

STK1100 våren 2023

Forventning, kovarians og korrelasjon

Svarer til avsnitt 5.2 i læreboka

Matematisk institutt
Universitetet i Oslo

Forventningsverdi

La X og Y være diskrete stokastiske variabler med simultan punktsannsynlighet $p(x,y)$ og la $h(x,y)$ være en reell funksjon. Da er

$$E[h(X,Y)] = \sum_x \sum_y h(x,y) \cdot p(x,y)$$

Hvis X og Y er kontinuerlige stokastiske variabler med simultan synlighetstetthet , $f(x,y)$ så har vi

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

Eksempel – Fordeling av karakterer

La X være karakteren i norsk og Y karakteren i matematikk for en tilfeldig valgt elev

Punktsannsynligheten $p(x,y)$ er gitt ved tabellen
(sannsynlighetene er gitt som prosent)

$y \backslash x$	1	2	3	4	5	6
1	1	4	5	3	-	-
2	1	4	11	6	-	-
3	1	4	8	8	2	-
4	-	3	7	6	4	-
5	-	1	3	6	5	1
6	-	-	1	2	2	1

Hva er forventet forskjell i karakterene i norsk
og matematikk?

Vi er interessert i forskjellen på karakterene i norsk og matematikk, dvs $h(X, Y) = |X - Y|$

Vi finner (se kommandoer på neste slide)

$$\begin{aligned} E\{|X - Y|\} &= \sum_x \sum_y |x - y| \cdot p(x, y) \\ &= |1 - 1| \cdot p(1, 1) + |2 - 1| \cdot p(2, 1) + \dots + |6 - 6| \cdot p(6, 6) \\ &= 0 \cdot 0.01 + 1 \cdot 0.04 + \dots + 0 \cdot 0.01 = 1.07 \end{aligned}$$

Tilsvarende finner vi

$$E(X) = 3.41 \quad E(Y) = 3.22$$

Merk at vi også kan finne $E(X)$ og $E(Y)$ av de marginale punktsannsynlighetene

Kommandoer for å beregne forventningsverdiene på forrige slide

Python

```
import numpy as np
import scipy.stats as stats
import math
tmp = np.arange(1,7)
x = np.tile(tmp,(6,1))
y = x.transpose()
pxy =np.array([[0.01,0.04,0.05,0.03,0.0,0.0],
               [0.01,0.04,0.11,0.06,0.0,0.0],
               [0.01,0.04,0.08,0.08,0.02,0.0],
               [0.0,0.03,0.07,0.06,0.04,0.0],
               [0.0,0.01,0.03,0.06,0.05,0.01],
               [0.0,0.0,0.01,0.02,0.02,0.01]])
sum(sum(abs(x-y)*pxy))
```

Regneregel for forventning

La X og Y være to stokastiske variabler
(diskrete eller kontinuerlige)


Da har vi (regner for kontinuerlig)

$$\begin{aligned} E(aX + bY + c) &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (ax + by + c) \cdot f(x, y) dx dy \\ &= a \int_{-\infty}^{\infty} x \left[\int_{-\infty}^{\infty} f(x, y) dy \right] dx + b \int_{-\infty}^{\infty} y \left[\int_{-\infty}^{\infty} f(x, y) dx \right] dy + c \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) dx dy \\ &= a \int_{-\infty}^{\infty} x \cdot f_X(x) dx + b \int_{-\infty}^{\infty} y \cdot f_Y(y) dy + c \\ &= aE(X) + bE(Y) + c \end{aligned}$$

Eksempel (forts. av 5.4 i Devore & Berk)

X og Y har simultantetthet

$$f(x,y) = \begin{cases} \frac{6}{5}(x + y^2) & 0 \leq x \leq 1, \quad 0 \leq y \leq 1 \\ 0 & \text{ellers} \end{cases}$$



De marginale tetthetene er (for $0 \leq x \leq 1$, $0 \leq y \leq 1$)

$$f_x(x) = \frac{6}{5}x + \frac{2}{5} \quad \text{og} \quad f_y(y) = \frac{6}{5}y^2 + \frac{3}{5}$$

Vi har at

$$E(X) = \int_{-\infty}^{\infty} xf_X(x)dx = \int_0^1 x \left(\frac{6}{5}x + \frac{2}{5} \right) dx = \frac{3}{5}$$

Tilsvarende er $E(Y) = \frac{3}{5}$

Vi finner:

$$\begin{aligned} E(1 + X + 2Y) &= 1 + E(X) + 2E(Y) \\ &= 1 + \frac{3}{5} + 2 \cdot \frac{3}{5} = \frac{14}{5} = 2.8 \end{aligned}$$

Uavhengige stokastiske variabler

La X og Y være uavhengige stokastiske variabler

Da har vi for alle (x, y) at

$$p(x, y) = p_X(x) \cdot p_Y(y) \quad (\text{diskret})$$

$$f(x, y) = f_X(x) \cdot f_Y(y) \quad (\text{kontinuerlig})$$

Vi kan da vise at (jf. forelesningen)

$$E\{g(X) \cdot h(Y)\} = E\{g(X)\} \cdot E\{h(Y)\}$$

Spesielt har vi at

$$E(X \cdot Y) = E(X) \cdot E(Y)$$

Kovarians

La X og Y være stokastiske variabler med simultan punktsannsynlighet $p(x, y)$ eller simultantetthet $f(x, y)$

Forventningene er $\mu_X = E(X)$ og $\mu_Y = E(Y)$

Da er **kovariansen** mellom X og Y gitt ved

$$\text{Cov}(X, Y) = E\{(X - \mu_X) \cdot (Y - \mu_Y)\}$$

$$= \begin{cases} \sum_x \sum_y (x - \mu_X) \cdot (y - \mu_Y) \cdot p(x, y) & (\text{diskret}) \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \mu_X) \cdot (y - \mu_Y) \cdot f(x, y) dx dy & (\text{kontinuerlig}) \end{cases}$$

Merk at $\text{Cov}(X, X) = E\{(X - \mu_X)^2\} = V(X)$

Hvis X og Y er uavhengige, så er $\text{Cov}(X, Y) = 0$
(men ikke omvendt)

Eksempel – kovarians mellom karakterer

Vi vil bestemme kovariansen mellom karakterene i norsk (X) og matematikk (Y)

Vi har funnet at

$$\mu = E(X) = 3.41 \quad \mu_Y = E(Y) = 3.22$$

Vi får at

$$\begin{aligned} \text{Cov}(X, Y) &= \sum_x \sum_y (x - 3.41) \cdot (y - 3.22) \cdot p(x, y) \\ &= (1 - 3.41) \cdot (1 - 3.22) \cdot p(1, 1) + \dots \\ &\quad \dots + (6 - 3.41) \cdot (6 - 3.22) \cdot p(6, 6) \\ &= 0.710 \end{aligned}$$

Regneregel for kovarians

La X og Y være to stokastiske variabler
(diskrete eller kontinuerlige)

Forventningene er

$$\mu_X = E(X) \quad \mu_Y = E(Y)$$

Da har vi

$$\begin{aligned}\text{Cov}(X, Y) &= E\{(X - \mu_X) \cdot (Y - \mu_Y)\} \\ &= E(XY) - \mu_X Y - \mu_Y X + \mu_X \mu_Y \\ &= E(XY) - \mu_X E(Y) - \mu_Y E(X) + \mu_X \mu_Y \\ &= E(XY) - \mu_X \cdot \mu_Y\end{aligned}$$

Eksempel (forts. av 5.4 i Devore & Berk)

X og Y har simultan tetthet

$$f(x, y) = \begin{cases} \frac{6}{5}(x + y^2) & 0 \leq x \leq 1, \quad 0 \leq y \leq 1 \\ 0 & \text{ellers} \end{cases}$$

Vi har at $\mu_X = E(X) = \frac{3}{5}$ og $\mu_Y = E(Y) = \frac{3}{5}$

Nå har vi at

$$E(XY) = \iint_{-\infty}^{\infty} xyf(x, y)dxdy = \iint_0^1 xy \frac{6}{5}(x + y^2)dxdy = \frac{7}{20}$$

Det gir at

$$\text{Cov}(X, Y) = E(XY) - \mu_X\mu_Y = \frac{7}{20} - \frac{3}{5} \cdot \frac{3}{5} = -\frac{1}{100}$$

Regneregel for kovarians

La X og Y være to stokastiske variabler med
 $\mu_X = E(X)$ og $\mu_Y = E(Y)$

Da har vi

$$\text{Cov}(aX + b, cY + d)$$

$$= E\{[aX + b - (a\mu_X + b)] \cdot [cY + d - (c\mu_Y + d)]\}$$

$$= E\{ac \cdot (X - \mu_X) \cdot (Y - \mu_Y)\}$$

$$= acE\{(X - \mu_X) \cdot (Y - \mu_Y)\}$$

$$= ac\text{Cov}(X, Y)$$

Korrelasjon

Kovariansen avhenger av hvilken måleenhet vi bruker

Et mål for samvariasjon som ikke avhenger av måleenhet er **korrelasjonskoeffisienten**

La $\sigma_x = SD(X)$ og $\sigma_y = SD(Y)$

Da er korrelasjonskoeffisienten gitt ved

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

Merk at

$$\text{Corr}(X, Y) = \text{Cov}\left(\frac{X - \mu_X}{\sigma_X}, \frac{Y - \mu_Y}{\sigma_Y}\right)$$

Eksempel – Korrelasjon mellom karakterer

Vi har funnet at

$$\text{Cov}(X, Y) = 0.710$$

Vi har videre at

$$\sigma_X = \sqrt{\text{Var}(X)} = 1.06$$

$$\sigma_Y = \sqrt{\text{Var}(Y)} = 1.44$$

Dermed er

$$\rho_{X,Y} = \frac{\text{Cov}(X, Y)}{\sigma_X \cdot \sigma_Y} = \frac{0.710}{1.06 \cdot 1.44} = 0.47$$

Egenskaper til korrelasjonskoeffisienten

For korrelasjonskoeffisienten gjelder følgende

- 1) Hvis a og c begge er positive, eller begge er negative, er
$$\text{Corr}(aX + b, cY + d) = \text{Corr}(X, Y)$$
- 2) $-1 \leq \text{Corr}(X, Y) \leq 1$
- 3) $\text{Corr}(X, Y) = \pm 1$ hvis og bare hvis
$$Y = aX + b \text{ der } a \neq 0$$
- 4) Hvis X og Y er uavhengige, er $\text{Corr}(X, Y) = 0$
(det omvendte resultatet gjelder ikke)