LEKCE11
ZÁKLADY LINEÁRNÍ REGRESE - VZTAH SPOJITÝCH PROMĚNNÝCH

Velmi často nás zajímá jaký je VZTAH SPOJITÉ VELIČINY k ostatním veličinám, neboli to, co se ve statistice nazývá REGRESE.

Cílem REGRESE je vyjádřit VZTAH SPOJITÉ VELIČINY k ostatním veličinám prostřednictvím:

- REGRESNÍ ROVNICE (nějaké funkce), která by umožnila predikovat hodnotu určité proměnné na základě znalosti hodnoty jiné proměnné.
- REGRESNÍ ČÁRY, která je grafickým vyjádřením regresního vztahu (regresní rovnice) ve formě:
  - Regresní KŘIVKY (jako vyjádření nelineárního vztahu).
  - Regresní PŘÍMKY (jako vyjádření lineárního vztahu - lineární regrese).

GRAPHS ⇨ SCATTERPLOT ⇨ SIMPLE

pro osu x „Average female life expectancy“
pro osu x „Females who read“

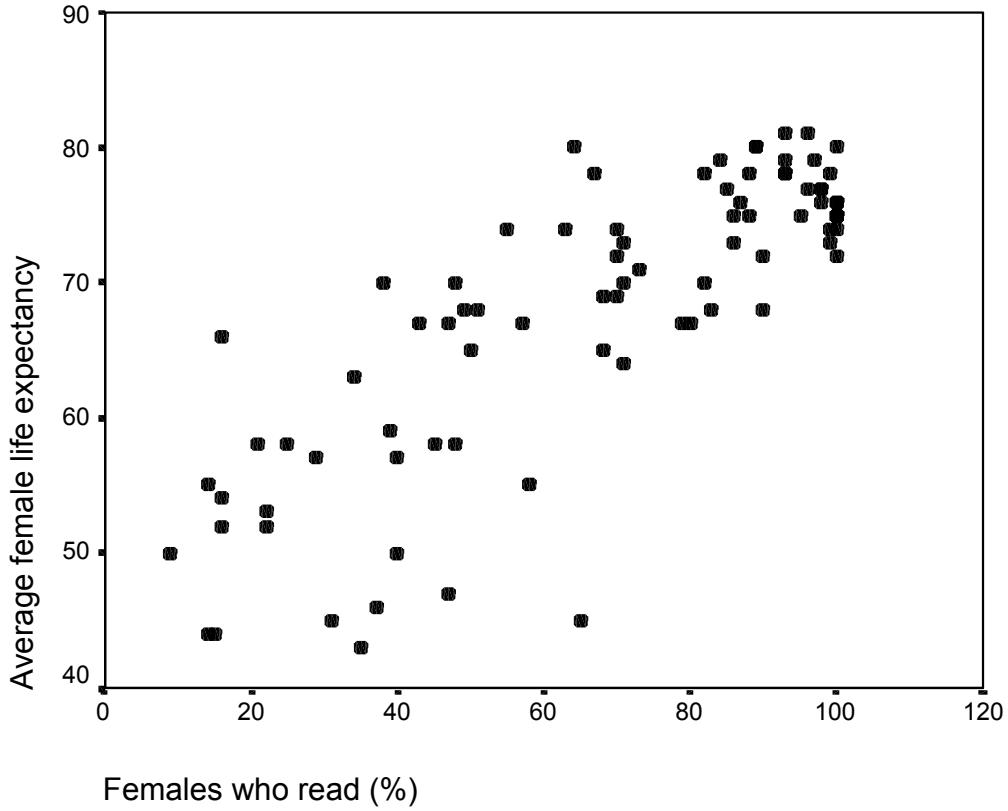

GRAPHS ⇨ SCATTERPLOT ⇨ SIMPLE
pro osu x „Average female life expectancy“
pro osu x „Females who read“

EDITOVAT GRAF:

- SCATTERPLOT OPTIONS (změnit CASE LABELS OFF na CASE LABELS ON)
- FIT LINE TOTAL (zadat)

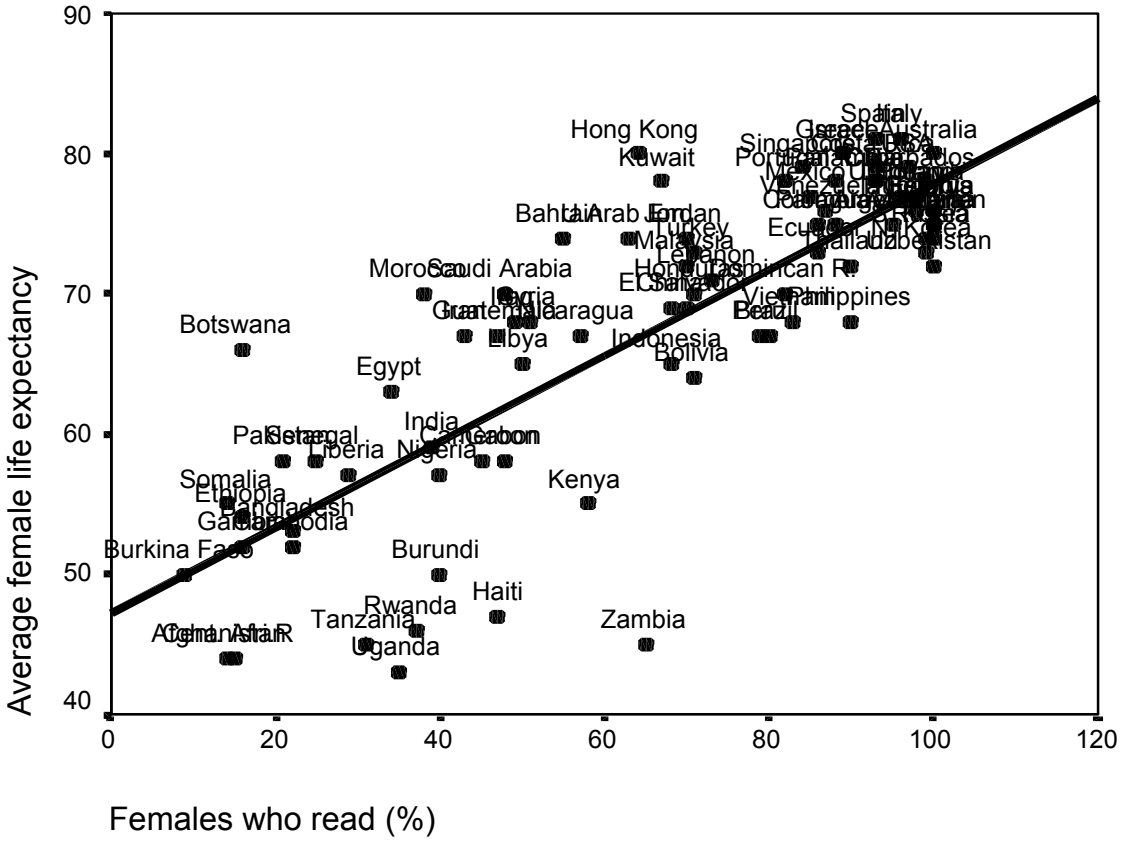

© Petr Mareš

REGRESNÍ MODEL V JEDNODUCHÉ LINEÁRNÍ REGRESI

Základní informace, o kterou usilujeme je rovnice regresní (predikční) přímky. V případě JEDNODUCHÉ LINEÁRNÍ REGRESE je její obecný tvar:

$y = b_0 + b_1x$

Ve složitějším případě bychom mohli uvažovat i o tzv. náhodné chybě (random error) e, protože ne všechny body leží přímo na přímce:

$y = b_0 + b_1x + e$

y = ZÁVISLE PROMĚNNÁ - závisle proměnná neboli výsledek (outcome). Je to ta proměnná, jejíž hodnotu chceme predikovat.

x_1 = NEZÁVISLE PROMĚNNÁ - neboli prediktor. Je to ta proměnná, jejíž hodnota slouží k predikci hodnoty y.

b_0 = Konstanta neboli INTERCEPT, bod ve kterém přímka protne osu y (hodnota y pro $x_i = 0$).

b_1 = SMĚRNICE (sklon) přímky neboli SLOPE, která určuje o kolik jednotek se změní hodnota y, když se hodnota x změní o 1 jednotku

e = náhodná chyba (variance nevysvětlitelné regresní rovnicí – zahrnutými nezávislými proměnnými).

Může jít nejen o:

- JEDNODUCHOU LINEÁRNÍ REGRESI, kdy jde o vliv jediné nezávisle proměnné na sledovanou závislou proměnnou.

  Příklad:
  Souvislost mezi velikostí inflace (vyjádřené mírou inflace) a velikostí nezaměstnanosti (vyjádřené mírou nezaměstnanosti).

  míra nezaměstnanosti = a + b . míra inflace

ale též o:

- MNOHONÁSOBNOU LINEÁRNÍ REGRESI, kdy jde o současný kombinovaný vliv více nezávisle proměnných na sledovanou závislou proměnnou

  Příklad:
  Subjektivní hranice chudoby jako vyjádření

  SPL = a + b_1 . příjem rodiny + b_2 . počet dospělých v rodině + b_3 . počet dětí v rodině

© Petr Mareš

CÍL REGRESNÍ ANALÝZY

Najít koeficienty, které pomohou
- odhadnout hodnotu predikované proměnné
- za pomoci hodnoty predikátoru pro nové případy.

Těmito koeficienty jsou již zmíněné:
- Konstanta (intercept) b_0 což je bod,
- ve kterém přímka protíná osu y (x=0).
- Sklon (směrnice) přímky (slope) b_1 (respektive b) což je poměr mezi vertikální změnou a horizontální změnou podél přímky. Jinak řečeno je to změna **y**, která je způsobena změnou **x** o jednotku.

PŘÍMKA JE MODELEM ROZLOŽENÍ DAT

V sociální realitě se nesetkáváme s případy ideální lineární regrese. Data jsou více či méně rozptýlena a linearita vztahu je vyjádřena tím, že přímka je jen vhodným modelem pro proložení daty (vyjadřuje tendenci v datech).

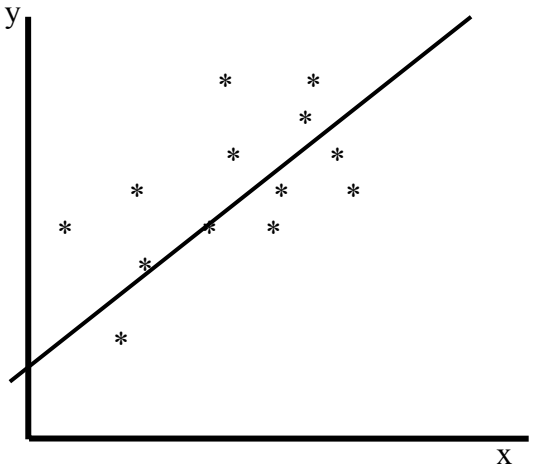

Daty lze proložit řadu přímek. Nejjednodušší způsob jak stanovit regresní přímku je metoda nejmenších čtverců odchylek (residuálů). Jen u jedné z přímek je totiž suma čtverců odchylek minimální.

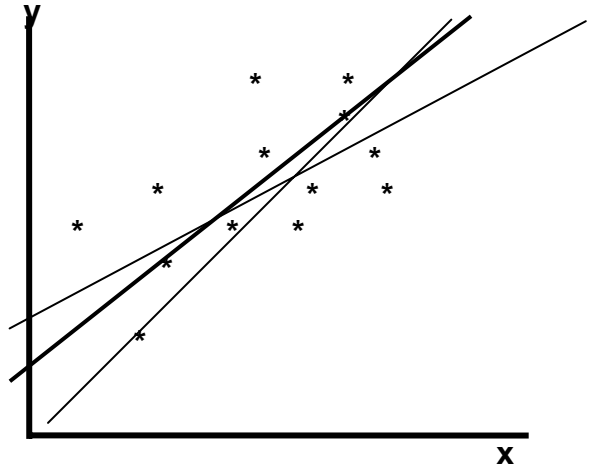

© Petr Mareš

IDENTIFIKACE REGRESNÍ PŘÍMKY

Nejjednodušší způsob identifikace regresní respektive predikční přímky představuje METODA NEJMENŠÍCH ČTVERCŮ

Predikované a pozorované hodnoty se liší (predikční přímka je pozorovanými hodnotami proložena) o tzv. RESIDUÁLY.

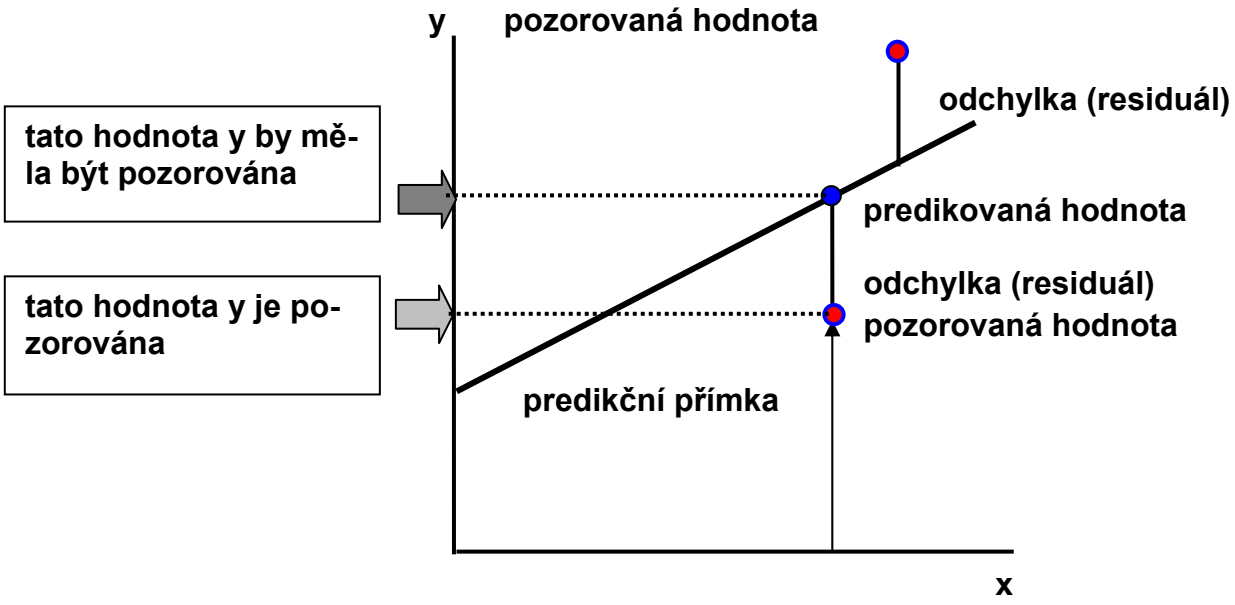

Součet čtverců všech residuálu musí být nejmenší možný.

PŘÍMKA NENÍ JEN MODELEM ROZLOŽENÍ DAT má též PREDIKČNÍ HODNOTU (predikční přímka). Z každé hodnoty x odvodíme příslušnou hodnotu y.

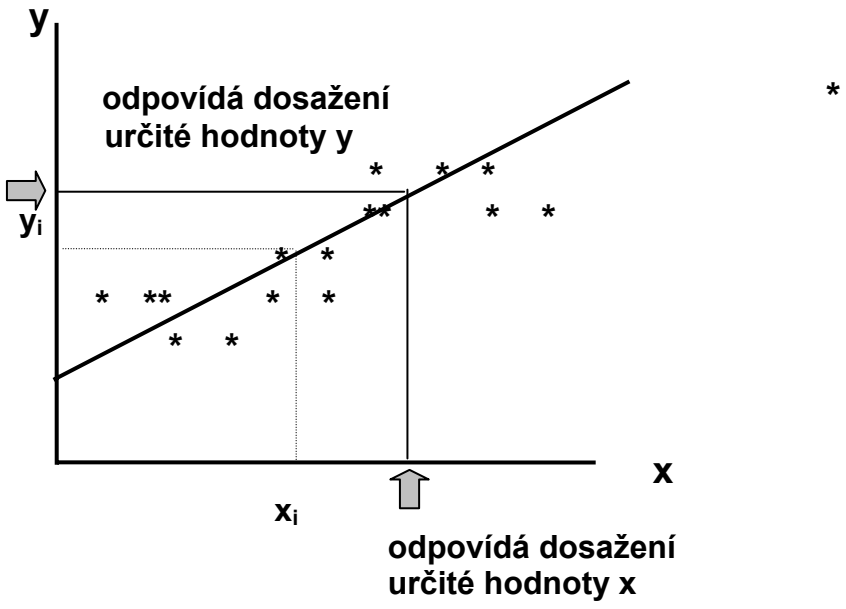

© Petr Mareš

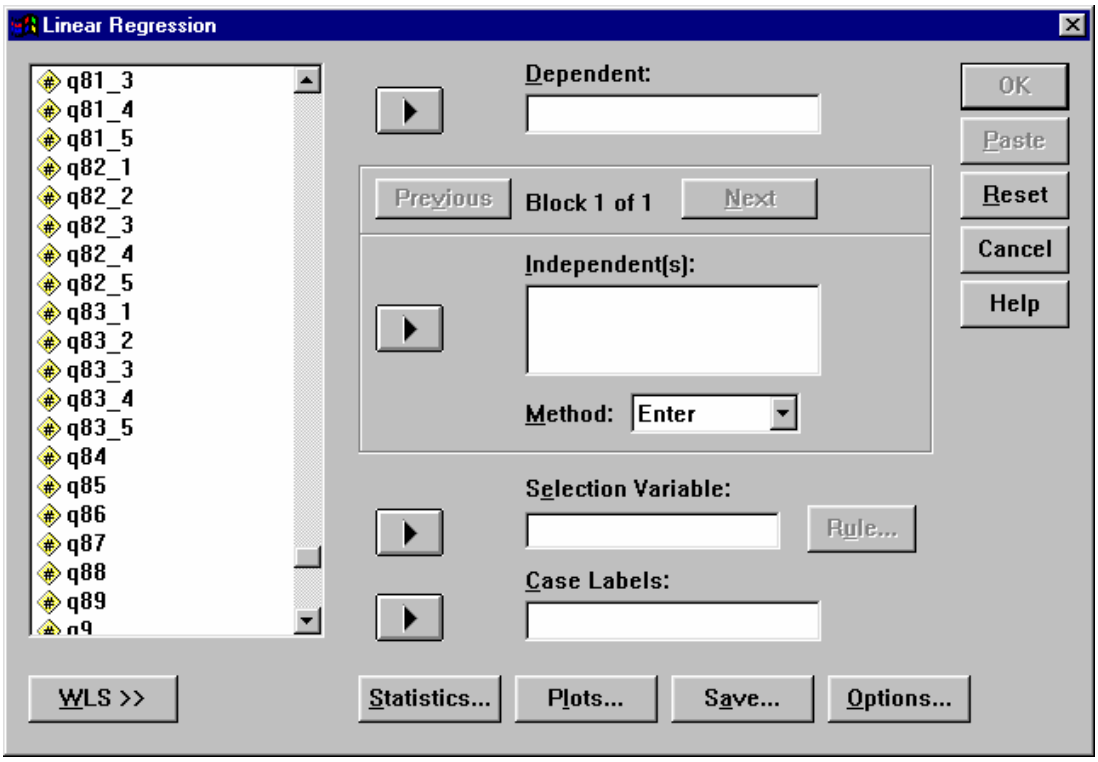
Linear Regression
q81_3
q81_4
q81_5
q82_1
q82_2
q82_3
q82_4
q82_5
q83_1
q83_2
q83_3
q83_4
q83_5
q84
q85
q86
q87
q88
q89
Dependent:
Previous
Block 1 of 1
Next
Independent(s):
Method:
Enter
Selection Variable:
Rule...
Case Labels:
OK
Paste
Reset
Cancel
Help
WLS >>
Statistics...
Plots...
Save...
Options...

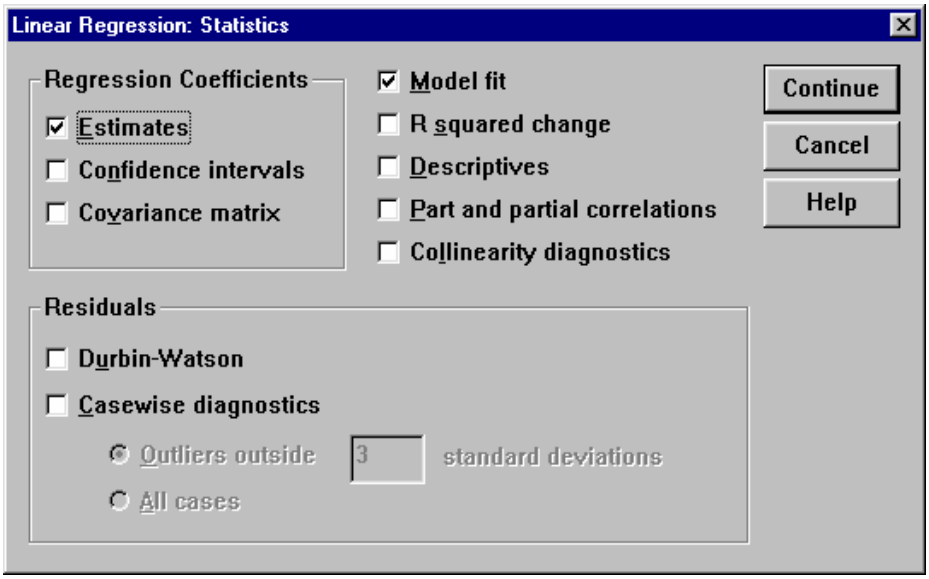
Linear Regression: Statistics
Regression Coefficients
Estimates
Confidence intervals
Covariance matrix
Model fit
R squared change
Descriptives
Part and partial correlations
Collinearity diagnostics
Continue
Cancel
Help
Residuals
Durbin-Watson
Casewise diagnostics
Outliers outside
3
standard deviations
All cases

© Petr Mareš

ZÁKLADY LINEÁRNÍ REGRESE - VZTAH SPOJITÝCH PROMĚNNÝCH

PŘÍKLAD

VÝPOČET KONSTANT

Coefficients [a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	89,985	1,765		50,995	,000
	BIRTHRAT Births per 1000 population, 1992	-,697	,050	-,968	-13,988	,000

a. Dependent Variable: LIFEEXPF Female life expectancy 1992

intercept **směrnice (slope)**

URČENÍ ROVNICE:

$$y = 89{,}985 - 0{,}697 \cdot x$$

© Petr Mareš