

Medisinsk statistikk Del II
Forelesning 25 februar 2009
Korrelasjon

av
Stian Lydersen og Eirik Skogvoll

1

Innhold

- Kovarians og korrelasjon (5.6.1)
- Pearson's r (11.7)
- T-test og z-test for korrelasjonskoeffisient (11.8)
- Konfidensintervall
- Rang-korrelasjon, Spearman's r_s (11.12)
- (Intra Class Correlation Coefficient ICC, 12.9)

2


Korrelasjon

= sammenheng, samvariasjon
≠ kausalitet (årsak/virkning)


Hva skiller korrelasjon fra regresjon?

3

Eksempel: Fig. 5.16a



4



5

Kovarians

Def. 5.13 s 142 (5.12, s. 135 i 5th edition)

$$\text{Cov}(X, Y) = E[(X - \mu_x)(Y - \mu_y)]$$

I klartekst ☺ :
"Forventningsverdien
til produktet
av avviket
for hhv. X og Y
fra sine respektive forventningsverdier"

6

Kovarians og uavhengighet

- Hvis X og Y er uavhengige, er $\text{cov}(X, Y) = 0$
- Omvendt gjelder ikke nødvendigvis!
- Men:
- Hvis (X, Y) er bivariat normalfordelt og $\text{cov}(X, Y) = 0$, så er X og Y uavhengige.

7

Kovarians og korrelasjon


Problem med enhetene ...

- Hvis X og Y måler hhv. FEV (l) og høyde (m) får kovariansen enheten l*m (sml. med definisjon og enhet for varians)
- Løser dette ved å dividere med standardavvikene til X og Y


$$\text{Corr}(X, Y) = \rho = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y}$$

$$\rho \in (-1, 1)$$

8



9



10

Kovarians beregnet fra et utvalg
- empirisk kovarians:

Utvalgs-kovarians:

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

11


Korrelasjon beregnet fra et utvalg
- empirisk korrelasjon:
Pearson's r

$$r = \frac{s_{xy}}{s_x s_y}$$

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


12

Eksempel: Fig. 5.16a




13

Eksempel: Fig. 5.16b




14

Eksempel: Fig. 5.16c



15

Eksempel: Fig. 5.16d



16

Noen egenskaper til korrelasjonen

- $-1 \leq r \leq 1$
- $r=1$ hvis og bare hvis alle observasjonene ligger langs en linje med **postivt** stigningstall
- $r=-1$ hvis og bare hvis alle observasjonene ligger langs en linje med **negativt** stigningstall


17

Korrelasjon - eksempel

	vektog	vektkg	alder	sbt	
1	135,00	3,83	3,00	89,00	
2	120,00	3,40	4,00	90,00	
3	100,00	2,84	3,00	83,00	
4	105,00	2,98	2,00	77,00	
5	130,00	3,69	4,00	92,00	
6	125,00	3,54	5,00	98,00	
7	125,00	3,54	2,00	82,00	
8	105,00	2,98	3,00	85,00	
9	120,00	3,40	5,00	96,00	
10	90,00	2,55	4,00	95,00	
11	120,00	3,40	2,00	80,00	
12	95,00	2,69	3,00	79,00	
13	120,00	3,40	3,00	86,00	
14	150,00	4,25	4,00	97,00	
15	160,00	4,54	3,00	92,00	
16	125,00	3,54	3,00	88,00	
17					

Rosner
Table 11.9
s 511
(5th ed
table 11.7,
s. 468)

18



19

Korrelasjonsanalyse - bruk

- Screene "store mengder" data for sammenhenger - hva henger sammen med hva?
- Før inklusjon av prediktor-variable i evt. multipl regressjonsmodell - hvilke variable måler omtrent det samme?
- Alminnelig i psykologisk forskning - (spørreskjema f.eks.) hvilke egenskaper er korrelert?
→ *faktor-analyse, prinsipal komponent-analyse*

20

Korrelasjonsanalyse - misbruk

Bland, J. M , Altman, D. G.:
Statistical methods for assessing agreement
between two methods of clinical measurements
The Lancet, 8 Febr 1986, p 307-310

(Sitert 13143 ganger ISI 23 februar 2009)

21

Ikke-paramterisk korrelasjonskoeffisient

- Kan være å foretrekke når:
 - Sammenhengen er ikke-lineær
 - Data er ordinale (kvalitative)
 - Ved avvik fra normalfordelingen(?)
- Alternativer:
 - Spearman's rho
 - Kendall's tau
 - Liten forskjell på dem, men kanskje en viss preferanse for Kendall's tau.

22

"Our results suggest that Kendall's tau, has many advantages over Pearson's and Spearman's r; when applied to psychiatric data, tau, maintained adequate control of type I errors, was nearly as powerful as Pearson's r, provided much tighter confidence intervals and had a clear interpretation."

Arndt S, Turvey C, Andreasen NC: Correlating and predicting psychiatric symptom ratings: Spearman's r versus Kendall's tau correlation. *JOURNAL OF PSYCHIATRIC RESEARCH* Volume: 33 Issue: 2 Pages: 97-104, 1999

23

Denne, derimot, skriver at begge er ganske bra:

Kraemer HC: Correlation coefficients in medical research: from product moment correlation to the odds ratio. *STATISTICAL METHODS IN MEDICAL RESEARCH* Volume: 15 Issue: 6 Pages: 525-545, 2006

24

Rang-korrelasjon, Spearman's r_s

- Observasjonene ordnes i stigende rekkefølge
- Regn ut Pearson's korrelasjonskoeffisient for rangene (i)

Transformasjon :

$$X_i \xrightarrow{\text{ordnes}} X_{(i)}$$

25

T-test for korrelasjonskoeffisient

(Rosner Eq. 11.20)

- Beregn Pearson's r
- Transformer denne til T :

$$T_{n-1} = \frac{\bar{r} - \mu}{\frac{s}{\sqrt{n}}} \dots \text{og i dette tilfelle}$$

$$T_{n-2} = \frac{r-0}{\frac{\sqrt{1-r^2}}{\sqrt{n-2}}} = \frac{r}{\frac{\sqrt{1-r^2}}{\sqrt{n-2}}} = \frac{r(\sqrt{n-2})}{\sqrt{1-r^2}}$$

26

Z-test for korrelasjonskoeffisient

(Rosner Eq. 11.21 – 11.22)

- Beregn Pearson's r
- Fisher's z-transformasjon gir en tilnærmet normalfordelt variabel, Z :

$$Z = \frac{1}{2} \ln \left(\frac{1+r}{1-r} \right)$$

Under H_0 ($\rho = \rho_0$) har Z forventningsverdi og varians

$$E(Z_0) = \frac{1}{2} \ln \left(\frac{1+\rho_0}{1-\rho_0} \right)$$

$$\text{Var}(Z_0) = \frac{1}{n-3}$$

27

Konfidensintervall for ρ

- (Rosner eq. 11.23)
- Utregnet Pearson's r_0 fra et utvalg med n observasjoner, bruker Fisher's Z -transformasjon

$$z_0 = \frac{1}{2} \ln \left(\frac{1+r_0}{1-r_0} \right)$$

$$95 \% \text{ CI for } Z = (z_1, z_2) = z_0 \pm \frac{z_{1-\frac{\alpha}{2}}}{\sqrt{n-3}}$$

$$95 \% \text{ CI for } \rho = (\rho_1, \rho_2) = \left(\frac{e^{2z_1} - 1}{e^{2z_1} + 1}, \frac{e^{2z_2} - 1}{e^{2z_2} + 1} \right)$$

28

Sammenlikning av to uavhengige korrelasjonskoeffisienter:
Fisher's z-test (Eqn 11.27)

$$H_0: \rho_1 = \rho_2 \text{ versus } \rho_1 \neq \rho_2$$

Under H_0 så gjelder tilnærmet

$$\frac{Z_1 - Z_2}{\sqrt{\frac{1}{n_1 - 3} + \frac{1}{n_2 - 3}}} \sim N(0,1)$$

29

Sammenlikning av to avhengige korrelasjonskoeffisienter

$$H_0: \rho_{XZ} = \rho_{YZ} \text{ versus } \rho_{XZ} \neq \rho_{YZ}$$

Wolfe's test (Rosner Eqn 11.28) forutsetter bl.a. $\sigma_X = \sigma_Y$.

Bedre:

En metode basert på Fisher's z-transformasjon, se

Meng, X. L., Rosenthal, R., Rubin, D. B.:
Comparing correlated correlation coefficients.
Psychological bulletin, 1992, Vol 111, No 1, p 172-175.
(Referert 562 ganger ISI 16 februar 2009)

30

To sum up, the z test in Equation 11.22 is used to test hypotheses about nonzero null correlations, whereas the t test in Equation 11.20 is used to test hypotheses about null correlations of zero. The z test can also be used to test correlations of zero under the null hypotheses, but the t test is slightly more powerful in this case and is preferred. However, if $\rho_0 \neq 0$, then the one sample z test is very sensitive to non-normality of either x or y. This is also true for the two sample correlation test presented later in this section.

Rosner (6th ed) s 501

Noen sammenhenger i enkel lineær regresjon:

- Hypotesen $\beta = 0$ er ekvivalent med $\rho = 0$. En F-test (eller t-test) for $\beta = 0$ er ekvivalent med en t-test for $\rho = 0$
- $b = r s_y/s_x$
- r^2 dvs. "coefficient of determination" tolkes best i regresjon som andelen "forklart varians"

Intraclass correlation coefficient (ICC)
(Rosner 6th ed: 12.9, page 613-617)
Correlation between two measurements in the same subjects (or clusters).

One-way random effects ANOVA:
Measurement number j at subject (or cluster) number i:

$$y_{ij} = \mu + \alpha_i + \varepsilon_{ij}, \quad \alpha_i \sim N(0, \sigma_A^2), \quad \varepsilon_i \sim N(0, \sigma^2)$$

$$ICC = \frac{\sigma_A^2}{\sigma_A^2 + \sigma^2}$$

Between cluster variance

Within cluster variance

Total variance