

SF1920/SF1921 Sannolikhetsteori och statistik  
6,0 hp  
Föreläsning 6  
Väntevärden  
Korrelation och kovarians  
Stora talens lag

Jörgen Säve-Söderbergh

## Theorem

Om  $Y = g(X)$  gäller att

$$E(Y) = \begin{cases} \sum_k g(k) p_X(k) & \text{diskreta s.v.} \\ \int_{-\infty}^{\infty} g(x) f_X(x) dx & \text{Kontinuerliga s.v.} \end{cases}$$

Vi kan generalisera till flera stokastiska variabler

## Theorem

Om  $Z = g(X, Y)$  gäller att

$$E(Z) = \begin{cases} \sum_j \sum_k g(j, k) p_{X,Y}(j, k) & \text{diskreta s.v.} \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) f_{X,Y}(x, y) dx dy & \text{kontinuerliga s.v.} \end{cases}$$

Intressanta fall av funktionen  $g(\cdot)$  är  $g(X, Y) = X + Y$ ,  
 $g(X, Y) = X$  samt  $g(X, Y) = XY$

# Väntevärdet av en summa av två stokastiska variabler

## Theorem

$$E(X + Y) = E(X) + E(Y)$$

## Bevis.

Antag  $X$  och  $Y$  är kontinuerliga stokastiska variabler.

$$\begin{aligned} E(X + Y) &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x + y) f_{X,Y}(x, y) dx dy \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x f_{X,Y}(x, y) dx dy + \\ &\quad + \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} y f_{X,Y}(x, y) dx dy \\ &= E(X) + E(Y) \end{aligned}$$

I boken finns ett bevis för diskreta stokastiska variabler. □

Vi behöver inte anta att  $X$  och  $Y$  är oberoende. Gäller för flera s.v. ...

## Theorem

$$E(aX + bY + c) = aE(X) + bE(Y) + c \quad (\text{Inget oberoende!})$$

## Bevis.

(Skiss) Antag att  $X$  och  $Y$  är kontinuerliga.

$$E(aX + bY + c) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (ax + by + c) f_{X,Y}(x, y) dx dy$$



# Väntevärdet av en produkt av två stokastiska variabler

## Theorem

Om  $X$  och  $Y$  är oberoende, gäller att  $E(XY) = E(X)E(Y)$

## Bevis.

Antag att  $X$  och  $Y$  är kontinuerliga.

$$\begin{aligned} E(XY) &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} xy f_{X,Y}(x,y) dx dy \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} xy f_X(x) f_Y(y) dx dy \\ &= \left( \int_{-\infty}^{\infty} x f_X(x) dx \right) \left( \int_{-\infty}^{\infty} y f_Y(y) dy \right) \\ &= E(X)E(Y) \end{aligned}$$



Kan generaliseras till flera stokastiska variabler.

# Mått på beroendet mellan två stokastiska variabler i en tvådimensionell stokastisk variabel $(X, Y)$

Vi önskar uttrycka beroendet mellan de två variablerna  $X$  och  $Y$  i en tvådimensionell stokastisk variabel  $(X, Y)$  med ett tal.

Det är motsvarigheten till läges- och spridningsmått som vi söker.

Betrakta en bivariat täthetsfunktion över  $\mathbb{R}^2$ .

Vi har sett ovan att variansen är väntevärdet av funktionen  $g(X) = (X - \mu)^2$ .


Vilken funktion  $g(X, Y)$  ska vi använda i väntevärdet för att fånga beroendet mellan  $X$  och  $Y$ ?

Vi studerar funktionen

$$g(X, Y) = (X - \mu_X)(Y - \mu_Y).$$


# Effekten av produkten $(X - \mu_X)(Y - \mu_Y)$

De stokastiska variablerna  $X$  och  $Y$  har respektive väntevärde  $\mu_X$  och  $\mu_Y$ .



# Positivt och negativt beroende mellan $X$ och $Y$

nivåkurvor liknande dem i Figur 5.7, framgår rätt tydligt att det finns ett beroende. I Figur 5.7a har  $X$  och  $Y$  en tendens att avvika åt samma håll från sina väntevärden  $\mu_X$  respektive  $\mu_Y$ , dvs ett högt värde på  $X$  har en tendens att följas av ett högt värde även på  $Y$  och vice versa. I Figur 5.7b däremot tenderar  $X$  och  $Y$  att avvika åt olika håll från sina väntevärden.



**Figur 5.7** Nivåkurvor.



## Definition

Kovariansen  $\text{Cov}(X, Y)$  mellan  $X$  och  $Y$  definieras som

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

Vi ser att

$$\text{Cov}(X, X) = E[(X - \mu_X)^2] = \text{Var}(X)$$

Om  $X$  och  $Y$  har en simultan täthet  $f_{X,Y}(x, y)$  gäller att

$$\text{Cov}(X, Y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - \mu_X)(y - \mu_Y) f_{X,Y}(x, y) dx dy.$$

Om  $X$  och  $Y$  är diskreta s.v.

$$\text{Cov}(X, Y) = \sum_i \sum_k (i - \mu_X)(j - \mu_Y) p_{X,Y}(x, y).$$

# Beräkningsformel för kovariansen

Om vi använder räkneregler för  $E(\cdot)$  ovan

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

d.v.s.

Theorem

$$\text{Cov}(X, Y) = E[XY] - \mu_X\mu_Y.$$

# Räkner regler för $\text{Cov}(\cdot)$

## Theorem

- $\text{Cov}(X, X) = \text{Var}(X)$
- $\text{Cov}(X, Y) = \text{Cov}(Y, X)$
- $\text{Cov}(aX + b, cY + d) = ac\text{Cov}(Y, X)$
- $\text{Cov}(X + Y, Z) = \text{Cov}(X, Z) + \text{Cov}(Y, Z)$

## Bevis.

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



# Kovariansen är en bilinear funktion

Detta betyder att kovariansen är linjär i båda sina argument.

## Theorem

$$\begin{aligned} \text{Cov}(X + Y, Z + W) = \\ \text{Cov}(X, Z) + \text{Cov}(X, W) + \text{Cov}(Y, Z) + \text{Cov}(Y, W) \end{aligned}$$

En linjärkombination av stokastiska variabler  $X_1, X_2, \dots, X_n$  är

$$c_1 X_1 + c_2 X_2 + \dots + c_n X_n = \sum_{j=1}^n c_j X_j,$$

där  $c_1, c_2, \dots, c_n$  är godtyckliga reella tal.

## Theorem

$$\text{Cov}\left(\sum_{i=1}^n a_i X_i, \sum_{j=1}^n b_j X_j\right) = \sum_{i=1}^n \sum_{j=1}^n a_i b_j \text{Cov}(X_i, X_j)$$

Standardavvikelsen för en stokastisk variabel  $X$  betecknas  $D(X)$ .

## Definition

Korrelationskoefficienten för  $X$  och  $Y$  definieras som

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

- $\rho$  är ett mått på det **lineära** beroendet mellan  $X$  och  $Y$ .
- $\rho$  saknar dimension.
- Varför delar vi  $\text{Cov}(X, Y)$  med produkten av  $D(X)$  och  $D(Y)$ ?

Det gör att

$$-1 \leq \rho \leq 1.$$

## Definition

Om  $\text{Cov}(X, Y) = 0$  säges  $X$  och  $Y$  vara *okorrelerade*.

Då  $\text{Cov}(X, Y) = E(XY) - E(X)E(Y)$  är två s.v. okorrelerade om och endast om  $E(XY) = E(X)E(Y)$ .

## Theorem

Om  $X$  och  $Y$  är oberoende så är de också okorrelerade.

## Bevis.

Om  $X$  och  $Y$  är oberoende  $E(XY) = E(X)E(Y)$ . Alltså är  $X$  och  $Y$  okorrelerade. □

Motsatsen är inte sann; Beroende variabler kan vara okorrelerade.

Exempel 5.13

En lineärkombination av stokastiska variabler  $X_1, X_2, \dots, X_n$  är

$$c_1 X_1 + c_2 X_2 + \dots + c_n X_n = \sum_{j=1}^n c_j X_j,$$

där  $c_1, c_2, \dots, c_n$  är godtyckliga reella tal.

## Theorem

$$E\left(\sum_{j=1}^n c_j X_j\right) = \sum_{i=1}^n c_i E(X_i)$$

$$\text{Var}\left(\sum_{j=1}^n c_j X_j\right) = \sum_{i=1}^n c_i^2 \text{Var}(X_i) + 2 \sum_{i < j} c_i c_j \text{Cov}(X_i, X_j)$$

Om  $X_1, X_2, \dots, X_n$  är oberoende

$$\text{Var}\left(\sum_{j=1}^n c_j X_j\right) = \sum_{i=1}^n c_i^2 \text{Var}(X_i)$$

Välj  $c_i = \frac{1}{n}$ , vilket ger

$$c_1 X_1 + \cdots + c_n X_n = \frac{1}{n} X_1 + \cdots + \frac{1}{n} X_n = \frac{X_1 + \cdots + X_n}{n} = \bar{X}.$$

## Theorem


Om  $X_1, X_2, \dots, X_n$  är oberoende s.v. med samma väntevärde  $\mu$  och standardavvikelsen  $\sigma$

$$E(\bar{X}) = \frac{1}{n} \sum_{i=1}^n \mu = n \frac{\mu}{n} = \mu$$

$$\text{Var}(\bar{X}) = \sum_{i=1}^n \left(\frac{1}{n}\right)^2 \sigma^2 = n \frac{\sigma^2}{n^2} = \frac{\sigma^2}{n}$$

$$D(\bar{X}) = \frac{\sigma}{\sqrt{n}}$$





**FIGUR:** Sannolikhetsfunktionen för medelvärdet  $\bar{X}_n = (X_1 + \dots + X_n)/n$ , där de enskilda observationerna är  $Po(1)$ , för  $n = 1, 10, 100$  och  $1000$ . Den diskreta fördelningen koncentreras alltmer runt värdet 1, dvs väntevärdet.

Låt  $X_1, X_2, \dots$  vara oberoende och likafördelade stokastiska variabler, var och en med väntevärdet  $\mu$ , och sätt

$$\bar{X}_n = \frac{X_1 + X_2 + \dots + X_n}{n}.$$

Då gäller, för alla  $\epsilon > 0$ , att

$$P(\mu - \epsilon < \bar{X}_n < \mu + \epsilon) \rightarrow 1 \quad \text{då} \quad n \rightarrow \infty.$$