

STK1100 våren 2023

Simultane, marginale og betingede fordelinger

Dekker det meste av avsnitt 5.4 og 5.5

Matematisk institutt
Universitetet i Oslo

Simultane og marginale punktsannsynligheter for diskrete stokastiske variabler

For to diskrete stokastiske variabler X og Y er den **simultane punktsannsynligheten** gitt ved

$$p(x, y) = P(X = x \text{ og } Y = y)$$

Den **marginale punktsannsynligheten** for X er

$$p_X(x) = P(X = x) = \sum_y p(x, y)$$

Den **marginale punktsannsynligheten** for Y er

$$p_Y(y) = P(Y = y) = \sum_x p(x, y)$$

Betinget punktsannsynlighet for diskrete stokastiske varabler

Den **betingete punktsannsynligheten** for Y gitt at $X = x$ er gitt ved

$$\begin{aligned} p_{Y|X}(y | x) &= P(Y = y | X = x) \\ &= \frac{P(X = x \text{ og } Y = y)}{P(X = x)} = \frac{p(x, y)}{p_X(x)} \end{aligned}$$

Den **betingete punktsannsynligheten** for X gitt at er $Y = y$ er gitt ved

$$p_{X|Y}(x | y) = P(X = x | Y = y) = \frac{p(x, y)}{p_Y(y)}$$

Eksempel – Fordeling av karakterer

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

Simultan og marginal punktsannsynlighet for X og Y er gitt i tabellen (i prosent)

$y \backslash X$	1	2	3	4	5	6	$P(Y=y)$
1	1	4	5	3	-	-	13
2	1	4	11	6	-	-	22
3	1	4	8	8	2	-	23
4	-	3	7	6	4	-	20
5	-	1	3	6	5	1	16
6	-	-	1	2	2	1	6
$P(X=x)$	3	16	35	31	13	2	100

$y \backslash x$	1	2	3	4	5	6	$P(Y=y)$
1	1	4	5	3	-	-	13
2	1	4	11	6	-	-	22
3	1	4	8	8	2	-	23
4	-	3	7	6	4	-	20
5	-	1	3	6	5	1	16
6	-	-	1	2	2	1	6
$P(X=x)$	3	16	35	31	13	2	100

Gitt at $X = 5$, har vi (f. eks.) at

$$p_{Y|X}(4 | 5) = \frac{p(5,4)}{p_X(5)} = \frac{4/100}{13/100} = 0.31 \quad (31\%)$$

$$p_{Y|X}(5 | 5) = \frac{p(5,5)}{p_X(5)} = \frac{5/100}{13/100} = 0.38 \quad (38\%)$$

Betinget forventning og varians for diskrete stokastiske variable

Den **betingete forventningen** for Y gitt at $X = x$ er gitt ved

$$\mu_{Y|X=x} = E(Y | X = x) = \sum_y y \cdot p_{Y|X}(y | x)$$

Den **betingete variansen** for Y gitt at $X = x$ er gitt ved

$$\sigma_{Y|X=x}^2 = V(Y | X = x) = \sum_y (y - \mu_{Y|X=x})^2 \cdot p_{Y|X}(y | x)$$

Tilsvarende gjelder for betinget forventning og varians for X gitt at $Y = y$

Eksempel (forts)

$y \backslash X$	1	2	3	4	5	6	$P(Y=y)$
1	1	4	5	3	-	-	13
2	1	4	11	6	-	-	22
3	1	4	8	8	2	-	23
4	-	3	7	6	4	-	20
5	-	1	3	6	5	1	16
6	-	-	1	2	2	1	6
$P(X=x)$	3	16	35	31	13	2	100

Gitt at $X = 5$, er forventet verdi av Y

$$\mu_{Y|X=5} = \sum_{y=1}^6 y \cdot p_{Y|X}(y | 5) = 4.54$$

Gitt at $X = 3$, er forventet verdi av Y

$$\mu_{Y|X=3} = \sum_{y=1}^6 y \cdot p_{Y|X}(y | 3) = 2.86$$

(Python-kommandoer
på neste slide)

Python-kommandoer for å beregne de betingete forventningene på forrige slide

```
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]])
px = sum(pxy)
sum(tmp*pxy.transpose()[4]/[px[4]])
sum(tmp*pxy.transpose()[2]/[px[2]])
```

Simultane og marginale sannsynlighetstettheter for kontinuerlige stokastiske variabler

For to kontinuerlige stokastiske variabler X og Y har vi en **simultan synlighetstetthet** $f(x, y)$

De **marginale sannsynlighetstetthetene** for X og Y er

$$f_X(x) = \int_{-\infty}^{\infty} f(x, y) dy$$

$$f_Y(y) = \int_{-\infty}^{\infty} f(x, y) dx$$

Betingete sannsynlighetstettheter for kontinuerlige stokastiske variabler

Den betingede sannsynlighetstettheten for Y gitt at $X = x$ er gitt ved

$$f_{Y|X}(y | x) = \frac{f(x, y)}{f_X(x)}$$

Den betingede sannsynlighetstettheten for X gitt at $Y = y$ er gitt ved

$$f_{X|Y}(x | y) = \frac{f(x, y)}{f_Y(y)}$$

Eksempel (fra læreboka)

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 $0 \leq x \leq 1, \quad 0 \leq y \leq 1$)

$$f_x(x) = \int_{-\infty}^{\infty} f(x, y) dy = \int_0^1 \frac{6}{5}(x + y^2) dy = \frac{6}{5}x + \frac{2}{5}$$

$$f_y(y) = \int_{-\infty}^{\infty} f(x, y) dx = \int_0^1 \frac{6}{5}(x + y^2) dx = \frac{6}{5}y^2 + \frac{3}{5}$$

Den betingete tettheten for Y gitt $X=x$ er
(for $0 \leq y \leq 1$)

$$\begin{aligned}f_{Y|X}(y|x) &= \frac{f(x,y)}{f_X(x)} \\&= \frac{\frac{6}{5}(x+y^2)}{\frac{6}{5}x + \frac{2}{5}} \\&= \frac{3(x+y^2)}{3x+1}\end{aligned}$$

Et tilsvarende uttrykk gjelder for den betingete tettheten for X gitt $Y=y$

Betinget forventning og varians for kontinuerlige stokastiske variabler

Den **betingete forventningen** for Y gitt at $X = x$ er gitt ved

$$\mu_{Y|X=x} = E(Y | X = x) = \int_{-\infty}^{\infty} y \cdot f_{Y|X}(y | x) dy$$

Den **betingete variansen** for Y gitt at $X = x$ er gitt ved

$$\sigma_{Y|X=x}^2 = V(Y | X = x) = \int_{-\infty}^{\infty} (y - \mu_{Y|X=x})^2 \cdot f_{Y|X}(y | x) dy$$

Tilsvarende gjelder for betinget forventning og varians for X gitt at $Y = y$

Eksempel (forts)

Den betingete tettheten for Y gitt $X = x$ er
(for $0 \leq y \leq 1$)

$$f_{Y|X}(y|x) = \frac{3(x + y^2)}{3x + 1}$$

Den betingete forventningen til Y gitt $X = x$ er

$$\mu_{Y|X=x} = \int_{-\infty}^{\infty} y \cdot f_{Y|X}(y|x) dy$$

$$= \int_0^1 y \cdot \frac{3(x + y^2)}{3x + 1} dy = \frac{2x + 1}{4\left(x + \frac{1}{3}\right)}$$

Uavhengige stokastiske variabler

To stokastiske variabler X og Y er **uavhengige** hvis vi **for alle** (x, y) har at

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

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

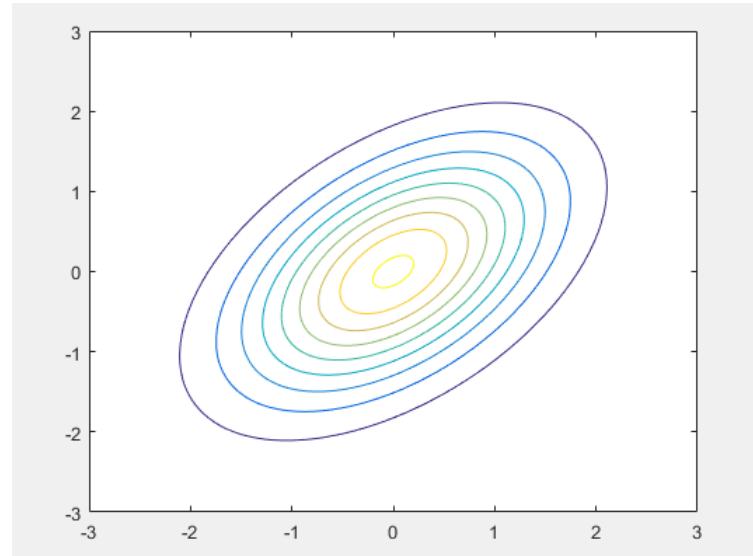
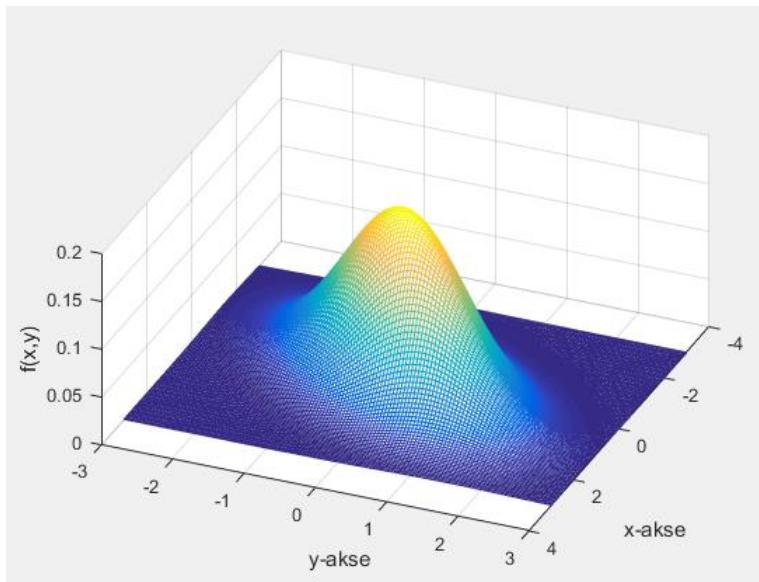
X og Y er **uavhengige** hvis og bare hvis de betingete punktsannsynlighetene / tetthetene er lik de marginale punktsannsynlighetene / tetthetene

Binormalfordeling

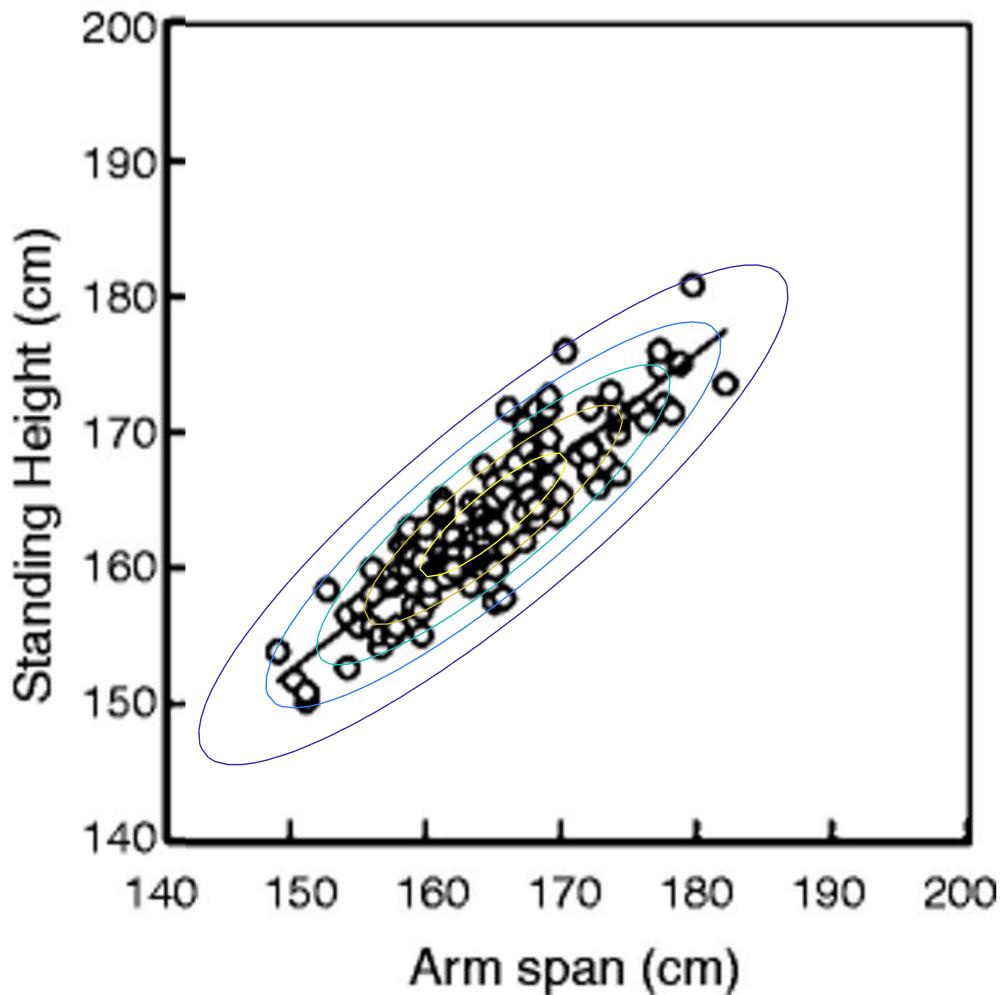
X og Y er binormalt fordelt med simultantetthet

$$f(x,y) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp\left\{-\left[\left(\frac{x-\mu_1}{\sigma_1}\right)^2 - 2\rho\left(\frac{x-\mu_1}{\sigma_1}\right)\left(\frac{y-\mu_2}{\sigma_2}\right) + \left(\frac{y-\mu_2}{\sigma_2}\right)^2\right]\Big/2(1-\rho^2)\right\}$$

Illustrasjon for $\mu_1 = \mu_2 = 0$, $\sigma_1 = \sigma_2 = 1$ og $\rho = 0.50$



Eksempel: Rekkevidde og høyde for unge kvinner (australske data)



Vi har to kontinuerlige stokastiske variabler
 X = rekkevidde
 Y = høyde

X og Y er binormalt fordelt med

$$\mu_1 = \mu_2 = 164$$

$$\sigma_1 = \sigma_2 = 10$$

$$\rho = 0.90$$

Den marginale tettheten for X er (krever en del regning)

$$f_X(x) = \int_{-\infty}^{\infty} f(x, y) dy = \frac{1}{\sigma_1 \sqrt{2\pi}} \exp \left\{ -\frac{1}{2\sigma_1^2} (x - \mu_1)^2 \right\}$$

Altså er $X \sim N(\mu_1, \sigma_1)$

Tilsvarende er $Y \sim N(\mu_2, \sigma_2)$

Videre har vi at $\rho = \text{corr}(X, Y)$

Hvis $\rho = 0$, er X og Y uavhengige

Den betingete tettheten til Y gitt $X = x$ er
(krever en del regning)

$$f_{Y|X}(y | x) = \frac{f(x, y)}{f_X(x)}$$

$$= \frac{1}{\sigma_2 \sqrt{1-\rho^2} \sqrt{2\pi}} \exp \left\{ -\frac{1}{2\sigma_2^2(1-\rho^2)} \left(y - \mu_2 - \rho \sigma_2 \frac{x - \mu_1}{\sigma_1} \right)^2 \right\}$$

Altså er

$$[Y|X = x] \sim N \left(\mu_2 + \rho \sigma_2 \frac{x - \mu_1}{\sigma_1}, \sigma_2^2(1 - \rho^2) \right)$$

Regresjon mot gjennomsnittet

For binormalfordeling har vi at

$$\mu_{Y|X=x} = \mu_2 + \rho \sigma_2 \frac{x - \mu_1}{\sigma_1}$$

som vi kan skrive

$$\frac{\mu_{Y|X=x} - \mu_2}{\sigma_2} = \rho \frac{x - \mu_1}{\sigma_1}$$

Eksempel

Høyde av mødre og døtre (jf læreboka 333-334)

Dobbelforventning

Den betingete forventningen for Y gitt at $X = x$ er gitt ved (for diskrete tilfellet)

$$\mu_{Y|X=x} = E(Y | X = x) = \sum_y y \cdot p_{Y|X}(y | x)$$

Vi har at $\mu_{Y|X=x} = h(x)$ er en funksjon av x

Merk at

$$\begin{aligned} E[E(Y | X)] &= Eh(X) = \sum_x \left(\sum_y y \cdot p_{Y|X}(y | x) \right) p_x(x) \\ &= \sum_y \sum_x y \cdot p(x, y) = \sum_y y \cdot p_Y(y) = E(Y) \end{aligned}$$

Resultatet gjelder tilsvarende for det kontinuerlige tilfellet

Eksempel

Simultan og marginal punktsannsynlighet for X = karakter i norsk og Y = karakter i matematikk er gitt i tabellen

$y \backslash x$	1	2	3	4	5	6	$P(Y=y)$
1	1	4	5	3	-	-	13
2	1	4	11	6	-	-	22
3	1	4	8	8	2	-	23
4	-	3	7	6	4	-	20
5	-	1	3	6	5	1	16
6	-	-	1	2	2	1	6
$P(X=x)$	3	16	35	31	13	2	100

Vi finner

x	1	2	3	4	5	6
$\mu_{Y X=x}$	2.00	2.56	2.86	3.39	4.54	5.50

Det gir

$$E(E(Y | X)) = 2.00 \cdot 0.03 + \dots + 5.50 \cdot 0.02 = 3.22 = E(Y)$$