

Zobrazení dvourozměrných dat, korelační koeficient



Zobrazení dvourozměrných dat, korelační koeficient



Dvourozměrná analýza

- zkoumá vztahy mezi dvěma proměnnými
- **Do jaké míry jedna proměnná ovlivňuje druhou proměnnou?**

Př.

- Predikuje intelekt akademický úspěch?
- Mají dobrí češtináři i dobré známky z matematiky?

"Jedna proměnná ovlivňuje druhou=

- mezi proměnnými existuje vztah, pokud rozložení hodnot jední proměnné je asociováno s rozložením hodnot druhé proměnné

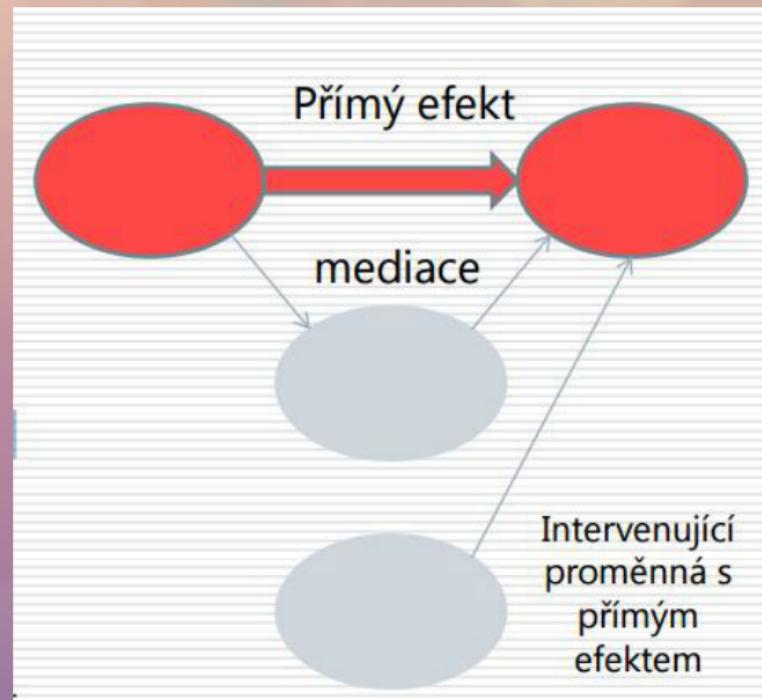
Statistická závislost

- hodnotě jedné veličiny (proměnné) odpovídá celé množství hodnot jiné veličiny
- př. výška žáků se s přibývajícím věkem zvětšuje (ale nelze tvrdit, že určitému věku přináleží určitá výška)

- cílem v prověrov - v huma ambicióz



- cílem výzkumu je obvykle prověřovat kauzální vztahy
- v humanitních vědách velmi ambiciózní



Závislá a nezávislá proměnná

Nezávislá proměnná

- jejím chováním se vysvětluje chování závislé proměnné
- příčinná proměnná - v důsledku jejich změny se mění vysvětlovaná proměnná.

Závislá proměnná

- její chování se snažíme vysvětlit
- mění se v důsledku chování nezávislé proměnné

Intervenující proměnná

- zasahuje do vztahu mezi závislou a nezávislou proměnnou a ovlivňuje jej
- obvykle není možné identifikovat všechny intervenující proměnné

Kontingenční tabulka

- způsob, jak popsat dvourozměrná rozdělení
- dá se použít pro všechny úrovně měření
- nevhodnější pro nominální úroveň (nemá příliš mnoho hodnot)
- nevhodná, když máme mnoho hodnot - nepřehlednost

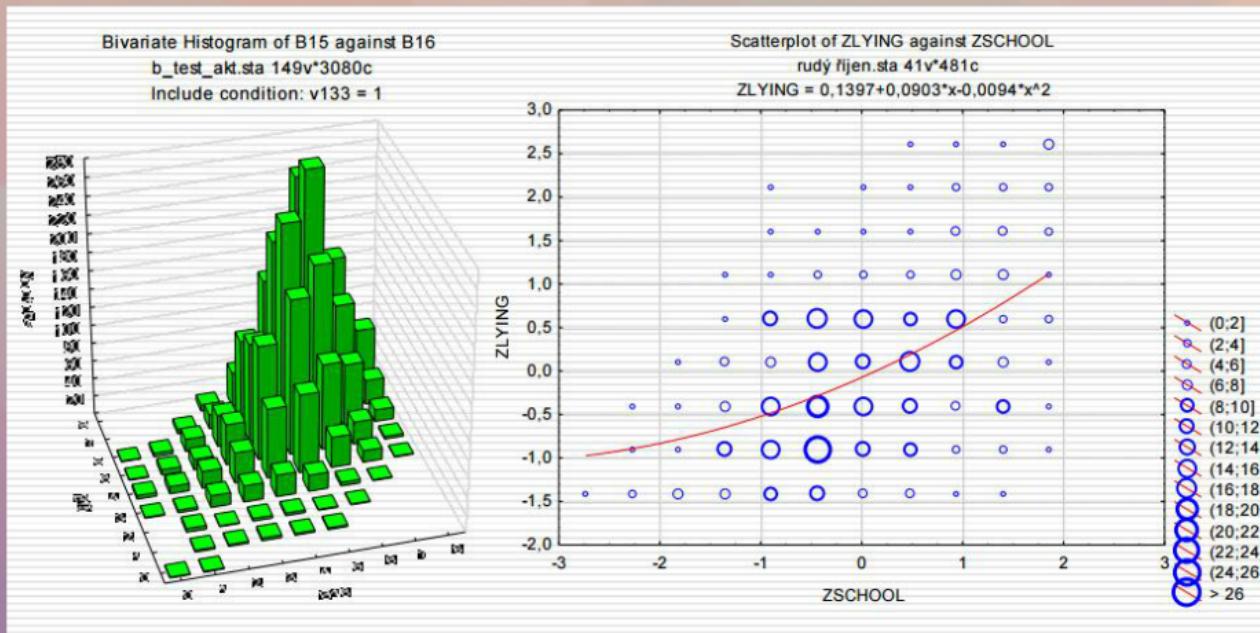
		známka z matematiky					celkem
		1	2	3	4	5	
známka z čj	1	82	40	8	1	0	131
	2	71	200	73	17	0	361
	3	4	75	109	25	0	213
	4	1	7	23	24	1	56
	5	0	0	2	1	2	5
celkem		158	322	215	68	3	766

Kontingenční tabulka

		známka z matematiky					celkem
		1	2	3	4	5	
známka z čj	1	82	40	8	1	0	131
	2	71	200	73	17	0	361
	3	4	75	109	25	0	213
	4	1	7	23	24	1	56
	5	0	0	2	1	2	5
celkem		158	322	215	68	3	766

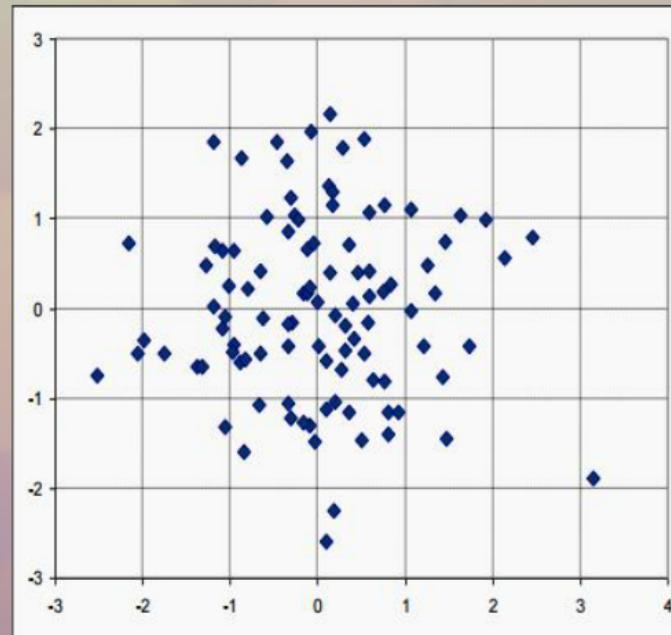
- v hlavní diagonále kontingenční tabulky více nakumulované hodnoty než jinde - lineární trend
- Hodnoty je třeba přehledně uspořádat (stejně jako u tabulky četností)
- Pro data všech úrovní měření, nevhodnější pro diskrétní prom. s málo hodnotami
- Buňky mohou obsahovat absolutní četnosti, rel. četnosti (řádkové, sloupcové, celkové)
- Poslední sloupec/řádek obsahuje tzv. sloupcové/řádkové marginální (relativní) četnosti
- Je grafickou podobou je trojrozměrného sloupcový diagramu či histogramu (může tedy obsahovat i intervaly)
- Relativně vysoké četnosti v jedné z diagonál naznačují lineární provázanost proměnných

Grafická zobrazení dvourozměrného rozdělení



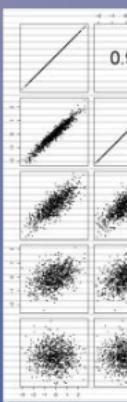
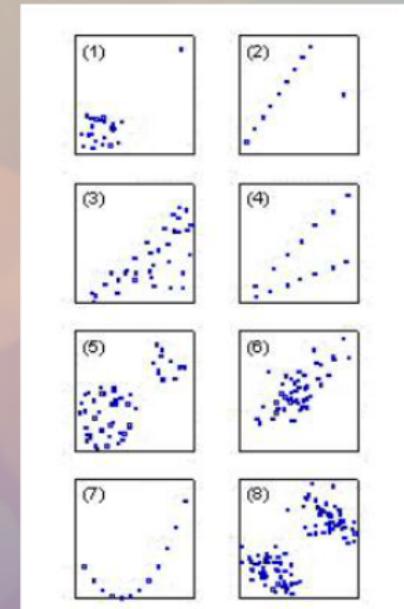
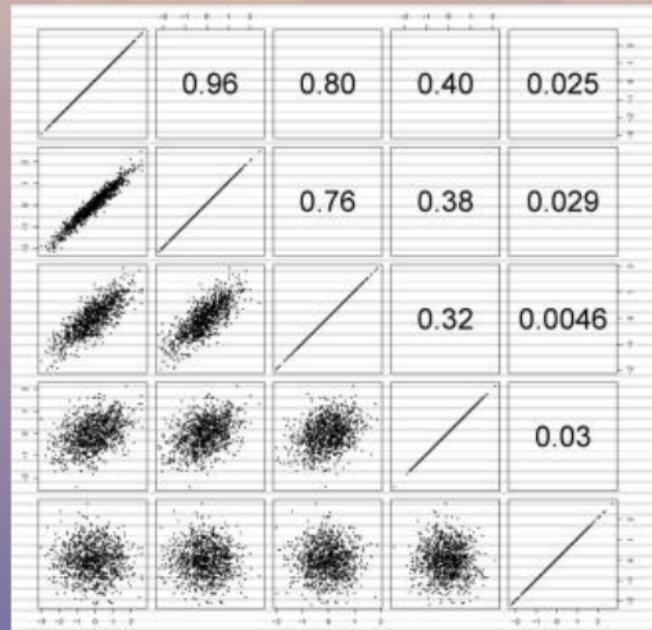
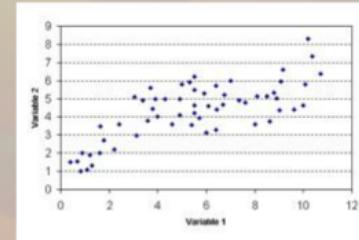
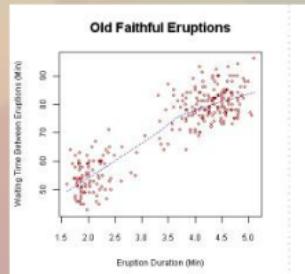
Bodový graf - scatterplot

- Používá se na poměrové úrovni, zobrazuje přesné polohy odpovědi každého respondenta
- těsně související proměnné obvykle uspořádány do elipsy (čím užší a protáhlejší, tím těsnější vztah)
- Nahrazuje kontingenční tabulku, jsou-li obě proměnné spojité
- Pro proměnné s málo body měření nemá smysl
 - Každá osa reprezentuje jednu proměnnou, každý bod je jedna zkoumaná osoba (jednotka)
 - Poskytuje tím lepší evidenci o vztahu dvou proměnných...
 - ...čím více měření jsme provedli
 - ...čím přesnější jednotlivá měření byla



! Korelace
vztah dvou
pouze je

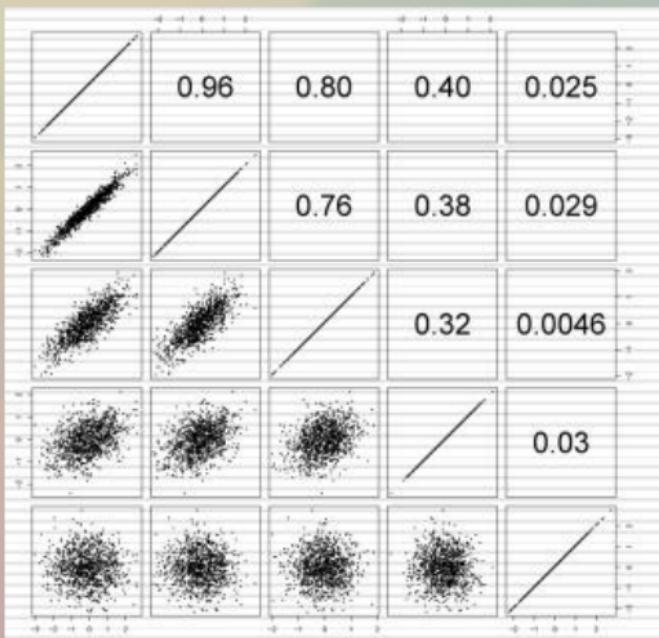
Různé podoby vztahu mezi dvěma proměnnými



- Lineární vztah je korelace.
- Je to monotónní, tedy čím více X, tím více Y.
- Projevuje se tak, že má „ideální“ přímku.

$$y = ax + b$$

- Tato funkce/příslušný popisuje strmost
- Korelace popisuje těsnost vztahu.



Pouze takto vypadající scattery zobrazují vztah mezi 2 proměnnými, který je lineární a dobře (=smysluplně, výstižně) popsatelný pomocí Pearsonova korelačního koeficientu. U ostatních jde buď o vztahy nelineární, nebo je problém v heterogenitě, outlierech...

- Čím těsnější (=intenzivnější) je vztah 2 proměnných, tím jsou body v scattery nahuštěny okolo přímky.
- Těsnost nesouvisí s sklonem té přímky, pouze s tím, jak blízko scattery podél přímce.

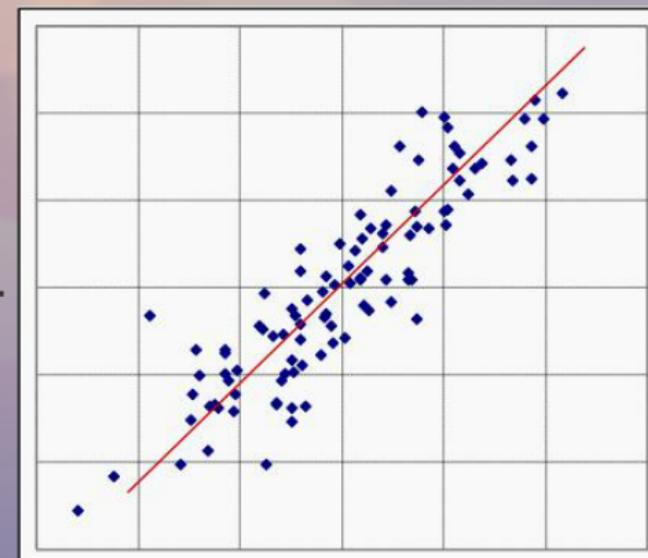
- Těsnost se uvažuje když kde 0=žádný vztah (data na diagonále).
- Znaménko u hodnoty (+) nebo o (-) vztahu.
- Rozsah je těsnost vzdálenost mezi min. a max. hodnotou.

Lineární souvislost (vztah)

- Lineární vztah je to, co se obvykle míní slovem korelace.
- Je to monotónní vztah, který se dá popsát slovy čím více X, tím více/méně Y.
- Projevuje se tak, že scatterplot se dá proložit „ideální“ přímkou

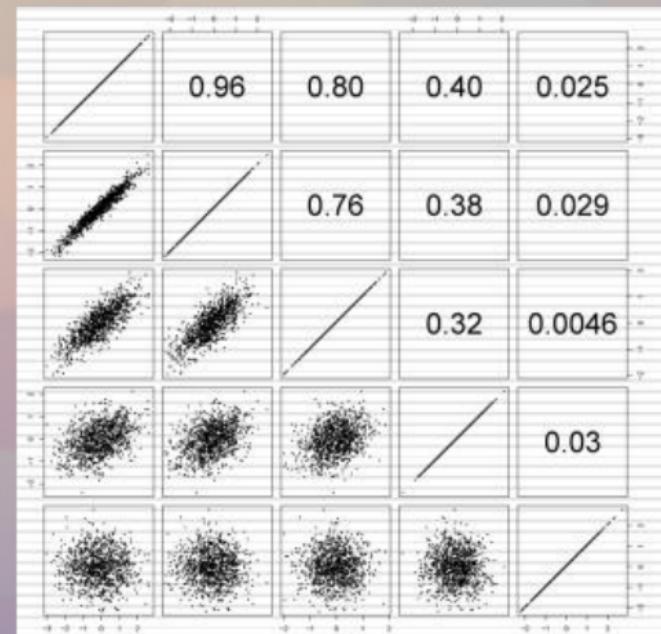
$$y = ax + b$$

- Tato funkce/přímka popisuje strmost vztahu.
- Korelace popisuje těsnost vztahu.



Těsnost vztahu

- Čím těsnější (=intenzivnější, silnější) vztah 2 proměnných je, tím jsou body více nahuštěny okolo nějaké přímky
- Těsnost nesouvisí se sklonem té přímky, ale pouze s tím, jak moc se scatterplot podobá přímce.



- Těsnost se udává bezrozměrným číslem od 0 do 1, kde 0=žádný vztah(těsnost) a 1= maximální vztah (data na diagonále v obrázku napravo)
- Znaménko udává, zda jde o vztah čím víc, tím víc (+) nebo o vztah čím víc, tím míň (-)
- Rozsah je tedy od -1 do 1

Korelace

Standardizovaný sdílený rozptyl

$$r_{xy} = \frac{\sum z_x z_y}{n-1}$$

$$r_{xy} = \frac{1}{n-1} \sum_{i=1}^n \left(\frac{x_i - m_x}{s_x} \right) \left(\frac{y_i - m_y}{s_y} \right)$$

Pearsonův součinový, momentový koeficient korelace

- nutná intervalová a vyšší úroveň měření
- velký vliv odlehlých hodnot na výsledek
- je vhodný pro popis normálně rozložených proměnných
- vyjadřuje pouze sílu(těsnost) lineárního vztahu

Nabývá hodnot v rozmezí -1 až 1

0 = žádný vztah

1(-1) = dokonalý kladný (záporný) vztah



Korelace nepopisuje funkční vztah dvou proměnných, ale pouze jeho směr a těsnost.

1. Který z následujících korelačních koeficientů ukazuje na nejtěsnější (nejsilnější) vztah?

- a) 0,55
- b) 0,09
- c) -0,77
- d) 0,1
- e) 1,05

2. Pěti reprezentativním vzorkům lidí ve věku 15, 20, 30, 45 a 60 let jsme dali dotazník na měření politické konzervativnosti. Těmto 5 vzorkům v uvedeném pořadí vyšly následující průměrné hodnoty konzervativnosti: 60, 85, 80, 70, 65. Korelace mezi věkem a politickou konzervativností je

- a) 1.0
- b) -1.0
- c) lineární
- d) nelineární

3. Korelace mezi X a Y je 0,60; korelace mezi X a W je -0,80. Má X těsnější lineární vztah s Y nebo s W?

Zobrazení dvourozměrných dat, korelační koeficient

