

SF1901: Sannolikhetslära och statistik

Föreläsning 5.

Flera stokastiska variabler.

Jan Grandell & Timo Koski

31.01.2012



Flerdimensionella stokastiska variabler

Ofta mäter vi i samma slumpförsök flera storheter, och då beskrivs resultatet av en n -dimensionell stokastisk variabel (X_1, X_2, \dots, X_n) .

Exempel

Slumpförsöket är att vi väljer en person slumpmässigt här i rummet, och sätter

X = personens vikt;

Y = personens längd.

Vi nöjer oss med att ge detaljer i det två-dimensionella fallet. Låt (X, Y) vara en två-dimensionell s.v.

$F_{X,Y}(x, y) = P(X \leq x, Y \leq y)$ kallas (den simultana) fördelningsfunktionen för (X, Y) .

$F_X(x) = P(X \leq x) = P(X \leq x, Y \leq \infty) = F_{X,Y}(x, \infty)$ kallas den marginella fördelningsfunktionen för X .

$F_Y(y) = F_{X,Y}(\infty, y)$ kallas den marginella fördelningsfunktionen för Y .



Definition

X och Y är oberoende stokastiska variabler om

$$F_{X,Y}(x,y) = F_X(x)F_Y(y)$$

obs! Detta bör gälla för ALLA (x,y) .



Definition

(X_1, X_2, \dots, X_n) är oberoende stokastiska variabler om

$$\begin{aligned} F_{X_1, \dots, X_n}(x_1, \dots, x_n) &= P(X_1 \leq x_1, \dots, X_n \leq x_n) \\ &= F_{X_1}(x_1) \cdots F_{X_n}(x_n). \end{aligned}$$

Omvänt gäller att om X_1, X_2, \dots, X_n är oberoende s.v. så fås den simultana fördelningen enl. definitionen ovan.



KTH Matematik

Simultan sannolikhetsfunktion

(X, Y) är en diskret två-dimensionell s.v., om

$$F_{X,Y}(x, y) = \sum_{0 \leq j \leq [x]} \sum_{0 \leq k \leq [y]} p_{X,Y}(j, k) du dv$$

där

$$\sum_{j=0}^{\infty} \sum_{k=0}^{\infty} p_{X,Y}(j, k) = 1, \quad p_{X,Y}(j, k) \geq 0.$$

Funktionen $p_{X,Y}(i, k)$ kallas den simultana sannolikhetsfunktionen för (X, Y) .



Simultan tähet

(X, Y) är en kontinuerlig två-dimensionell s.v., om

$$F_{X,Y}(x,y) = \int_{-\infty}^x \int_{-\infty}^y f_{X,Y}(u,v) du dv$$

där

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f_{X,Y}(x,y) dx dy = 1, \quad f_{X,Y}(x,y) \geq 0.$$

Funktionen $f_{X,Y}(x,y)$ kallas den simultana täthetsfunktionen för (X, Y) .



Marginalfördelningar fört kontinuerliga s.v.er

Låt (X, Y) vara en kontinuerlig två-dimensionell s.v.. Den marginella fördelningsfunktionen för Y är

$$F_Y(y) = F_{X,Y}(\infty, y) = \int_{-\infty}^y \int_{-\infty}^{\infty} f_{X,Y}(x, v) dx dv$$

och

$$f_Y(y) = \frac{d}{dy} F_Y(y) = \int_{-\infty}^{\infty} f_{X,Y}(x, y) dx$$

är den marginella täthetsfunktionen för Y . Analogt är

$$f_X(x) = \frac{d}{dx} F_X(x) = \int_{-\infty}^{\infty} f_{X,Y}(x, y) dy$$

den marginella täthetsfunktionen för X .



Oberoende stokastiska variabler

Definition

X och Y är oberoende stokastiska variabler om

$$f_{X,Y}(x,y) = f_X(x)f_Y(y)$$



Normalfördelade stokastiska variabler


$X \in N(0, 1)$, $Y \in N(0, 1)$

$$\varphi_X(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$$


$$\varphi_Y(y) = \frac{1}{\sqrt{2\pi}} e^{-y^2/2}$$

$$\varphi_X(x) \cdot \varphi_Y(y) = \frac{1}{2\pi} e^{-(x^2+y^2)/2}$$

Produkten $\varphi_X(x) \cdot \varphi_Y(y)$



$X \in \text{Exp}(2)$, $Y \in \text{Exp}(2)$, oberoende



Väntevärdet av $g(X, Y)$

Sats

Låt (X, Y) vara en tvådimensionell s.v. Då gäller

$$E[g(X, Y)] = \begin{cases} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) f_{X,Y}(x, y) dx dy & \text{för } (X, Y) \text{ kontinuerlig,} \\ \sum_{k=0}^{\infty} \sum_{j=0}^{\infty} g(k, j) f_{X,Y}(k, j) & \text{för } (X, Y) \text{ diskret.} \end{cases}$$



Väntevärdet av $g(X, Y) = X + Y$

Sats

Låt (X, Y) vara en tvådimensionell s.v. Då gäller

$$E[X + Y] = E[X] + E[Y]$$

Bevis. Låt (X, Y) vara en kontinuerlig tvådimensionell s.v.. Den föregående satsen visar med $g(x, y) = x + y$ att

$$\begin{aligned} & \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x + y) f_{X,Y}(x, y) dx dy = \\ & \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} xf_{X,Y}(x, y) dx dy + \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} yf_{X,Y}(x, y) dx dy \\ &= \int_{-\infty}^{\infty} x \int_{-\infty}^{\infty} f_{X,Y}(x, y) dy dx + \int_{-\infty}^{\infty} y \int_{-\infty}^{\infty} f_{X,Y}(x, y) dx dy \\ &= \int_{-\infty}^{\infty} xf_X(x) dx + \int_{-\infty}^{\infty} yf_Y(y) dy = E[X] + E[Y] \end{aligned}$$



KTH Matematik

Kovarians och korrelationskoefficient

Låt (X, Y) vara en tvådimensionell s.v. där vi är intresserade av sambandet mellan X s och Y s variation. Det kan vara naturligt att betrakta variablerna

$$X - \mu_X \quad \text{och} \quad Y - \mu_Y.$$

Vi skiljer på fallen då X och Y "samvarierar" resp. "motverkar varandra", dvs. då

ett stort/litet värde på X gör ett stort/litet värde på Y troligt
resp.

ett stort/litet värde på X gör ett litet/stort värde på Y troligt.



Kovariansen mellan X och Y

Betraktar vi nu variabeln

$$(X - \mu_X)(Y - \mu_Y),$$

så innebär detta att den i första fallet, eftersom $+ \cdot + = +$ och $- \cdot - = +$, att den har en tendens att vara positiv. På motsvarande sätt, eftersom $- \cdot + = -$ och $+ \cdot - = -$, har den i andra fallet en tendens att vara negativ. Det som vi, lite slarvigt, har kallat tendens, kan vi ersätta med väntevärde. Vi leds då till följande definition.

Definition

Kovariansen mellan X och Y är

$$C(X, Y) = E[(X - \mu_X)(Y - \mu_Y)],$$

där $\mu_X = E(X)$ och $\mu_Y = E(Y)$.

Kovariansen mellan X och Y

Sats

Kovariansen mellan X och Y är

$$C(X, Y) = E[XY] - \mu_X \cdot \mu_Y,$$

där $\mu_X = E(X)$ och $\mu_Y = E(Y)$.

Bevis. :

$$C(X, Y) = E[(X - \mu_X)(Y - \mu_Y)] = E[XY - X\mu_Y - \mu_X Y + \mu_X \mu_Y]$$

$$= E[XY] - E[X\mu_Y] - E[\mu_X Y] + \mu_X \mu_Y$$

$$= E[XY] - \mu_Y E[X] - \mu_X E[Y] + \mu_X \mu_Y = E[XY] - \mu_Y \mu_X - \mu_X \mu_Y + \mu_X \mu_Y$$

$$= E[XY] - \mu_Y \mu_X$$



Kovariansen mellan oberoende X och Y

Sats

Om X och Y är oberoende, så

$$C(X, Y) = 0.$$

Bevis. : Vi tittar på $C(X, Y) = E[XY] - \mu_X \cdot \mu_Y$. Låt oss betrakta det kontinuerliga fallet. Med funktionen $g(x, y) = x \cdot y$ får vi

$$E[XY] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x \cdot y f_{X,Y}(x, y) dx dy$$

och antagandet om oberoende, $f_{X,Y}(x, y) = f_X(x)f_Y(y)$, ger

$$= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x \cdot y f_X(x)f_Y(y) dx dy = \int_{-\infty}^{\infty} x f_X(x) dx \int_{-\infty}^{\infty} y f_Y(y) dy = \mu_X \cdot \mu_Y.$$



Korrelationskoefficienten mellan X och Y

Kovariansen kan sägas ha fel sort. Det verkar rimligt att ett mått på ett så abstrakt begrepp som samvariation skall vara "sortfritt". Det vanligaste måttet är korrelationskoefficienten.

Definition

Korrelationskoefficienten mellan X och Y är

$$\rho = \rho(X, Y) = \frac{C(X, Y)}{D(X)D(Y)}.$$

Man kan visa att $|\rho| \leq 1$, där $\rho = \pm 1$ betyder att det finns ett perfekt linjärt samband, dvs. $Y = aX + b$.

Sats

Om X och Y är oberoende så är de okorrelerade, dvs. $\rho(X, Y) = 0$.

Omvändningen gäller ej, dvs. okorrelerade variabler kan vara beroende.

Exempel

Den simultana sannolikhetsfunktionen för stokastiska variablerna X och Y med $p_{X,Y}(j,k)$

X / Y	0	1	2	3
0	0.2	0	0	0
1	0	0.1	0.1	0
2	0	0.1	0.1	0
3	0	0	0	0.4

- Marginalfördelning för X :

$$p_X(0) = 0.2 + 0 + 0 + 0 = 0.2,$$

$$p_X(1) = 0 + 0.1 + 0.1 + 0 = 0.2$$

$$p_X(2) = 0 + 0.1 + 0.1 + 0 = 0.2,$$

$$p_X(3) = 0 + 0 + 0 + 0.4 = 0.4$$



Exempel (forts.)

- På samma sätt får marginalfördelning för Y :

$$p_Y(0) = 0.2, p_Y(1) = 0.2$$

$$p_Y(2) = 0.2, p_Y(3) = 0.4.$$

- X och Y är INTE oberoende, ty, t.ex.,

$$p_X(0) \cdot p_Y(0) = 0.2 \cdot 0.2 = 0.04 \neq 0.2 = p_{X,Y}(0,0)$$



Exempel (forts.):

$$E(X) = 0 \cdot 0.2 + 1 \cdot 0.2 + 2 \cdot 0.2 + 3 \cdot 0.4 = 1.8.$$

samt

$$E(Y) = 1.8.$$

$$E(X^2) = 0^2 \cdot 0.2 + 1^2 \cdot 0.2 + 2^2 \cdot 0.2 + 3^2 \cdot 0.4 = 4.6.$$

$$V(X) = E(X^2) - E(X)^2 = 4.6 - 1.8^2 = 1.36 = V(Y).$$



Exempel (forts.): Kovarians och korrelation

-

$$E(X \cdot Y) = 0 \cdot 0 \cdot 0.2 + 1 \cdot 1 \cdot 0.1$$

$$+ 1 \cdot 2 \cdot 0.1 + 2 \cdot 1 \cdot 0.1 + 2 \cdot 2 \cdot 0.1 + 3 \cdot 3 \cdot 0.4 = 4.5$$

- Kovariansen

$$C(X, Y) = E(X \cdot Y) - E(X) E(Y) = 4.5 - 1.8 \cdot 1.8 = 1.26$$

- Korrelationskoefficienten

$$\begin{aligned}\rho(X, Y) &= \frac{C(X, Y)}{\sqrt{V(X)} \sqrt{V(Y)}} = \frac{1.26}{\sqrt{1.36} \sqrt{1.36}} \\ &= \frac{1.26}{1.36} = 0.926.\end{aligned}$$

Vad säger detta ?

Sats

Låt (X, Y) vara en tvådimensionell s.v. Då gäller

$$(1) \quad E(aX + bY) = aE(X) + bE(Y);$$

$$(2) \quad V(aX + bY) = a^2V(X) + b^2V(Y) + 2abC(X, Y).$$

Bevis. (1) har visats ovan.



Mer om väntevärden: Bevis av (2)

(2) fås av följande

$$\begin{aligned} V(aX + bY) &= E[(aX + bY - a\mu_X - b\mu_Y)^2] = E[(aX - a\mu_X + bY - b\mu_Y)^2] \\ &= E[a^2(X - \mu_X)^2 + b^2(Y - \mu_Y)^2 + 2ab(X - \mu_X)(Y - \mu_Y)] \\ &= a^2V(X) + b^2V(Y) + 2abC(X, Y). \end{aligned}$$



Följdsats

Låt X och Y vara två oberoende (okorrelerade räcker) s.v. Då gäller

$$E(X + Y) = E(X) + E(Y) \quad V(X + Y) = V(X) + V(Y)$$

$$E(X - Y) = E(X) - E(Y) \quad V(X - Y) = V(X) + V(Y).$$



Mer om väntevärden

Detta går att utvidga till godtyckligt många variabler:

Sats

Låt X_1, \dots, X_n vara oberoende (okorrelerade räcker) s.v. och sätt

$$Y = c_1 X_1 + \dots + c_n X_n.$$

Då gäller

$$E(Y) = c_1 E(X_1) + \dots + c_n E(X_n)$$

och

$$V(Y) = c_1^2 V(X_1) + \dots + c_n^2 V(X_n)$$



Aritmetiskt medelvärde

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

Sats

Låt X_1, X_2, \dots, X_n vara oberoende och likafördelade s.v. med väntevärde μ och standardavvikelse σ . Då gäller att

$$E(\bar{X}) = \mu, \quad V(\bar{X}) = \frac{\sigma^2}{n} \quad \text{och} \quad D(\bar{X}) = \frac{\sigma}{\sqrt{n}}.$$

Uttrycket " X_1, X_2, \dots, X_n är likafördelade" betyder att de stokastiska variablernas fördelningar, dvs. att de stokastiska variablernas *statistiska egenskaper*, är identiska. *Utfallen* av variablerna varierar dock.



Stora talens lag

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

Sats

Stora talens lag *För varje $\varepsilon > 0$ gäller*

$$P(|\bar{X} - \mu| > \varepsilon) \rightarrow 0 \quad \text{då } n \rightarrow \infty.$$

Bevis. Enl. Tjebysjovs olikhet gäller

$$P(|\bar{X} - \mu| > \varepsilon) \leq \frac{V(\bar{X})}{\varepsilon^2} = \frac{\sigma^2}{n\varepsilon^2} \rightarrow 0$$

då $n \rightarrow \infty$.



Summans fördelning

Låt X och Y vara två oberoende kontinuerliga stokastiska variabler med tätheter $f_X(x)$ och $f_Y(y)$.

Sätt $Z = X + Y$. Då gäller

$$F_Z(z) = P(X + Y \leq z) = P((X, Y) \in \{(x, y); x + y \leq z\})$$

$$= \int_{x+y \leq z} f_X(x)f_Y(y) dx dy$$

(fixera x och integrera över y)

$$= \int_{-\infty}^{\infty} f_X(x) \left(\int_{-\infty}^{z-x} f_Y(y) dy \right) dx$$

$$= \int_{-\infty}^{\infty} f_X(x) F_Y(z - x) dx.$$



Summans fördelning

Z är också en kontinuerlig stokastisk variabel. Derivation map. z ger

$$f_Z(z) = F'_Z(z) = \int_{-\infty}^{\infty} f_X(x)f_Y(z-x) dx.$$

Denna operation kallas *fältnings*.

