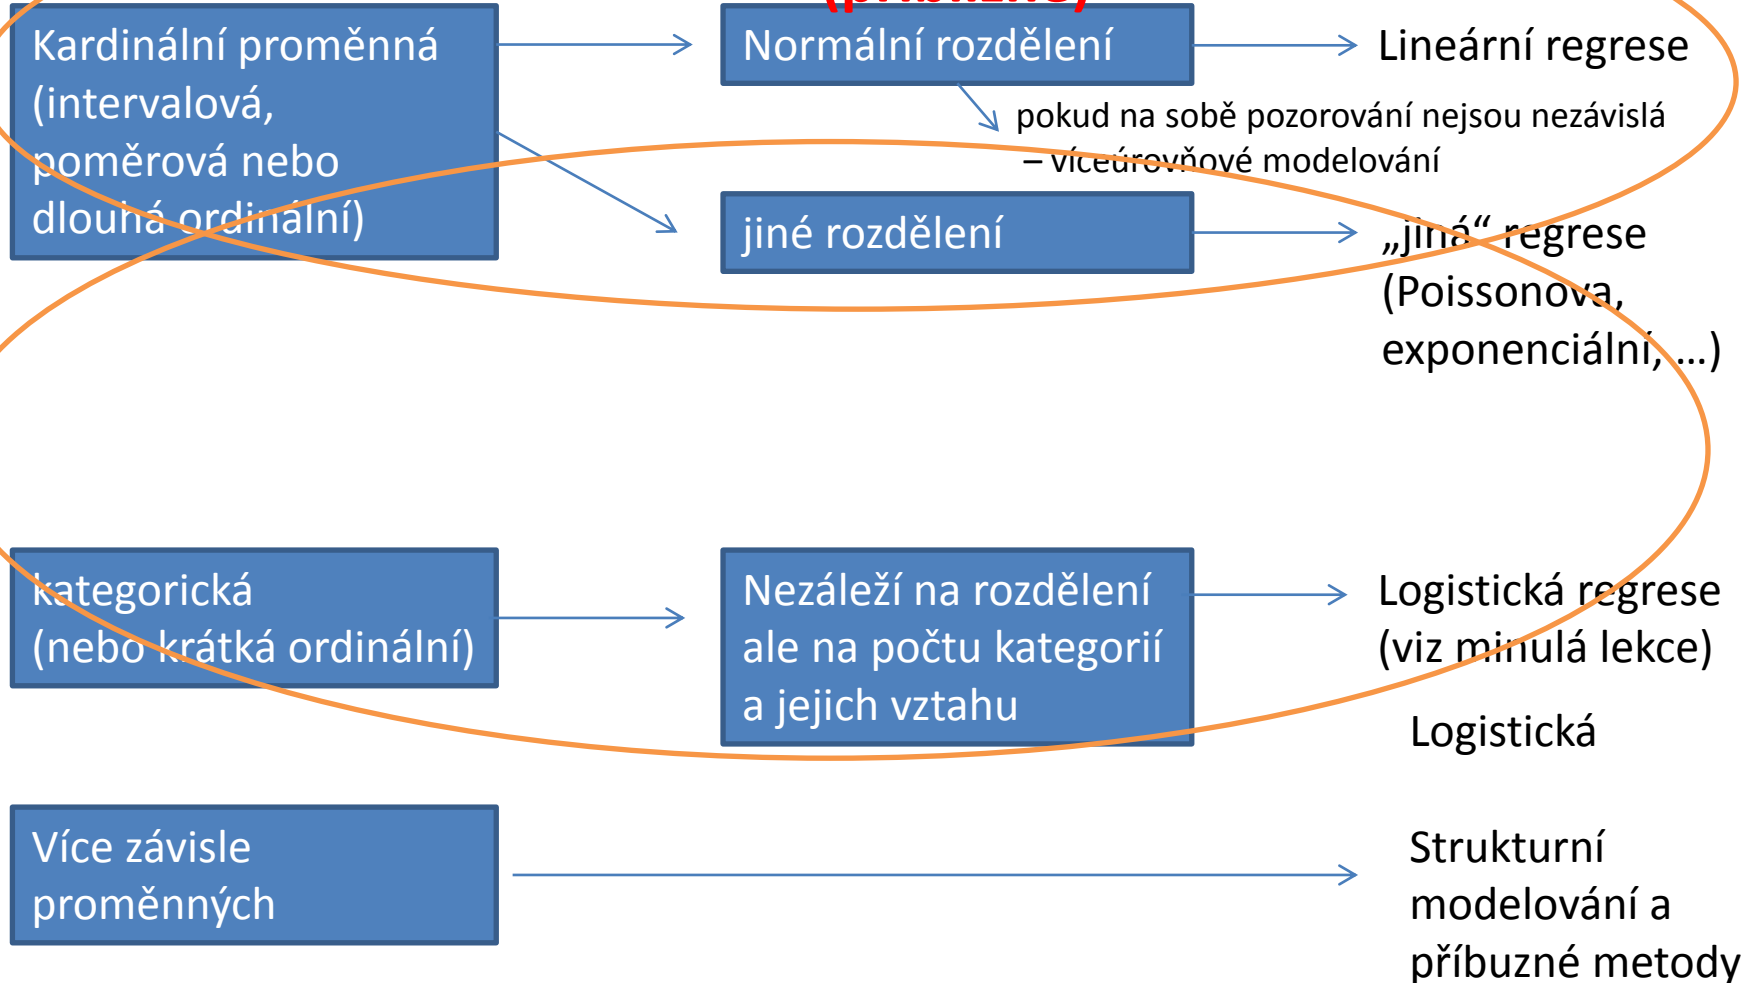
Rozhodovací strom



Rozhodovací strom

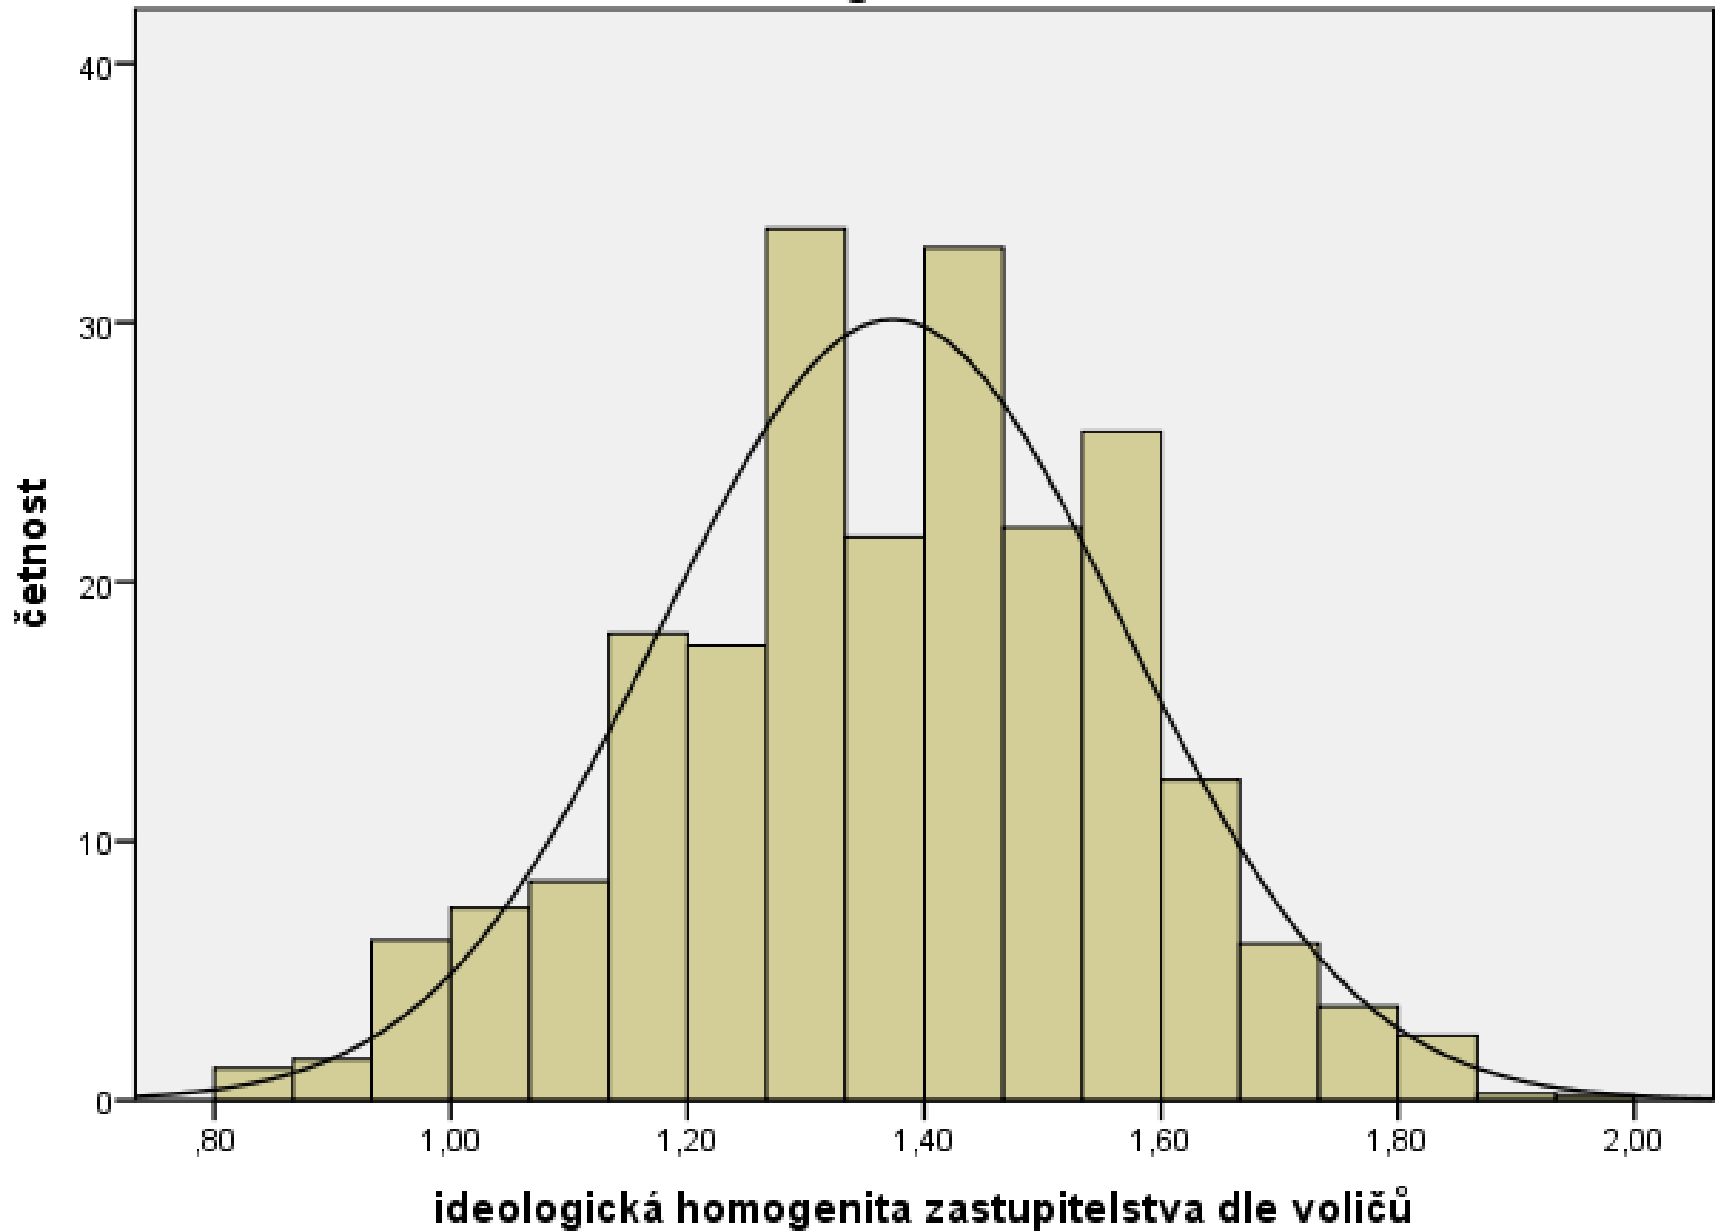
Lineární

(přibližně)




	Stata	SAS	SPSS	Mplus	R
Regression Models					
Robust Regression	Stata	SAS			R
Models for Binary and Categorical Outcomes					
Logistic Regression	Stata	SAS	SPSS	Mplus	R
Exact Logistic Regression	Stata	SAS			R
Multinomial Logistic Regression	Stata	SAS	SPSS	Mplus	R
Ordinal Logistic Regression	Stata	SAS	SPSS	Mplus	R
Probit Regression	Stata	SAS	SPSS	Mplus	R
Count Models					
Poisson Regression	Stata	SAS	SPSS	Mplus	R
Negative Binomial Regression	Stata	SAS	SPSS	Mplus	R
Zero-inflated Poisson Regression	Stata	SAS		Mplus	R
Zero-inflated Negative Binomial Regression	Stata	SAS		Mplus	R
Zero-truncated Poisson	Stata	SAS			R
Zero-truncated Negative Binomial	Stata	SAS		Mplus	R
Censored and Truncated Regression					
Tobit Regression	Stata	SAS		Mplus	R
Truncated Regression	Stata	SAS			R
Interval Regression	Stata	SAS			R
Multivariate Analysis					
One-way MANOVA	Stata	SAS	SPSS		
Discriminant Function Analysis	Stata	SAS	SPSS		
Canonical Correlation Analysis	Stata	SAS	SPSS		R
Multivariate Multiple Regression	Stata	SAS		Mplus	
Mixed Effects Models					
Generalized Linear Mixed Models	Introduction to GLMMs				
Mixed Effects Logistic Regression	Stata				R
Other					
Latent Class Analysis				Mplus	

Histogram 1




Cases weighted by vaha

Histogram 2



Cases weighted by vaha


zájem o politiku: EU




zájem o politiku: EU

Cases weighted by vaha

PO.45a Zájem o politiku



PV.1a Pravděpodobnost účasti ve volbách do PS



Co regrese dělá


- **Odhad parametrů** přímky (při 1 nezávisle proměnné), roviny (při 2) či nadroviny (při více)
- Parametry: **sklon** (pro každou proměnnou) a ***konstanta*** (jedna pro celý model)
- Parametry popisují vztah mezi nezávisle a závisle proměnnou
- Hodnota závisle proměnné (y) = konstanta (a) + sklon(b)*hodnota nezávisle proměnné (x)
- $y = a + b * x$
- $y = a + b_1 * x + b_2 * x + b_3 * x + \dots$


Co nám výpočet poskytne?

- R-square (česky index determinace)
 - Ukazuje jak dobře model sedí na data
- Parametry
 - Unstandardized beta (nestandardizovaný beta koeficient)
 - Constant (konstanta)
- Hodnoty signifikance

Co je to R-square?

- Ukazuje, kolik procent rozptylu závisle proměnné je vysvětleno přidáním nezávisle proměnných
- Původní rozptyl je vypočten jako suma kvadratických odchylek mezi průměrem a jednotlivými hodnotami závisle proměnné
- „nový“ rozptyl je vypočten jako suma odchylek od regresní přímky/roviny
- Rozdíl mezi původním a novým rozptylem vydělený původní variabilitou = R-square
- Čím víc proměnných, tím nižší R-square
 - Řešeno pomocí adjusted R-square





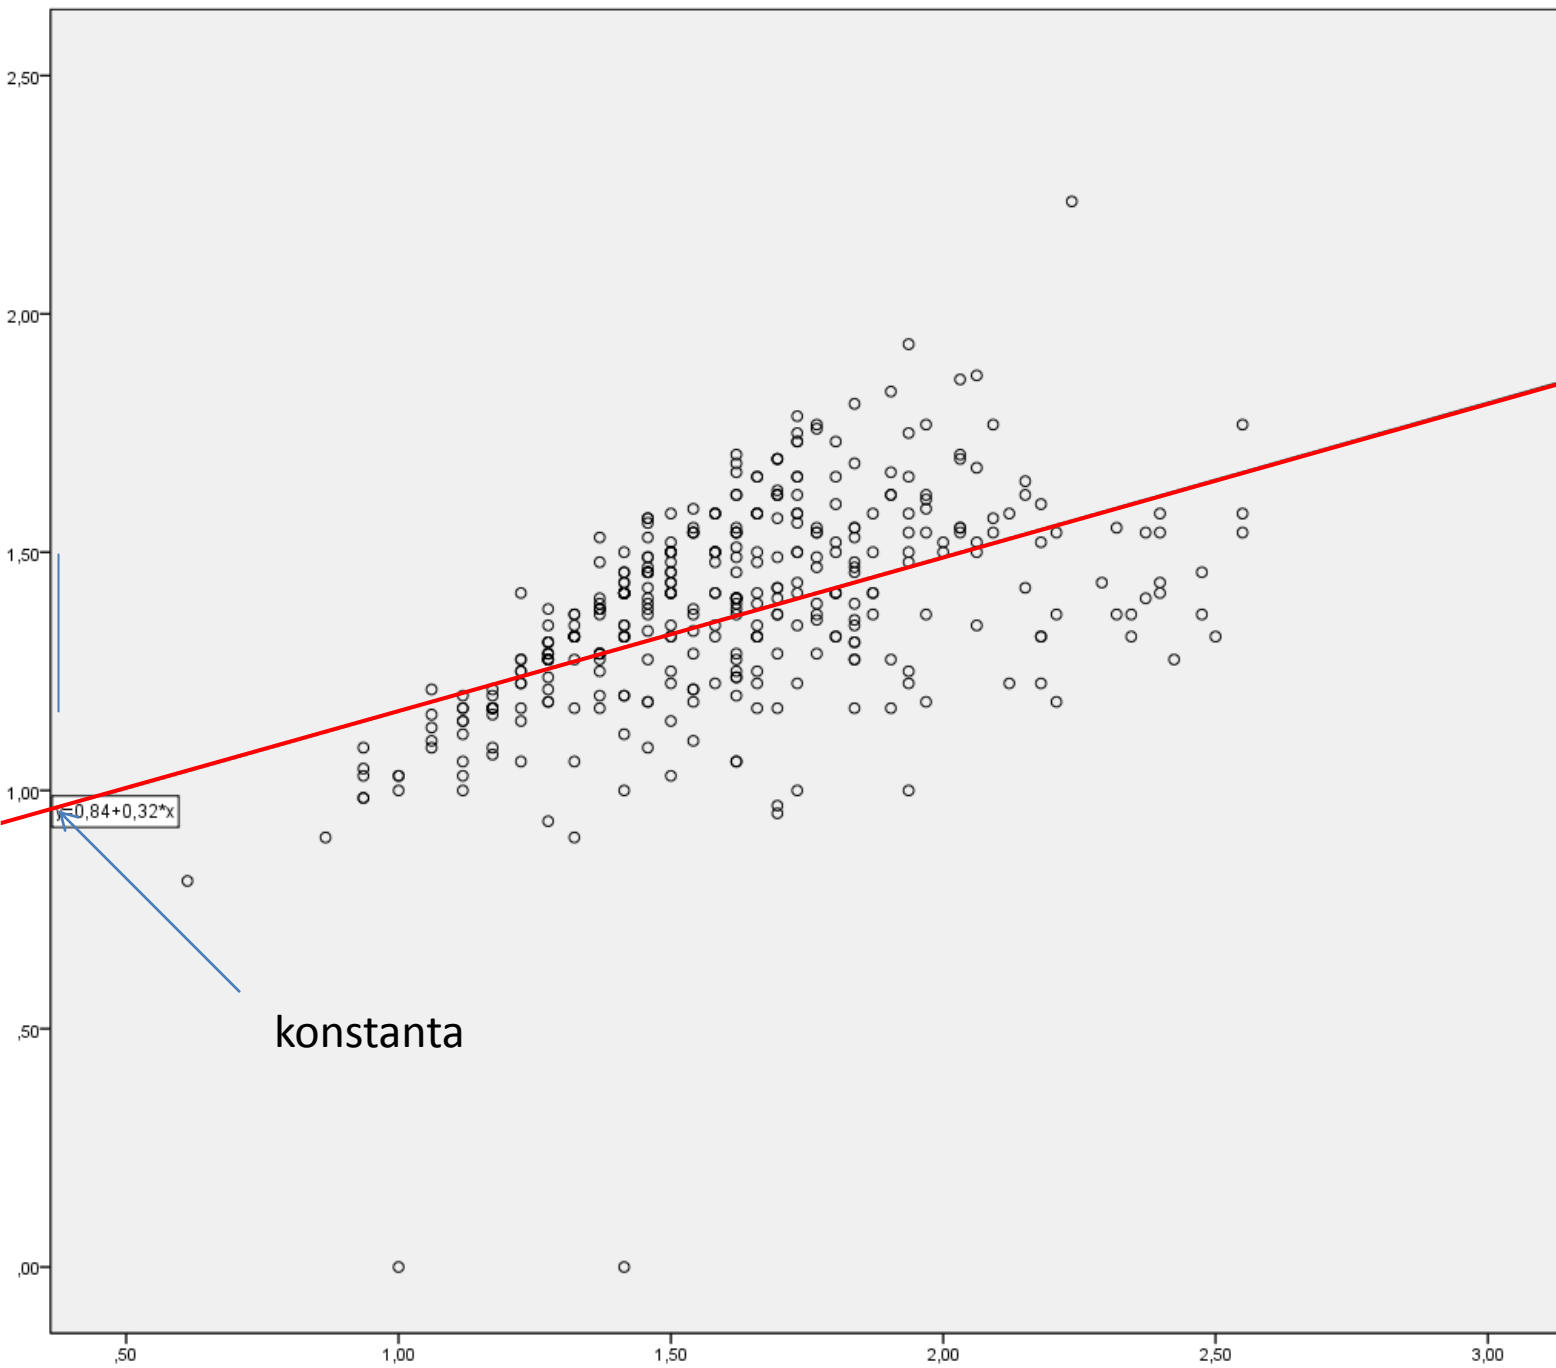
Průměr závisle
proměnné

$y = 0,84 + 0,32 * x$

Konstanta

- Jaká je očekávaná hodnota nezávisle proměnné, pokud jsou hodnoty všech nezávisle proměnných 0
- Pro smysluplnou interpretaci je často potřeba rekódovat proměnné
 - Každý má nějaký věk, pohlaví, výšku, váhu, ...
 - Pro testování hypotéz není konstanta důležitá
 - Důležitá pro tvorbu grafů (není předmětem tohoto kurzu)

Y



konstanta


X

Nestandardizovaný Beta koeficient

- efekt nezávisle proměnné na závisle proměnnou
- **„o kolik se změní hodnota závisle proměnné, pokud se hodnota nezávisle proměnné změní o jednotku“** pokud vše ostatní zůstává shodné
- Různé proměnné se mohou změnit o různý počet jednotek
 - Pro srovnání síly proměnných v modelu – standardizovaný koeficient beta (jakou změnu v počtu směrodatných odchylek závisle proměnné způsobí změna o směrodatnou odchylku nezávisle proměnné)


Y

2,50
2,00
1,50
1,00
,50
,00



$y = 0,84 + 0,32 * x$

X



Příklad

- Téma: Názory na zasahování státu do ekonomiky
- Popis problému:
 - Občané mají různé názory na to, zda a jak by měl stát zasahovat do hospodářství
- Otázka: Co způsobuje rozdílné názory na zásahy státu do ekonomiky mezi občany?

Postup

- Nadefinování modelu pomocí hypotéz vycházejících z teorie
- Sestavení datasetu obsahujícího závisle a nezávisle proměnné dle specifikace
- Zkontrolování rozdělení závisle proměnné
- Zkontrolování vlastností nezávisle proměnných

Teorie

- Politické hodnoty
- Hodnoty jsou preferovanými stavy věcí (svoboda x sociální spravedlnost)
- Hodnoty se utváří v průběhu socializace – role věku
- Hodnoty jsou ovlivněny aktuální situací jedince (adaptace) - role příjmu
- Role vzdělání a třídy

Hypotézy

- H1: starší voliči budou preferovat vyšší míru zasahování státu do ekonomiky
- H2: s rostoucím příjmem poroste preference vyšší ekonomické svobody.
- H3: s vyšším vzděláním poroste preference vyšší ekonomické svobody
- H3X: s vyšším vzděláním poroste preference vyšší míry zasahování státu do ekonomiky
- H4: lidé se zkušeností s nezaměstnaností budou více preferovat zásahy do ekonomiky než lidé bez takové zkušenosti

- H0 proměnná nemá vliv

Proměnné

- Závisle proměnná: Míra zasahování státu do ekonomiky
 - Vytvořeno jako faktorové skóre na základě proměnných
 - Hodnoty 0 – 10 (0 – zasahování, 10 – svoboda)
 - Ke kterému z každé dvojice následujících výroků byste se spíše přiklonil?
 - Rozvoj hospodářství má být ponechán vlastnímu vývoji/má být usměrňován státem
 - Stát má zaručit, aby ten, kdo chce pracovat, dostal práci/
Kdo chce pracovat, musí se o získání práce postarat sám
 - Velkým hospodářským podnikům má stát umožnit co největší samostatnost/
Na velké hospodářské podniky má stát co nejvíce dohlížet
 - Velikost soukromého vlastnictví by nijak být omezována neměla/by nějakým způsobem být omezována měla.

Nezávisle proměnné



- Nezávisle / kontrolní proměnné
- Příjem: čistý příjem domácnosti
- Subjektivní hodnocení příjmu (dichotomická proměnná)
- Věk
- Nespokojenost s vnějšími podmínkami: součet proměnných ptajících se na hodnocení ekonomické a politické situace (od 0 do 10)
- Vzdělání: kategorická proměnná rekódovaná na dummy proměnné
 - ZŠ vzdělání referenční kategorií
- Nezaměstnanost: kategorická proměnná rekódovaná na dummy proměnné
 - Bez zkušenosti s nezaměstnaností jako referenční kategorie
- Zájem o politiku: 0-10

Normalita závisle proměnné

- Jinakost rozdělení
 - ovlivňuje především hodnoty signifikance
 - Zkresluje odhady parametrů
- Prvně vizuální zhodnocení pomocí histogramu
- Testy nejsou úplně nezbytné, ale jejich provedením nic nezkazíte
 - K-S a S-W
 - Ve velkých souborech lze brát s rezervou
 - **Šikmost a strmost není větší než 3x SE**

Test normality závisle proměnné

- Histogram
 - Analyze- descriptive stat- frequencies – plots
- Kolmogorův-Smirnovův test
 - Analyze – descriptive stat – explore – plots – normality plots with tests




Tests of Normality

	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
hodnoty: ekonomická levice pravece	,021	959	,200 [*]	,998	959	,155

*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

Normal Q-Q Plot of hodnoty: ekonomická levice pravice



Odebrání outlierů

- Outliery je možné z analýzy vynechat
- Jde o přípustnou manipulaci s daty
- Nutné reportovat!!!
- Vhodné také ukázat rozdíl ve výsledcích analýzy před a po odstranění outlierů

- Teď to ale dělat nebudeme

Další postup

- Rekódování nezávisle proměnných
- Kontrola multikolinearity nezávisle proměnných
 - Nezávisle proměnné by mezi sebou neměly příliš souviset
 - První kontrola pomocí korelačního koeficientu
 - Další kontrola přímo v modelu
- Výpočet

Průzkum souvislosti mezi proměnnými

- Crostab
- Korelace

Kontrola multikolinearity

- Analyze – correlate - bivariate

Correlations

		IDE.2 Věk	prijem	nespokojeno st s vnějšími podmínkami	IDE.10a Osobní čistý měsíční příjem
IDE.2 Věk	Pearson Correlation	1	-,330**	,155**	,163**
	Sig. (2-tailed)		,000	,000	,000
	N	1043	651	989	764
prijem	Pearson Correlation	-,330**	1	-,259**	,545**
	Sig. (2-tailed)	,000		,000	,000
	N	651	652	634	639
nespokojenost s vnějšími podmínkami	Pearson Correlation	,155**	-,259**	1	-,103**
	Sig. (2-tailed)	,000	,000		,006
	N	989	634	991	718
IDE.10a Osobní čistý měsíční příjem	Pearson Correlation	,163**	,545**	-,103**	1
	Sig. (2-tailed)	,000	,000	,006	
	N	764	639	718	765

** . Correlation is significant at the 0.01 level (2-tailed).

Naklikání modelu

- Analyze – regression – linear
- Dependent: lp_ekonom
- Independent: vek, nespokojenost, prijem, chudi_subj, učeň, sš, vš, zkus_nezam, zajem, muž, mesto
- Statistics: colinearity diagnostics, casewise diagnostics >2,5
- Plots: Y:*ZRESID, X:*ZPRED

OK

Interpretace R^2 a adj. R^2

Model Summary^b

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,306 ^a	,094	,077	1,69542	1,605

a. Predictors: (Constant), příjem, vek, ...

b. Dependent Variable: hodnoty: ekonomická levice pralice

- Model vysvětluje 9,4 % variability závisle proměnné

ANOVA^a

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	172,310	11	15,665	5,450	,000 ^b
	Residual	1664,315	579	2,874		
	Total	1836,625	590			

a. Dependent Variable: hodnoty: ekonomická levice pralice

b. Predictors: (Constant), příjem, vek, ...

- Model je statisticky významný (tj. můžeme jeho výstupy zobecnit na populaci)

Interpretace R^2 a adj. R^2

- **neukazuje**, nakolik jsou výsledky platné v celém souboru,
- **neukazuje**, pro jaké procento voličů vztah platí
- ukazuje jak moc model vysvětluje rozptyl v závisle proměnné.
- Jak dobře model popisuje realitu (zaznamenanou v datech)
- Když je model nesignifikantní (tj. žádná z proměnných nepřispívá k vysvětlení rozptylu), tak použité nezávisle proměnné nemají efekt na závisle proměnnou,
 - nikoli, že k analýze proměnné není regrese použitelná
 - To závisí na naplnění předpokladů
 - Dobrý výsledek (vyvrací teorii)

Interpretace konstanty

- **Pro testování teorií nepodstatné**
- Nesmyslná, protože nikdo ve vzorku nemá věk 0
- Proto proměnnou věk rekódujeme
 - Odečteme 15
- V novém modelu je konstantu možné interpretovat:
- hodnota závisle proměnné očekávaná pro nejmladší občanky, spokojené s podmínkami, bez příjmu, ale subjektivně bohaté, se zš vzděláním, bez zájmu o politiku, a zkušenosti s nezaměstnaností žijící ve vsi (= 5,1)

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	C
		B	Std. Error	Beta			
1	(Constant)	5,135	,426		12,064	,000	
	vek	-,018	,005	-,180	-4,057	,000	
	nespokojenost s vnějšími podmínkami	-,029	,044	-,028	-,651	,515	
	příjem	,010	,005	,090	1,932	,054	
	subjektivně chudá domácnost	-,367	,174	-,094	-2,102	,036	
	učňovské vzdělání nebo sš bez maturity	,086	,210	,024	,412	,681	
	sš s maturitou	,181	,223	,048	,815	,415	
	vysokoškolské vzdělání	,272	,264	,055	1,030	,303	
	zkušenost s nezaměstnaností	-,273	,186	-,062	-1,470	,142	
	zajímá se o politiku	-,053	,149	-,015	-,353	,724	
	muž	,111	,145	,031	,768	,443	
	obec nad 5000 obyvatel	,069	,151	,018	,458	,647	

a. Dependent Variable: hodnoty: ekonomická levice pravice

Interpretace nestandardizovaného beta koeficientu

- 2 situace
- Dummy proměnné x kardinální proměnné
- Interpretace efektu dummy proměnné:
 - nestandardizovaný koeficient ukazuje rozdíl dané kategorie oproti referenční kategorii
- Interpretace efektu kardinální proměnné
 - Při změně nezávisle proměnné o jednotku se hodnota závisle proměnné změní o hodnotu nestandardizovaného koeficient

Interpretace efektu dummy proměnné

Coefficients^a

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Tolerance
	B	Std. Error	Beta			
1	(Constant)	5,135	,426			
	vek	-,018	,005	-,180	-,4057	,000
	nespokojenost s vnějšími podmínkami	-,029	,044	-,028	-,651	,515
	příjem	,010	,005	,090	1,932	,054
	subjektivně chudá domácnost	-,367	,174	-,094	-2,102	,036
	učňovské vdělání nebo sš bez maturity	,086	,210	,024	,412	,681
	sš s maturitou	,181	,223	,048	,815	,415
	vysokoškolské vzdělání	,272	,264	,055	1,030	,303
	zkušenost s nezaměstnaností	-,273	,186	-,062	-1,470	,142
	zajímá se o politiku	-,053	,149	-,015	-,353	,724
	muž	,111	,145	,031	,768	,443
	obec nad 5000 obyvatel	,069	,151	,018	,458	,647

a. Dependent Variable: hodnoty: ekonomická levice pravice

Interpretace efektu dummy proměnné

- Subjektivně chudý občan preferuje zásahy do ekonomiky více než subjektivně bohatý občan volič (pokud jsou ostatní sledované charakteristiky stejné) a to o 0,36 bodu
- Nebo též
- Pokud je vše ostatní shodné, pak rozdíl na škále ekonomických hodnot mezi subjektivně bohatým a chudým občanem je 0,36 bodu. Chudý občan více preferuje zásahy do ekonomiky.

- **Kategorie K se liší o $\pm XX$ od referenční kategorie** (pokud je vše ostatní shodné)
- Interpretace musí obsahovat:
 - Identifikaci kategorie proměnné, ke které je koeficient vztažen
 - Identifikaci referenční kategorie
 - Informaci o velikosti rozdílu

Interpretace efektu kardinální proměnné

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Co Tot
		B	Std. Error	Beta			
1	(Constant)	5,135	,426		12,064	,000	
	vek	-,018	,005	-,180	-4,057	,000	
	nespokojenost s vnějšími podmínkami	-,029	,044	-,028	-,651	,515	
	příjem	,010	,005	,090	1,932	,054	
	subjektivně chudá domácnost	-,367	,174	-,094	-2,102	,036	
	učňovské vzdělání nebo sš bez maturity	,086	,210	,024	,412	,681	
	sš s maturitou	,181	,223	,048	,815	,415	
	vysokoškolské vzdělání	,272	,264	,055	1,030	,303	
	zkušenost s nezaměstnaností	-,273	,186	-,062	-1,470	,142	
	zajímá se o politiku	-,053	,149	-,015	-,353	,724	
	muž	,111	,145	,031	,768	,443	
	obec nad 5000 obyvatel	,069	,151	,018	,458	,647	

a. Dependent Variable: hodnoty: ekonomická levice pravice

Interpretace efektu kardinální proměnné

- Pokud má občan A o 1 000 Kč vyšší příjem než volič B a vše ostatní je shodné, pak volič A preferuje o 0,01 bodu ekonomickou svobodu
- Nebo též
- S růstem příjmu o 1000 Kč (pokud vše ostatní zůstává shodné) preference ekonomické svobody vzroste o 0,01 bodu
- Lze násobit
 - Pokud příjem vzroste o 10 000 Kč , pak preference ekonomické svobody vzroste o 0,1 bodu
 - Pokud příjem vzroste o 100 000 Kč , pak preference ekonomické svobody vzroste o 1 bod

Coefficients^a

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.
	B	Std. Error	Beta		
1	(Constant)	5,135	,426		
	vek	-,018	,005	-,180	-4,057
	nespokojenost s vnějšími podmínkami	-,029	,044	-,028	-,651
	příjem	,010	,005	,090	1,932
	subjektivně chudá domácnost	-,367	,174	-,094	-2,102
	učňovské vzdělání nebo sš bez maturity	,086	,210	,024	,412
	sš s maturitou	,181	,223	,048	,815
	vysokoškolské vzdělání	,272	,264	,055	1,030
	zkušenost s nezaměstnaností	-,273	,186	-,062	-1,470
	zajímá se o politiku	-,053	,149	-,015	-,353
	muž	,111	,145	,031	,768
	obec nad 5000 obyvatel	,069	,151	,018	,458

a. Dependent Variable: hodnoty: ekonomická levice pravice

Hodnocení signifikance

- Zobecňování výsledků na populaci
- Obvyklá hranice sig. $< 0,05$
- Potom považujeme efekt za signifikantní na hladině významnosti 95 %
- Nic nám nebrání zvolit si jinou hladinu významnosti (např. 90%, 99% nebo 99,99%)
- S nižší hladinou roste riziko, že budeme za platný považovat i efekt který v populaci neplatí
- S vyšší hladinou vyšší riziko že budeme za neplatný považovat i efekt, který v populaci platí

Následná kontrola

- Outlieři
- Homogenita rozptylu reziduí (homoskedascita)
- multikolinearita

Honocení multikolinearity

- VIF
- Arbitární hranice: 5
- A zároveň podobné hodnoty v dimenzích

- Proměnné levice a pravice
 - V pořádku, neboť se jedná o dummy proměnné vytvořené z jedné kategorické proměnné

Coefficients^a

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	5,135	,426		12,064	,000		
	vek	-,018	,005	-,180	-4,057	,000	,793	1,262
	nespokojenost s vnějšími podmínkami	-,029	,044	-,028	-,651	,515	,859	1,161
	příjem	,010	,005	,090	1,932	,054	,723	
	subjektivně chudá domácnost	-,367	,174	-,094	-2,102	,036	,790	
	učňovské vzdělání nebo sš bez maturity	,086	,210	,024	,412	,681	,471	
	sš s maturitou	,181	,223	,048	,815	,415	,457	
	vysokoškolské vzdělání	,272	,264	,055	1,030	,303	,555	
	zkušenost s nezaměstnaností	-,273	,186	-,062	-1,470	,142	,890	
	zajímá se o politiku	-,053	,149	-,015	-,353	,724	,879	1,138
	muž	,111	,145	,031	,768	,443	,931	1,074
	obec nad 5000 obyvatel	,069	,151	,018	,458	,647	,960	1,042

a. Dependent Variable: hodnoty: ekonomická levice pravice

Outlieři


- Např. pro případ č. 70 očekáváme, že nebude mít vyhraněný názor, ale přitom reálně jde o velmi levicového občana
- Podobně případ 105, ten je ale pravicový
- Můžeme vyřadit a zjistit, co to udělá s výsledky

Casewise Diagnostics^a

Case Number	Std. Residual	hodnoty: ekonomická levice pravice	Predicted Value	Residual
70	-2,177	,39	4,0863	-3,69304
105	2,283	9,23	5,3563	3,87237
127	-2,420	1,34	5,4433	-4,10519
156	2,015	60	3,0146	3,41904

Homoskedascita

- V reziduích by neměl být žádný zřetelný vzorec



heteroskedascita

- Příklad situace kdy homoskedascita není v pořádku

