

Formelsamling i medisinsk statistikk

Dette er formelsamling til O. O. Aalen: Innføring i statistikk med medisinske eksempler, 2. utg., Ad Notam Gyldendal, 1998. Formelsamlingen er utarbeidet i okt. 2000, med små endringer i okt. 2001.

På s. 7 er det også gitt noen *rettelser* til boken.

Gjennomsnitt

$$\bar{x} = \frac{1}{n}(x_1 + x_2 + x_3 + \cdots + x_n)$$

Median

Alle observasjoner ordnes i stigende rekkefølge. Ved *ulike* antall observasjoner, er medianen definert som den midterste av dem. Ved *like* antall, er medianen definert som gjennomsnittet av de to midterste.

Standardavvik

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

Grupperte data

Intervallmidtpunkter m_1, m_2, \dots, m_k . Hyppigheter f_1, f_2, \dots, f_k . Totalt antall observasjoner: n . Gjennomsnitt og standardavvik er gitt ved:

$$\bar{x} = \frac{1}{n}(m_1 f_1 + m_2 f_2 + \cdots + m_k f_k) = \frac{1}{n} \sum_{j=1}^k m_j f_j$$

$$s = \sqrt{\frac{1}{n-1} \left\{ \sum_{j=1}^k (m_j - \bar{x})^2 f_j \right\}}$$

Median og fraktiler for grupperte data finnes ved lineær interpolasjon.

Insidens og prevalens

Prevalens angir andelen i befolkningen som har en viss sykdom.

Insidensraten måler forekomsten av *nye* tilfeller av sykdommen over et gitt tidsrom.

Regneregler for sannsynlighet

Hvis begivenhetene A og B er disjunkte has

$$P(A \cup B) = P(A) + P(B)$$

For alle begivenheter A og B has

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

Definisjon av *betinget sannsynlighet*

$$P(A | B) = \frac{P(A \cap B)}{P(B)}$$

Begivenhetene A og B er *uavhengige* hvis

$$P(A \cap B) = P(A) \cdot P(B)$$

En tilsvarende produktregel er gyldig om vi har flere uavhengige begivenheter.

Regelen om *total sannsynlighet*

$$P(A) = P(A | B) \cdot P(B) + P(A | \bar{B}) \cdot P(\bar{B})$$

Bayes' lov

$$P(B | A) = \frac{P(B)P(A | B)}{P(B)P(A | B) + P(\bar{B})P(A | \bar{B})}$$

Diagnostiske tester

Sensitivitet: Sannsynlighet for positiv test gitt sykdom.

Spesifisitet: Sannsynlighet for negativ test gitt at det ikke foreligger sykdom.

Positiv prediktiv verdi: Sannsynlighet for at det foreligger sykdom gitt positiv test.

Negativ prediktiv verdi: Sannsynlighet for at det ikke foreligger sykdom gitt negativ test.

Kombinatorikk

Trekning av s kuler fra en boks med n kuler.

Antall *ordnede* utvalg *med tilbakelegging*

$$n^s$$

Antall *ordnede* utvalg *uten tilbakelegging*

$$n(n-1)(n-2) \cdots (n-s+1)$$

Antall *ikke-ordnede* utvalg *uten tilbakelegging*

$$\binom{n}{s} = \frac{n(n-1)(n-2) \cdots (n-s+1)}{s!}$$

Forventning og varians for teoretisk fordeling

$$E(X) = \sum_{\text{alle } x_i} x_i P(X = x_i)$$
$$\text{Var}(X) = \sum_{\text{alle } x_i} (x_i - E(X))^2 P(X = x_i)$$

Regneregler for forventning og varians

$$E(aX + b) = aE(X) + b,$$
$$\text{Var}(aX + b) = a^2 \text{Var}(X), \quad \text{SD}(aX + b) = |a| \text{SD}(X)$$
$$E(X_1 + X_2 + \dots + X_n) = E(X_1) + E(X_2) + \dots + E(X_n)$$

Hvis X_1, X_2, \dots, X_n er parvis *stokastisk uavhengige* has:

$$\text{Var}(X_1 + X_2 + \dots + X_n) = \text{Var}(X_1) + \text{Var}(X_2) + \dots + \text{Var}(X_n)$$

Binomisk fordeling

Sannsynligheten for at en begivenhet A inntreffer x ganger i løpet av n binomiske forsøk, er

$$P(X = x) = \binom{n}{x} p^x (1-p)^{n-x}, \quad x = 0, 1, \dots, n$$

Forventning og varians i binomisk fordeling er gitt ved:

$$E(X) = np, \quad \text{Var}(X) = np(1-p)$$

Poissonfordeling

Sannsynligheten for x forekomster, når forventning er lik λ , er gitt ved:

$$P(X = x) = \frac{\lambda^x e^{-\lambda}}{x!} \quad \text{for } x = 0, 1, 2, \dots$$

Forventning og varians er gitt ved:

$$E(X) = \lambda \quad \text{og} \quad \text{Var}(X) = \lambda$$

Poissonfordelingen anvendes også ved Poissonprosesser.

Normalfordeling

En stokastisk variabel X sies å være normal (μ, σ) hvis den følger en normalfordeling med forventning (sentrum) μ og standardavvik (spredning) σ . Den standardiserte variable $Y = (X - \mu)/\sigma$ er normal $(0,1)$. Sannsynlighetstettheten til normalfordelingen er gitt ved følgende formel:

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

der $\exp(a)$ er det samme som eksponentialfunksjonen e^a .

Formler for gjennomsnitt

La \bar{X} være gjennomsnittet av de uavhengige variablene X_1, X_2, \dots, X_n . Da gjelder:

$$E(\bar{X}) = \mu, \quad \text{Var}(\bar{X}) = \frac{\sigma^2}{n}, \quad \text{SD}(\bar{X}) = \frac{\sigma}{\sqrt{n}}, \quad s_{\bar{X}} = \frac{s}{\sqrt{n}}$$

Hvis variablene også er normalfordelte, vil et konfidensintervall være gitt ved

$$\bar{X} \pm c s_{\bar{X}}$$

der c bestemmes ut fra Studentfordelingen med $n - 1$ frihetsgrader.

En teststørrelse er gitt ved

$$t = \frac{\bar{X} - \mu}{s_{\bar{X}}} = \frac{\bar{X} - \mu}{s} \sqrt{n}$$

og denne er Studentfordelt med $n - 1$ frihetsgrader når H_0 gjelder.

Sammenlikning av to gjennomsnitt

Samme forutsetninger som over. Forøvrig antas gjennomsnittene å komme fra to uavhengige utvalg. Følgende teststørrelse er Studentfordelt med $n_1 + n_2 - 2$ frihetsgrader når H_0 gjelder

$$t = \frac{\bar{X}_1 - \bar{X}_2}{s_f \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}}$$

der s_f er definert ved

$$s_f = \sqrt{\frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}}$$

Et konfidensintervall er gitt ved

$$\bar{X}_1 - \bar{X}_2 \pm c s_f \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

der c er bestemt av Studentfordelingen med $n_1 + n_2 - 2$ frihetsgrader.

Poissonfordeling som tilnærming til binomisk fordeling

Binomisk fordeling kan tilnærmes med en Poissonfordeling hvis:

$$(1) \quad p \leq 0.05 \quad \text{og} \quad (2) \quad n \geq 50$$

Normalfordeling som tilnærming til binomisk fordeling

Når n i en binomisk fordeling er så stor at $np \geq 5$ og $n(1-p) \geq 5$, vil den binomiske fordelingen likne mye på en normalfordeling med parametre

$$\mu = np, \quad \sigma = \sqrt{np(1-p)}$$

Normalfordeling som tilnærming til Poissonfordeling

Når λ i en Poissonfordeling er minst lik 5, vil Poissonfordelingen likne mye på en normalfordeling med parametre

$$\mu = \lambda, \quad \sigma = \sqrt{\lambda}$$

Estimering av sannsynlighet

Hvis det er observert X forekomster ved n binomiske forsøk, er estimatet for sannsynligheten p gitt ved p^* , mens estimert standardfeil er gitt ved s_p

$$p^* = X/n, \quad s_p = \sqrt{\frac{p^*(1-p^*)}{n}}$$

Fordelingen til p^* er tilnærmet normalfordelt under de samme forutsetninger som for binomisk fordeling, med $\mu = p$ og $\sigma = \sqrt{\frac{p(1-p)}{n}}$.
Et 95% konfidensintervall for p^* er gitt ved

$$p^* \pm 2s_p$$

Teststørrelse for sammenlikning av to sannsynligheter

$$Y = \frac{p_1^* - p_2^*}{\sqrt{(\frac{1}{n_1} + \frac{1}{n_2})\bar{p}(1-\bar{p})}}$$

Teststørrelse for sammenlikning av to Poissonvariabler

$$Y = \frac{X_1 - X_2}{\sqrt{X_1 + X_2}}$$

Konfidensintervall for relativ risiko

Relativ risiko:

$$RR = \frac{X_1/n_1}{X_2/n_2}$$

Hjelpstørrelse:

$$s_{RR} = \sqrt{\frac{1}{X_1} + \frac{1}{X_2} - \frac{1}{n_1} - \frac{1}{n_2}}$$

95% konfidensintervall for RR :

$$(RR \times \exp(-1.96 s_{RR}), RR \times \exp(1.96 s_{RR}))$$

Regresjonsanalyse

Helningskoeffisienten, b , og skjæringspunktet med y -aksen, a , for minste-kvadraterslinjen er gitt ved

$$\hat{b} = s_{xy}/s_x^2, \quad \hat{a} = \bar{y} - \hat{b}\bar{x}$$

der s_x og s_y er standardavvikene til henholdsvis x - og y -verdiene, mens s_{xy} er definert ved

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

Minste kvadratsum er gitt ved

$$\text{rest} = \sum_{i=1}^n (y_i - \hat{a} - \hat{b}x_i)^2 = (n-1)(s_y^2 - \hat{b}s_{xy})$$

Standardavvik som måler variasjonen i punktene rundt den beste linjen:

$$s_{\text{reg}} = \sqrt{\frac{\text{rest}}{n-2}}$$

Konfidensintervall for \hat{b} bestemmes ut fra formelen:

$$\hat{b} \pm c \frac{s_{\text{reg}}}{\sqrt{(n-1)s_x^2}}$$

der c bestemmes ut fra en studentfordeling med $n-2$ frihetsgrader.

Korrelasjon

Korrelasjonskoeffisienten er definert på følgende måte:

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

Bestemmelse av forsøksstørrelse

Størrelse på et binomisk forsøk for å oppnå en sikkerhet på a i estimatet for sannsynligheten:

$$n = \frac{4p(1-p)}{a^2}$$

Størrelse på et forsøk med måledata for å oppnå en sikkerhet på a i gjennomsnittet:

$$n = 4(\sigma/a)^2$$

Antallet som kreves i hver gruppe når to binomiske sannsynligheter skal sammenliknes med signifikansnivå α og teststyrke $1 - \beta$:

$$n = \frac{p_1(1 - p_1) + p_2(1 - p_2)}{(p_2 - p_1)^2} \times f(\alpha, \beta)$$

Antallet som kreves i hver gruppe når to gjennomsnitt skal sammenliknes med signifikansnivå α og teststyrke $1 - \beta$:

$$n = 2(\sigma/\Delta)^2 \times f(\alpha, \beta)$$

Størrelsen $f(\alpha, \beta)$ er definert i tabellen nedenfor.

		β (type II feil)			
		0.05	0.10	0.20	0.50
α (type I feil)	0.10	10.8	8.6	6.2	2.7
	0.05	13.0	10.5	7.9	3.8
	0.02	15.8	13.0	10.0	5.4
	0.01	17.8	14.9	11.7	6.6

Tallene i tabellen er hentet fra Pocock (1983).

Table 1: *Tabell over funksjonen $f(\alpha, \beta)$*

Rettelser til boken

Nedenfor er det gitt noen rettelser til O. O. Aalen: Innføring i statistikk med medisinske eksempler, 2. utg., Ad Notam Gyldendal, 1998.

- side 114, linje 6: Følgende passus fjernes: "(dvs. en hvert fjerde år)"
- side 147, linje 4: Ordet "pleierne" erstattes med "graviditetene"
- side 147, siste linje: Tallet 6.09 erstattes med 4.14
- side 283, siste linje: Det skal stå 0.06%
- side 285, tabell: Tallet 167 skal erstattes med 197
- side 302, fasit til B76: Tallet -1.46 skal erstattes med -1.47