

# KORELAČNÍ ANALÝZA

# Korelační analýza

- Měření *intenzity závislosti* mezi proměnnými
- Úzká návaznost na regresní analýzu, neboť se v ní využívá teorie lineárních regresních modelů
- Nehledá formu vztahu mezi proměnnými, neboť už primárně vychází z předpokladu, že tento vztah je lineární (dokonce nejen z hlediska parametrů, ale i z hlediska proměnných), a soustředí se na konstrukci měr závislostí mezi těmito proměnnými.

# Populační párový korelační koeficient

- V nejjednodušším případě se sleduje závislost dvou náhodných veličin  $Y$  a  $X$ . V tomto případě lze použít jako míru lineární závislosti těchto veličin *(párový) koeficient korelace  $\rho_{xy}$* , definovaný vztahy:

$$\rho_{xy} = \frac{Cov(X, Y)}{\sigma(X) \cdot \sigma(Y)} \text{ pro } \sigma(X) > 0, \sigma(Y) > 0,$$

- Jinak  $\rho_{xy}=0$

- Kde  $Cov(x, y)$  značí kovariaci náhodných veličin  $X$  a  $Y$ ,  $\sigma(x)$  a  $\sigma(y)$  je směrodatná odchylka veličiny  $X$ , respektive  $Y$ , symbol  $E$  značí střední hodnotu náhodné veličiny.

# Hodnoty koeficientu korelace

- Pro párový koeficient korelace platí, že  $\rho_{xy}$  je z intervalu  $[-1,1]$ .
- Je-li  $\rho_{xy} = 0$ , říkáme, že veličiny  $X$  a  $Y$  jsou nezkorelované.
- Je-li  $\rho_{xy} = 1$  nebo  $\rho_{xy} = -1$ , existuje přesná funkční závislost mezi veličinami  $X$  a  $Y$  v podobě přímky.
- Tato přímka je rostoucí v prvním případě a klesající ve druhém případě.
- Je-li  $\rho_{xy} = 0$ , je třeba se omezit pouze na konstatování, že obě veličiny jsou nezkorelované. Nelze tvrdit, že jsou (statisticky) nezávislé.

# Příklad

- Vypočítejme koeficient korelace , jsou-li dány tyto údaje:

$X$	-2	-1	0	1	2
$Y$	4	1	0	1	4

- Všechny páry hodnot nastávají se stejnou pravděpodobností  $p$ .

# Řešení příkladu

- Mezivýpočty pro vyhodnocení koeficientu korelace:

$X_i$	$Y_i$	$X_i \cdot Y_i$
-2	4	-8
-1	1	-1
0	0	0
1	1	1
2	4	8
$\sum x_i = 0$	$\sum y_i = 10$	$\sum x_i \cdot y_i = 0$

- Kovariance:  $Cov(X, Y) = E(XY) - E(X) \cdot E(Y) = p \sum_i x_i y_i - p^2 \sum_i x_i \sum_i y_i = 0$
- $\rho_{xy} = 0$
- Přitom tyto veličiny rozhodně nejsou nezávislé. Dokonce mezi nimi existuje přesná funkční závislost v podobě kvadratické funkce.

# Výběrový párový korelační koeficient

- Populační párový korelační koeficient approxujeme výběrovým párovým korelačním koeficientem  $r_{xy}$ , získaným na základě realizace náhodného výběru:

$$r_{xy} = \frac{n \cdot \sum x_i \cdot y_i - \sum x_i \cdot \sum y_i}{\sqrt{[n \cdot \sum x_i^2 - (\sum x_i)^2] [n \cdot \sum y_i^2 - (\sum y_i)^2]}}$$

# Test statistické významnosti korelačního koeficientu

1. Nulová hypotéza  $H_0: \rho_{xy} = 0$ , alternativní hypotéza  $H_1: \rho_{xy} \neq 0$ .
2. Testové kritérium:

$$T = \frac{r_{xy} \cdot \sqrt{n-2}}{\sqrt{1-r_{xy}^2}}$$

3. Kritická hodnota testu  $K = t_{n-2}(\alpha)$ 
  - Studentovo rozdělení s  $n-2$  stupni volnosti.
4. Je-li  $|T| \geq K$ , pak se  $H_0$  zamítá, co znamená že korelační koeficient není statisticky významný, existuje lineární závislost mezi X a Y. V opačném případě se  $H_0$  nezamítá, Y není lineárně závislé na X.

# Příklad

- Mějme hodnoty  $x_i$  a  $y_i$  získané náhodným výběrem:

$x_i$	$y_i$
-2	-5
-1	-3
0	0
1	1
2	4

- Pro tyto hodnoty vypočítejte hodnotu korelačního koeficientu a testujte jeho statistickou významnost na hladině významnosti 0,01.

# Příklad - řešení

- Pro výpočet potřebujeme hodnoty:

$x_i$	$y_i$	$x_i y_i$	$x_i^2$	$y_i^2$
-2	-5	10	4	25
-1	-3	3	1	9
0	0	0	0	0
1	1	1	1	1
2	4	8	4	16
$\Sigma = 0$	$\Sigma = -3$	$\Sigma = 22$	$\Sigma = 10$	$\Sigma = 51$

- $\Sigma = 0 \quad \Sigma = -3 \quad \Sigma = 22 \quad \Sigma = 10 \quad \Sigma = 51$

- Test statistické významnosti:

1.  $H_0: \rho_{xy} = 0, \rho_{xy} \neq 0.$

2.  $T = \frac{0,9918 \cdot \sqrt{5-2}}{\sqrt{1-0,9918^2}} = \frac{1,718}{\sqrt{0,016}} = 13,443$

3. Kritická hodnota testu  $K = t_{n-2}(\alpha) = t_{5-2}(0,01) = 5,84$

4. Protože  $T > K$ , je lineární závislost  $Y$  na  $X$  významná.

$$r_{xy} = \frac{5,22 - 0 \cdot (-3)}{\sqrt{(5,10 - 0) \cdot (5,51 - (-3)^2)}} = 0,9918.$$

# Index korelace

- Není-li regresní funkcí, podle níž se posuzuje korelace veličin, přímka, ale jiná, i **nelineární** funkce, je možné k odhadu závislosti  $X$  a  $Y$  použít *index korelace*:

$$I_{xy} = \sqrt{\frac{S_{\hat{Y}}}{S_Y}}$$

- Kde:

$$S_{\hat{Y}} = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2,$$

$$S_Y = \sum_{i=1}^n (Y_i - \bar{Y})^2.$$

# Koeficient determinace

- Koeficient determinace určuje přiléhavost dat ke zvolenému modelu
- $R^2 = I^2 = \frac{S_{\bar{Y}}}{S_Y}$
- Index determinace (nebo taky koeficient determinace) tedy udává kvalitu regresního modelu, přesněji vyjádřeno udává, kolik procent rozptylu vysvětlované proměnné je vysvětleno modelem a kolik zůstalo nevysvětleno;
- nabývá hodnot od nuly do jedné (teoreticky i včetně těchto krajních mezí), přičemž hodnoty blízké nule značí špatnou kvalitu regresního modelu; hodnoty blízké jedné značí dobrú kvalitu regresního modelu;
- udává se většinou v procentech.

# SPEARMANŮV KORELAČNÍ KOEFICIENT

- Jsou-li hodnoty veličin  $X, Y$  zadány pořadím, používá se k odhadu míry závislosti těchto veličin *Spearmanův koeficient (pořadové) korelace*, který se počítá dle vzorce

$$r_s = 1 - \frac{6 \cdot \sum_{i=1}^n d_i^2}{n(n^2 - 1)}.$$

- Kde  $d_i$  differenze i-tého pořadí  $X$  a  $Y$  a  $n$  je počet párů hodnot  $X$  a  $Y$ , tedy rozsah výběru.

# Příklad

- Výrobky byly seřazeny dle jakosti dvěma komisemi, z nichž jednu tvořili odborníci a druhou zástupci laické veřejnosti. Rozhodněte, zda se výsledky hodnocení obou komisí shodují ve smyslu korelace.

Výrobek	Laické pořadí	Odborné pořadí
1	7	8
2	9	9
3	8	7
4	10	10
5	6	6
6	5	4
7	3	5
8	4	3
9	2	2
10	1	1

# Příklad - řešení

- V levé části níže uvedené tabulky jsou pořadí, v pravé části této tabulky jsou spočteny rozdíly v pořadí.

Výrobek	Laické pořadí	Odborné pořadí	$d_i$	$d_i^2$
1	7	8	-1	1
2	9	9	0	0
3	8	7	1	1
4	10	10	0	0
5	6	6	0	0
6	5	4	1	1
7	3	5	-2	4
8	4	3	1	1
9	2	2	0	0
10	1	1	0	0

$$r_s = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} = 1 - \frac{6 \cdot 8}{10 \cdot 99} = 0,95.$$

# Test statistické významnosti pořadového koeficientu korelace

1. Testovaná hypotéza  $H_0$ :  $X, Y$  jsou nezávislé vs. alternativní hypotéza  $H_1$ :  $X, Y$  nejsou nezávislé.
2. Testové kritérium má tvar:

$$T = (n - 1) \cdot r_s .$$

3. Kritická hodnota testu  $K$  = kritická hodnota rozdělení  $N(0,1)$  na hladině významnosti alfa = NORMSINV(1-alfa).
4. Je-li  $|T| \geq K$ , zamítáme hypotézu  $H_0$ . V opačném případě přijímáme  $H_0$ .

Přijmeme-li  $H_0$ , víme, že jsou veličiny nezávislé, a tedy i nezkorelované. Pokud hypotézu zamítneme, víme, že veličiny nejsou nezávislé, nejsme ale schopni rozhodnout v takovém případě, zda jsou nezkorelované. Test platí přibližně pro  $n \geq 30$ .

# VÍCENÁSOBNÁ ZÁVISLOST – PŘÍPAD DVOU VYSVĚTLUJÍCÍCH PROMĚNNÝCH

- Chceme-li zjistit lineární závislost proměnné  $Y$  na větším počtu vysvětlujících proměnných  $X_1, X_2, \dots, X_p$ , používáme k měření těsnosti závislosti buďto:
  - a. koeficienty dílčí (parciální) korelace,
  - b. koeficient vícenásobné korelace.

# Koeficient dílčí (parciální) korelace

- Měří kupříkladu intenzitu lineární závislosti proměnné  $Y$  na vysvětlující proměnné  $X_1$  za předpokladu, že je jistým způsobem odstraněn vliv ostatních proměnných . Značí se:

$$r_{y \cdot x_1 \cdot x_2, \dots, x_p}$$

- Jde o proměnné, které jsou uvedeny za symbolem „·“.
- Důvod výpočtu tohoto ukazatele jen ten, že vliv proměnné  $X_1$  může být zkreslen současným působením proměnných  $X_2, \dots, X_p$ . Omezíme se nyní na případ  $p = 2$ .

# Výběrový koeficient parciální korelace p=2

- Koeficient dílčí korelace vystupuje opět ve dvou podobách: buďto jde o populační koeficient nebo jeho odhad – výběrový koeficient parciální korelace. Výběrový koeficient parciální korelace se v **případě dvou vysvětlujících proměnných**

$$r_{yx_1 \bullet x_2} = \frac{r_{yx_1} - r_{yx_2} r_{x_1 x_2}}{\sqrt{(1 - r_{yx_2}^2)(1 - r_{x_1 x_2}^2)}} \quad r_{yx_2 \bullet x_1} = \frac{r_{yx_2} - r_{yx_1} r_{x_1 x_2}}{\sqrt{(1 - r_{yx_1}^2)(1 - r_{x_1 x_2}^2)}}.$$

- Koeficienty mohou nabývat hodnot z intervalu [-1,1].

# Test statistické významnosti koeficientu parciální korelace

1.  $H_0 : \rho_{yx_1 \bullet x_2} = 0$  (není přítomna korelační závislost),  $H_1 : \rho_{yx_1 \bullet x_2} \neq 0$ .
2. Testové kritérium:
3. Kritická hodnota na hladině alfa = K =  $t_{n-3}(\alpha) = \text{TINV}(\alpha, n-3)$ .
4. Pokud  $|T| \geq t_{n-3}(\alpha)$ ,  
$$T = \frac{r_{yx_1 \bullet x_2}}{\sqrt{1 - r_{yx_1 \bullet x_2}^2}}$$
.  
pak je koeficient parciální korelace statisticky významný, tj. nenulový.

# Koeficient vícenásobné korelace

- *Koeficient vícenásobné korelace* měří závislost proměnné  $Y$  na všech vysvětlujících proměnných  $X_1, X_2, \dots, X_p$  dohromady.
- **Pro 2 vysvětlující proměnné se výběrová verze tohoto koeficientu spočte dle vztahu:**

$$r_{y \bullet x_1 x_2} = \sqrt{\frac{r_{yx_1}^2 - 2r_{yx_1} r_{yx_2} r_{x_1 x_2} + r_{yx_2}^2}{1 - r_{x_1 x_2}^2}}, \quad 0 \leq r_{y \bullet x_1 x_2} \leq 1.$$

# Test statistické významnosti koeficientu vícenásobné korelace:

1.  $H_0: \rho_{y \bullet x_1 x_2} = 0$  (není závislost) vs.  $H_1: \rho_{y \bullet x_1 x_2} \neq 0$ .

2. Testové kritérium: 
$$T = \frac{r_{y \bullet x_1 x_2}^2 \cdot (n - 3)}{2 \cdot (1 - r_{y \bullet x_1 x_2}^2)}$$

3. Kritická hodnota K se tentokrát týká Fisherova rozdělení se stupni volnosti 2 a  $n-3$ :  $F_{2,n-3}(\alpha)$

4. Pokud je  $T \geq F_{2,n-3}(\alpha)$ ,

pak je koeficient vícenásobné korelace statisticky významný na dané hladině významnosti. V opačném případě není statisticky významný.

Děkuji za pozornost