

Zobrazení dvourozměrných dat, korelační koeficient

Dvourozměrná analýza

Objeví vztah mezi dvěma proměnnými
Do jaké míry jedna proměnná ovlivňuje druhou proměnnou?

Proč jsou vztahy pozorovatelné (apod.)?
Mají příčinu (období, občas změny v ročním období)?

Jedna proměnná ovlivňuje druhou?

- mají proměnné rovnou vztah, pokud rozdílů hodnot je v průměru je statisticky významný (hodnoty rozdílů jsou přibližně statisticky významné)
- hodnota jedné veličiny (proměnné) ovlivňuje hodnotu druhé veličiny
- od výšky žánru se v průměru liší věk (čím vyšší žánr, tím vyšší věk)

Statistická významnost



Číselná a vizuální porovnání

Číselná porovnání

Tabulka s číselnými hodnotami

Vizuální porovnání

Scatter plot showing a positive linear relationship between two variables. The x-axis is labeled 'Věk' and the y-axis is labeled 'Výška'. Data points are scattered around a positive linear trend line.

Kontingenční tabulka

Tabulka s číselnými hodnotami

Vizuální porovnání

Scatter plot showing a positive linear relationship between two variables. The x-axis is labeled 'Věk' and the y-axis is labeled 'Výška'. Data points are scattered around a positive linear trend line.

Bodový graf - scatterplot

Tabulka s číselnými hodnotami

Vizuální porovnání

Scatter plot showing a positive linear relationship between two variables. The x-axis is labeled 'Věk' and the y-axis is labeled 'Výška'. Data points are scattered around a positive linear trend line.

Různé podoby vztahu mezi dvěma proměnnými

Tabulka s číselnými hodnotami

Vizuální porovnání

Scatter plot showing a positive linear relationship between two variables. The x-axis is labeled 'Věk' and the y-axis is labeled 'Výška'. Data points are scattered around a positive linear trend line.

Korelace

Standardizovaný sdílený rozptyl

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$$

Pearsonův součinný, momentový koeficient korelace

- 1) měří intenzitu a výsíl (směr) vztahu
- 2) měří vlnu vlnění (hodnoty se pohybují mezi -1 a 1)
- 3) je vhodný pro úzké normálně rozdělených proměnných (úzký a normální)
- 4) vyjadřuje posude silnějšího (blíže k 1) nebo slabšího (blíže k 0) vztahu

Nabývá hodnot v mezích -1 až 1
0 = žádný vztah
1(-1) = dokonalý (kladný/záporný) vztah

! Korelace nepropojuje kausální vztah dvou proměnných, ale pouze jeho směr a sílu.

1. Měří sílu vztahu mezi dvěma proměnnými (období na nepřítomnosti (nejdejší) vztah?)
a) 0,95 b) 0,99 c) -0,77 d) 0,1 e) 1,05

2. Při reprezentativní vzorku (n = 100) je 33, 30, 41 a 26 lidí, kteří odpovídají na otázku: "přijde-li vám někdo, že jste šťastný, jak často se smějete?"
a) 1,01 b) 1,0 c) 0,99 d) 0,98

3. Korelace mezi X a Y je 0,85. Kde X = počet hodin strávených v práci a Y = mzdová sazba

Vizualizace vztahů

Tabulka s číselnými hodnotami

Vizuální porovnání

Scatter plot showing a positive linear relationship between two variables. The x-axis is labeled 'Věk' and the y-axis is labeled 'Výška'. Data points are scattered around a positive linear trend line.

Dvourozměrná analýza

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

Př.

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

"Jedna proměnná ovlivňuje druhou="

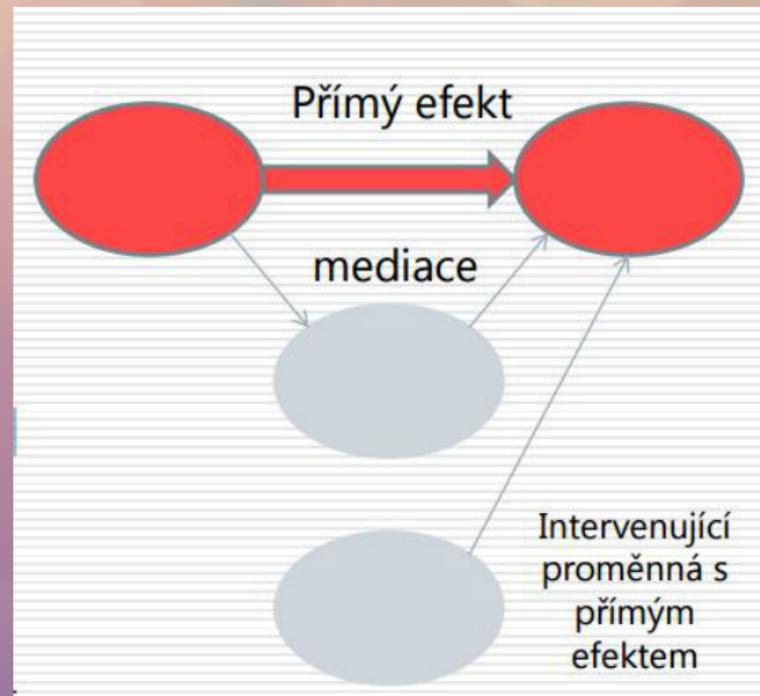
- mezi proměnnými existuje vztah, pokud rozložení hodnot jedné proměnné je asociováno s rozložením hodnot druhé proměnné

Statistická závislost

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

- cílem v
- prověřov
- v huma
ambiciózn

- 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 je
- obvykle není možné identifikovat všechny intervenující proměnné

Kontingenční tabulka

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

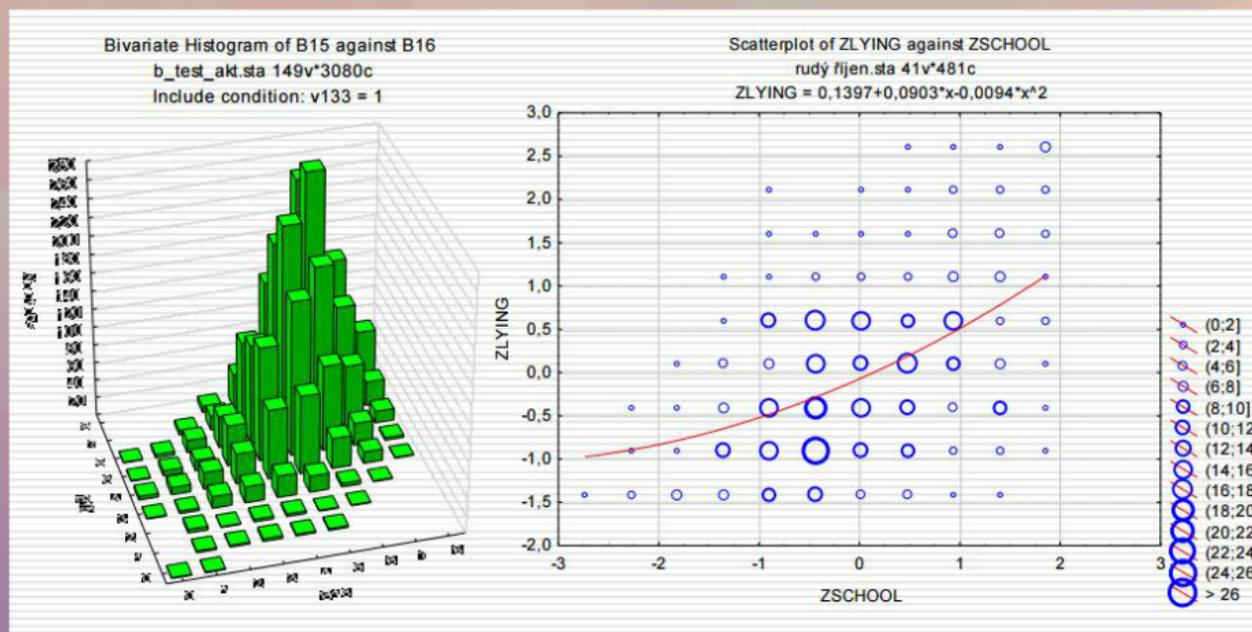
		známka z matematiky					celkem
		1	2	3	4	5	
známka z čj	1	82	40	8	1	0	131
	2	71	200	73	17	0	361
	3	4	75	109	25	0	213
	4	1	7	23	24	1	56
	5	0	0	2	1	2	5
celkem		158	322	215	68	3	766

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

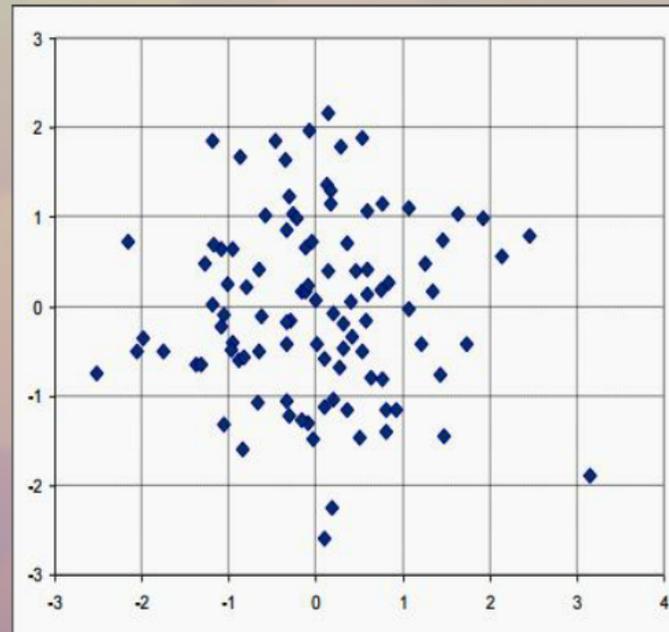
- v hlavní diagonále kontingenční tabulky více nakumulované hodnoty než jinde - lineární trend
- Hodnoty je třeba přehledně uspořádat (stejně jako u tabulky četností)
- Pro data všech úrovní měření, nejvhodnější pro diskrétní prom. s málo hodnotami
- Buňky mohou obsahovat absolutní četnosti, rel. četnosti (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

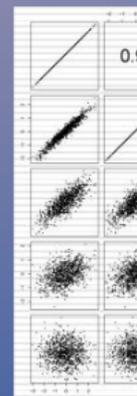
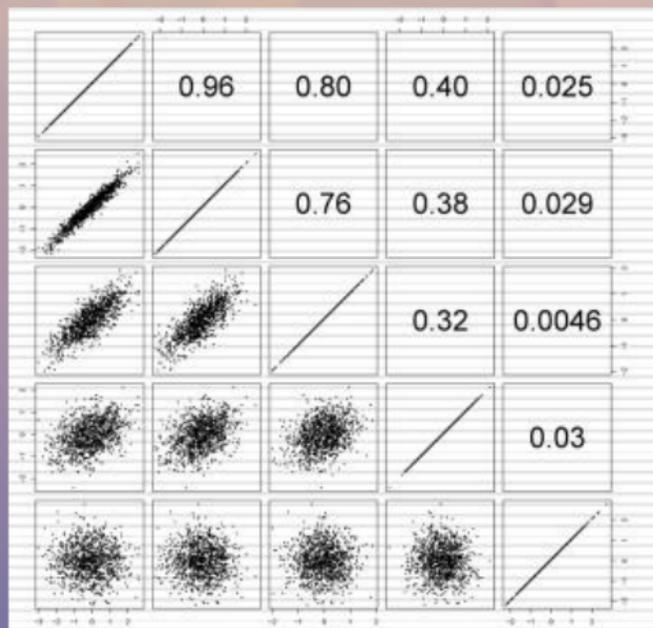
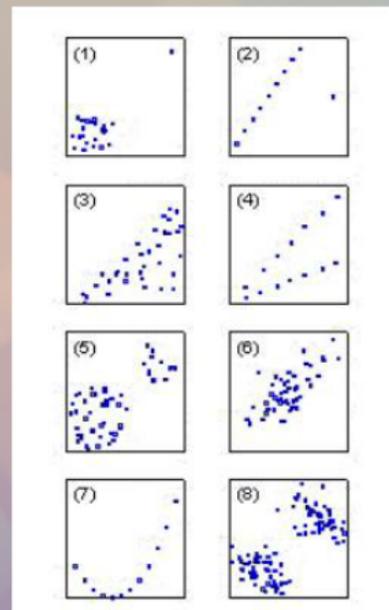
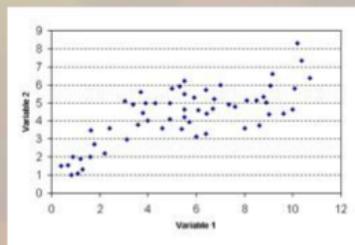
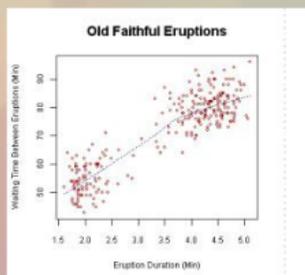
- Používá se na poměrové úrovni, zobrazuje přesné polohy odpovědi každého respondenta
- těsně související proměnné obvykle uspořádány do elipsy (čím užší a protáhlejší, tím těsnější vztah)
- Nahrazuje kontingenční tabulku, jsou-li obě proměnné spojité
- Pro proměnné s málo body měření nemá smysl
 - Každá 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

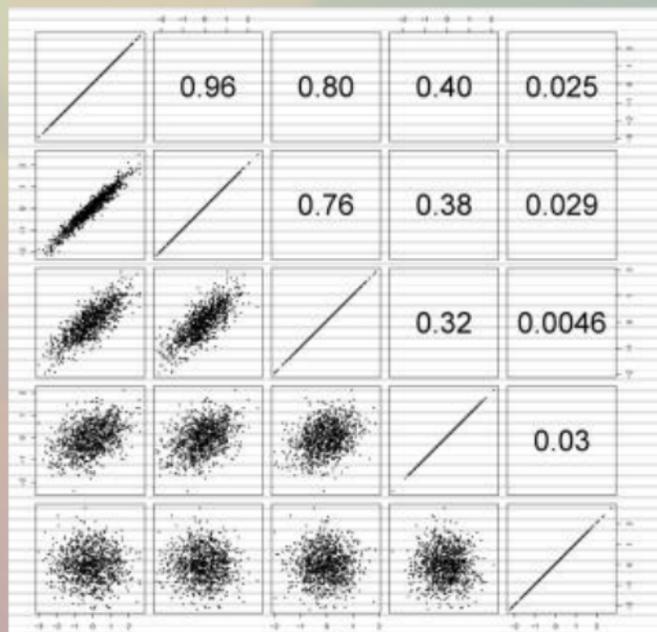




Korelac
vztah dv
pouze j

Různé podoby vztahu mezi dvěma proměnnými





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

- Lineární vztah, korelace.
- Je to monotónní, čím více X, tím více Y.
- Projevuje se takto „ideální“ přímkou.

$$y = ax + b$$

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

Těsnost

- Čím těsnější (=intenzivnější) vztah 2 proměnných, tím jsou body v scatterplotu nahuštěny okolo přímkou.
- Těsnost nesouvisí s sklonem té přímkou, pouze s tím, jak nahuštěný je scatterplot podél přímkou.

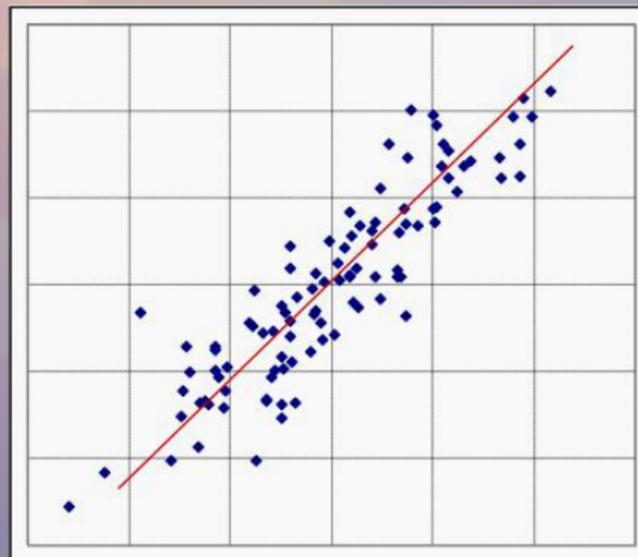
- Těsnost se udává od -1 do 1, kde 0=žádný vztah (data na diagonále).
- Znaménko udává znaménko vztahu (+) nebo o vzájemnosti (-).
- Rozsah je te...

Lineární souvislost (vztah)

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

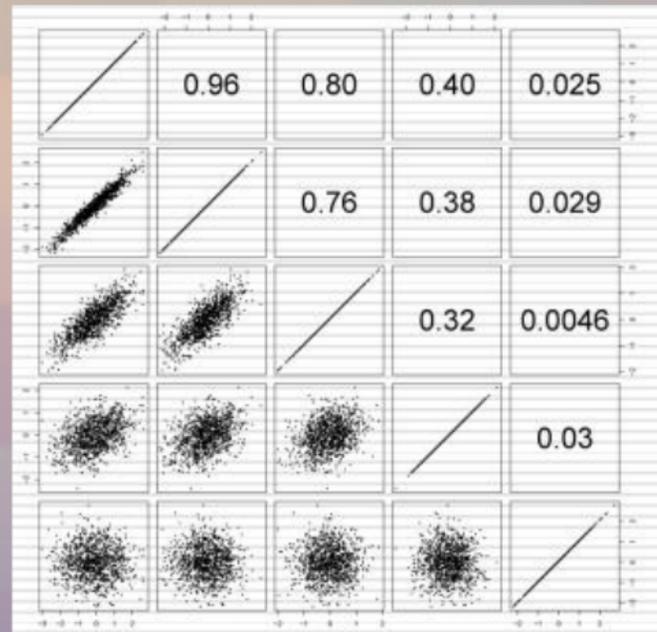
$$y = ax + b$$

- 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 součinný, momentový koeficient korelace

- nutná intervalová a vyšší úroveň měření
- velký vliv odlehlých hodnot na výsledek
- je vhodný pro popis normálně rozložených proměnných (alespoň unimodální)
- 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?

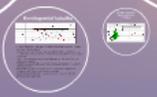
Zobrazení dvourozměrných dat, korelační koeficient

Dvourozměrná analýza
 - jaké vztahy mezi dvěma proměnnými
 - lze jako máv jítka považovat vztahy dvojích proměnných?
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?



Číselná a verbální proměnná
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?

Kontingenční tabulka
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?



Bodyový graf - scatterplot
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?

Různé podoby vztahu mezi dvěma proměnnými
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?

Korelace
 Standardizovaný sdílený rozptyl

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$$

 Pearsonův součinný, momentový koeficient korelace
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?

1. Měří sílu nelineárních korelačních vztahů (korelace na nepřímých (nejdejší) vztahy)
 a) 0,95 b) 0,99 c) -0,77 d) 0,1 e) 1,05
2. Při reprezentativním vzorku velikosti 15, 33, 30, 41 a 50 lze očekávat na měření poměrně vysokou korelaci. Tento vzorek vztahem mezi dvěma proměnnými (záporný, kladný, žádný)
 a) 1,0 b) 1,0 c) 1,0 d) 1,0 e) 1,0
3. Korelace mezi X a Y je 0,85. Korigovaná korelace mezi X a Y je 0,85. Korigovaná korelace mezi X a Y je 0,85.

Průběh vztahu
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?
 - jaké vztahy existují (záporný, kladný, žádný)?