

Elementær sandsynlighedsregning

Sandsynlighedsbegrebet

Et udfaldsrum S er mængden af alle de mulige udfald af et eksperiment.

En hændelse A er en delmængde af udfaldsrummet S .

Et sandsynlighedsmål er en funktion P , der afbilder hændelser ind i intervallet $[0; 1]$. Funktionen P skal opfylde

$$\begin{aligned} P(S) &= 1 \\ 0 \leq P(A) &\leq 1 \\ A \cap B = \emptyset \quad \Rightarrow \quad P(A \cup B) &= P(A) + P(B) \end{aligned}$$

Der gælder blandt andet

$$\begin{aligned} P(\emptyset) &= 0 \\ P(A^c) &= 1 - P(A) \\ P(A \cup B) &= P(A) + P(B) - P(A \cap B) \end{aligned}$$

Betinget sandsynlighed:

$$P(A|B) = \frac{P(A \cap B)}{P(B)}, \quad P(B) > 0$$

A og B er uafhængige, hvis

$$P(A \cap B) = P(A) P(B) \text{ for alle } A, B$$

Uafhængighed medfører, at

$$P(A|B) = P(A) \quad \text{og} \quad P(B|A) = P(B)$$

Lad E_1, E_2, \dots, E_k være en klassedeling af S , dvs. E_1, E_2, \dots, E_k opfylder

$$\begin{aligned} E_i \cap E_j &= \emptyset \text{ for alle } i \neq j \\ E_1 \cup E_2 \cup \dots \cup E_k &= S \quad * \end{aligned}$$

Loven om total sandsynlighed:

$$P(A) = \sum_{i=1}^k P(A|E_i) P(E_i) \quad **$$

*Definitionen kan udvides til at gælde tælligt mange hændelser, dvs. $E_1 \cup E_2 \cup \dots = S$.

Bayes' formel:

$$P(E_j|A) = \frac{P(A|E_j) P(E_j)}{P(A)} = \frac{P(A|E_j) P(E_j)}{\sum_{i=1}^k P(A|E_i) P(E_i)}, \quad j = 1, \dots, k \quad **$$

Symmetrisk sandsynlighed: Når alle udfald i S har samme sandsynligheden for en hændelse A udregnes ved at tælle, hvor mange udfald der hører til A , og dividere med antallet af udfald i S . Altså

$$P(A) = \frac{\# \text{ gunstige}}{\# \text{ mulige}}$$

Stokastisk variabel

En stokastisk variabel X er en reel funktion defineret på udfaldsrummet S , dvs. $X : S \rightarrow \mathbb{R}$, $X(s) = x, s \in S$

X er diskret, når X antager endeligt mange værdier eller højest tælleligt mange værdier.

X er kontinuert, når X antager flere end tælleligt mange værdier.

Diskrete fordelinger

Sandsynlighedsfunktion for en diskret stokastisk variabel:

$$p(x_k) = P(X = x_k)$$

Når X er heltallig, dvs. når X kun antager hele tal som værdier, kan sandsynlighedsfunktionen skrives

$$p(k) = P(X = k)$$

Fordelingsfunktion:

$$F(x) = P(X \leq x) = \sum_{x_k \leq x} p(x_k), \quad x \in \mathbb{R}$$

Middelværdi af X :

$$\mathbb{E}[X] = \sum_k x_k p(x_k) = \mu$$

Middelværdi af en afledt stokastisk variabel $g(X)$:

$$\mathbb{E}[g(X)] = \sum_k g(x_k) p(x_k)$$

Varians af X :

$$\text{Var}(X) = \mathbb{E}[(X - \mathbb{E}[X])^2] = \mathbb{E}[X^2] - (\mathbb{E}[X])^2 = \sigma^2$$

Spredning:

$$\sigma = \sqrt{\text{Var}(X)}$$

** Formlerne modificeres, når S består af tælleligt mange hændelser.

Eksempel 1. Kast med en terning. Lad X betegne antal øjne.

$$\begin{aligned} p(k) &= \frac{1}{6}, \quad k = 1, 2, \dots, 6 \\ E[X] &= \sum_{k=1}^6 k \frac{1}{6} = \frac{1}{6} \frac{6(6+1)}{2} = \frac{7}{2} \quad * \\ E[X^2] &= \sum_{k=1}^6 k^2 \frac{1}{6} = \frac{1}{6} \frac{6 \cdot 7 \cdot 13}{6} = \frac{91}{6} \quad * \\ \text{Var}(X) &= \frac{91}{6} - \left(\frac{7}{2}\right)^2 = \frac{182 - 49}{12} = \frac{35}{12} \end{aligned}$$

Lad Y betegne antal kast, der medgår, indtil en sekser fremkommer.

$$\begin{aligned} p(k) &= \frac{1}{6} \left(\frac{5}{6}\right)^{k-1}, \quad k = 1, 2, \dots \\ E[Y] &= \sum_{k=1}^{\infty} k \frac{1}{6} \left(\frac{5}{6}\right)^{k-1} = \frac{1}{6} \frac{1}{(1 - \frac{5}{6})^2} = 6 \quad ** \\ E[(Y+1)Y] &= \sum_{k=1}^{\infty} (k+1)k \frac{1}{6} \left(\frac{5}{6}\right)^{k-1} = \frac{1}{6} \frac{2}{(1 - \frac{5}{6})^3} = 72 \quad ** \\ E[Y^2] &= E[(Y+1)Y] - E[Y] = 72 - 6 = 66 \\ \text{Var}(Y) &= E[Y^2] - (E[Y])^2 = 66 - 6^2 = 30 \quad \square \end{aligned}$$

Indikatorvariabel. Lad I_A betegne indikatorvariabel for hændelsen A , dvs. I_A antager værdien 1, når A forekommer, og værdien 0, når A^c forekommer. Sæt $P(A) = p$.

$$E[I_A] = p, \quad \text{Var}(I_A) = p(1-p)$$

Binomialfordelingen. Lad X være antal gange en hændelse A forekommer blandt n uafhængige gentagelser af et forsøg. Sæt $P(A) = p$. Bemærk, at X kan opfattes som en sum af indikatorvariable for hændelsen A , dvs. $X = I_{A_1} + I_{A_2} + \dots + I_{A_n}$.

$$\begin{aligned} p(k) &= \binom{n}{k} p^k (1-p)^{n-k}, \quad k = 0, 1, \dots, n \\ E[X] &= np, \quad \text{Var}(X) = np(1-p) \end{aligned}$$

At X er binomialfordelt med antalsparameter n og sandsynlighedsparameter p , skrives kort $X \sim b(n, p)$.

Poissonfordelingen. Lad λ være det gennemsnitlige antal begivenheder, der indtræffer i et område (interval), og lad X være det antal begivenheder, der indtræffer.

$$\begin{aligned} p(k) &= \frac{e^{-\lambda} \lambda^k}{k!}, \quad k = 0, 1, 2, \dots \\ E[X] &= \lambda, \quad \text{Var}(X) = \lambda \end{aligned}$$

At X er Poissonfordelt med parameter λ , skrives kort $X \sim p(\lambda)$.

*Vedr. summationer, se baggrundsnote til sandsynlighedsregning side 3

**Vedr. summationer, se baggrundsnote til sandsynlighedsregning side 4

Kontinuerte fordelinger

Fordelingsfunktion:

$$F(x) = P(X \leq x), \quad x \in \mathbb{R}$$

Bemærk, at der gælder

$$\lim_{x \rightarrow -\infty} F(x) = 0, \quad \lim_{x \rightarrow \infty} F(x) = 1$$

Hvis der findes en stykkevis kontinuert funktion f , der opfylder

$$\begin{aligned} f(x) &\geq 0, \quad x \in \mathbb{R} \\ \int_{-\infty}^x f(u) du &= F(x), \quad x \in \mathbb{R} \end{aligned}$$

så kaldes f tæthedsfunktion for X . Der gælder blandt andet

$$\begin{aligned} \int_{-\infty}^{\infty} f(x) dx &= 1 \\ P(X = x) &= 0, \quad x \in \mathbb{R} \\ P(a < X \leq x) &= \int_a^x f(x) dx = F(x) - F(a) \end{aligned}$$

Middelværdi af X :

$$E[X] = \int_{-\infty}^{\infty} x f(x) dx = \mu$$

Middelværdi af en afledt stokastisk variabel $g(X)$:

$$E[g(X)] = \int_{-\infty}^{\infty} g(x) f(x) dx$$

Varians af X :

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

Spredning:

$$\sigma = \sqrt{\text{Var}(X)}$$

Eksempel 2. Lad X være en stokastisk variabel med tæthedsfunktion $f(x) = 3x^2$, $0 \leq x \leq 1$.

$$\begin{aligned} E[X] &= \int_0^1 x 3x^2 dx = 3 \left[\frac{x^4}{4} \right]_0^1 = \frac{3}{4} \\ E[X^2] &= \int_0^1 x^2 3x^2 dx = 3 \left[\frac{x^5}{5} \right]_0^1 = \frac{3}{5} \\ \text{Var}(X) &= \frac{3}{5} - \left(\frac{3}{4} \right)^2 = \frac{48 - 45}{80} = \frac{3}{80} = 0.0375 \end{aligned}$$

Lad $Y = \sqrt{X}$ være en afledt stokastisk variabel.

$$\begin{aligned} E[Y] &= \int_0^1 \sqrt{x} 3x^2 dx = 3 \left[\frac{2}{7} x^{\frac{7}{2}} \right]_0^1 = \frac{6}{7} \\ E[Y^2] &= \int_0^1 (\sqrt{x})^2 3x^2 dx = \frac{3}{4} \\ \text{Var}(Y) &= \frac{3}{4} - \left(\frac{6}{7} \right)^2 = \frac{147 - 144}{196} = \frac{3}{196} \approx 0.0153 \end{aligned}$$

□

Ligefordeling på interval. $X \sim U[a; b]$.

$$f(x) = \frac{1}{b-a}, \quad a < x < b$$

$$\text{E}[X] = \frac{a+b}{2}, \quad \text{Var}(X) = \frac{b^2 - a^2}{12}$$

Eksponentialfordelingen. $X \sim e(\lambda)$.

$$f(x) = \lambda e^{-\lambda x}, \quad x \geq 0$$

$$\text{E}[X] = \frac{1}{\lambda}, \quad \text{Var}(X) = \frac{1}{\lambda^2}$$

Normalfordelingen. $X \sim N(\mu, \sigma^2)$.

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad -\infty < x < \infty$$

$$\text{E}[X] = \mu, \quad \text{Var}(X) = \sigma^2$$

Todimensional stokastisk variabel

Diskrete fordelinger

Den simultane sandsynlighedsfunktion for en todimensional diskret variabel (X, Y) :

$$p(x_j, y_k) = P(X = x_j, Y = y_k) = P(X = x_j \cap Y = y_k)$$

Marginal sandsynlighedsfunktion

$$\text{for } X: \quad p_X(x_j) = P(X = x_j) = \sum_k p(x_j, y_k)$$

$$\text{for } Y: \quad p_Y(y_k) = P(Y = y_k) = \sum_j p(x_j, y_k)$$

Middelværdi af en afledt endimensional stokastisk variable $g(X, Y)$:

$$\text{E}[g(X, Y)] = \sum_j \sum_k g(x_j, y_k) p(x_j, y_k)$$

X og Y er uafhængige, hvis $p(x_j, y_k) = p_X(x_j) p_Y(y_k)$ for alle j og k .

Eksempel 3. Kast med to terninger. Lad X betegne det største antal øjne, der fremkommer, og lad Y betegne summen af antal øjne. Bemærk, at X kan antage værdierne $1, 2, \dots, 6$, og at Y kan antage værdierne $2, 3, \dots, 11, 12$. Vi udregner værdierne af den simultane sandsynlighedsfunktion:

$P(X = x, Y = y)$	2	3	4	5	6	7	8	9	10	11	12
1	$\frac{1}{36}$	—	—	—	—	—	—	—	—	—	—
2	—	$\frac{2}{36}$	$\frac{1}{36}$	—	—	—	—	—	—	—	—
3	—	—	$\frac{2}{36}$	$\frac{2}{36}$	$\frac{1}{36}$	—	—	—	—	—	—
4	—	—	—	$\frac{2}{36}$	$\frac{2}{36}$	$\frac{2}{36}$	$\frac{1}{36}$	—	—	—	—
5	—	—	—	—	$\frac{2}{36}$	$\frac{2}{36}$	$\frac{2}{36}$	$\frac{2}{36}$	$\frac{1}{36}$	—	—
6	—	—	—	—	—	$\frac{2}{36}$	$\frac{2}{36}$	$\frac{2}{36}$	$\frac{2}{36}$	$\frac{1}{36}$	—

Marginalfordelingen

for X :

x	1	2	3	4	5	6
$P(X = x)$	$\frac{1}{36}$	$\frac{3}{36}$	$\frac{5}{36}$	$\frac{7}{36}$	$\frac{9}{36}$	$\frac{11}{36}$

for Y :

y	2	3	4	5	6	7	8	9	10	11	12
$P(Y = y)$	$\frac{1}{36}$	$\frac{2}{36}$	$\frac{3}{36}$	$\frac{4}{36}$	$\frac{5}{36}$	$\frac{6}{36}$	$\frac{5}{36}$	$\frac{4}{36}$	$\frac{3}{36}$	$\frac{2}{36}$	$\frac{1}{36}$

Bemærk, at marginalfordelingerne fremkommer ved simpel addition af henholdsvis rækker og søjler i skemaet for den simultane sandsynlighedsfunktion.

Udregning af middelværdi og varians af henholdsvis X og Y :

$$E[X] = 1 \frac{1}{36} + 2 \frac{3}{36} + 3 \frac{5}{36} + 4 \frac{7}{36} + 5 \frac{9}{36} + 6 \frac{11}{36} = \frac{161}{36}$$

$$E[X^2] = 1 \frac{1}{36} + 4 \frac{3}{36} + 9 \frac{5}{36} + 16 \frac{7}{36} + 25 \frac{9}{36} + 36 \frac{11}{36} = \frac{791}{36}$$

$$\text{Var}(X) = \frac{791}{36} - \left(\frac{161}{36}\right)^2 = \frac{28476 - 25921}{1296} = \frac{2555}{1296} \approx 1.9715$$

$$E[Y] = 2 \frac{1}{36} + 3 \frac{2}{36} + \dots + 11 \frac{2}{36} + 12 \frac{1}{36} = \frac{252}{36} = 7$$

$$E[Y^2] = 4 \frac{1}{36} + 9 \frac{2}{36} + \dots + 121 \frac{2}{36} + 144 \frac{1}{36} = \frac{1974}{36} = \frac{329}{6}$$

$$\text{Var}(Y) = \frac{247}{6} - 7^2 = \frac{1974 - 1764}{36} = \frac{210}{36} = \frac{35}{6} \approx 5.8333 \quad \square$$

Kontinuerte fordelinger

Den simultane fordelingsfunktion for den todimensionale kontinuerte variabel (X, Y) :

$$F(x, y) = P(X \leq x, Y \leq y), \quad (x, y) \in \mathbb{R}^2$$

Hvis der findes en stykkevis kontinuert funktion af to reelle variable, som opfylder

$$f(x, y) \geq 0, \quad (x, y) \in \mathbb{R}^2$$

$$\int_{-\infty}^x \int_{-\infty}^y f(u, v) du dv = F(x, y)$$

så kaldes $f(x, y)$ den simultane tæthedsfunktion for (X, Y) .

Marginale tætheder:

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

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

X og Y er uafhængige, hvis tæthedsfunktionerne opfylder $f(x, y) = f_X(x) f_Y(y)$.

Middelværdi af en afledt endimensional stokastisk variabel $g(X, Y)$:

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

Eksempel 4. Lad den simultane tæthedsfunktion for (X, Y) være givet som

$$f(x, y) = 12x^2, \quad 0 \leq x \leq 1, \quad 0 \leq y \leq 1 - x$$

De marginale tætheder bliver

$$\begin{aligned} f_X(x) &= \int_0^{1-x} 12x^2 dy = 12x^2(1-x) = 12(x^2 - x^3), \quad 0 \leq x \leq 1 \\ f_Y(y) &= \int_0^{1-y} 12x^2 dx = 12 \left[\frac{x^3}{3} \right]_0^{1-y} = 4(1 - 3y + 3y^2 - y^3), \quad 0 \leq y \leq 1 \end{aligned}$$

Bemærk, at X og Y er afhængige.

Udregning af middelværdi og varians af henholdsvis X og Y :

$$\begin{aligned} E[X] &= \int_0^1 x 12(x^2 - x^3) dx = 12 \left[\frac{x^4}{4} - \frac{x^5}{5} \right]_0^1 = 12 \left(\frac{1}{4} - \frac{1}{5} \right) = \frac{3}{5} \\ E[X^2] &= \int_0^1 x^2 12(x^2 - x^3) dx = 12 \left[\frac{x^5}{5} - \frac{x^6}{6} \right]_0^1 = 12 \left(\frac{1}{5} - \frac{1}{6} \right) = \frac{2}{5} \\ \text{Var}(X) &= \frac{2}{5} - \left(\frac{3}{5} \right)^2 = \frac{10-9}{25} = \frac{1}{25} \\ E[Y] &= \int_0^1 y 4(1 - 3y + 3y^2 - y^3) dy = 4 \left[\frac{y^2}{2} - 3\frac{y^3}{3} + 3\frac{y^4}{4} - \frac{y^5}{5} \right]_0^1 \\ &= 4 \left(\frac{1}{2} - 3\frac{1}{3} + 3\frac{1}{4} - \frac{1}{5} \right) = 4 \cdot \frac{1}{20} = \frac{1}{5} \\ E[Y^2] &= \int_0^1 y^2 4(1 - 3y + 3y^2 - y^3) dy = 4 \left[\frac{y^3}{3} - 3\frac{y^4}{4} + 3\frac{y^5}{5} - \frac{y^6}{6} \right]_0^1 \\ &= 4 \left(\frac{1}{3} - 3\frac{1}{4} + 3\frac{1}{5} - \frac{1}{6} \right) = \frac{1}{15} \\ \text{Var}(Y) &= \frac{1}{15} - \left(\frac{1}{5} \right)^2 = \frac{5-3}{75} = \frac{2}{75} \end{aligned}$$

□

Kovarians og korrelation

Kovariansen mellem to stokastiske variable X og Y er givet ved

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

Bemærk, at

$$X, Y \text{ uafhængige} \Rightarrow E[XY] = E[X]E[Y] \Rightarrow \text{Cov}(X, Y) = 0$$

Når $\text{Cov}(X, Y) > 0$, så siges X og Y at være positivt korrelerede, og når $\text{Cov}(X, Y) < 0$, så siges X og Y at være negativt korrelerede.

Korrelationskoefficienten, eller blot korrelationen, er en dimensionsløs udgave af kovariancen:

$$\rho(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)} \sqrt{\text{Var}(Y)}} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$$

Egenskaber ved korrelation:

$$\begin{aligned} -1 &\leq \rho(X, Y) \leq 1 \\ \rho(X, Y) = \pm 1 &\Rightarrow \exists \alpha, \beta: Y = \alpha + \beta X \end{aligned}$$

Eksempel 3 fortsat. Udregning af kovarians og korrelation:

$$E[XY] = 1 \cdot 2 \cdot \frac{1}{36} + 2 \cdot 3 \cdot \frac{2}{36} + 2 \cdot 4 \cdot \frac{3}{36} + \dots + 6 \cdot 11 \cdot \frac{2}{36} + 6 \cdot 12 \cdot \frac{1}{36} = \frac{1232}{36} = \frac{308}{9}$$

$$\text{Cov}(X, Y) = \frac{308}{9} - \frac{161}{36} \cdot 7 = \frac{1232 - 1127}{36} = \frac{105}{36} = \frac{35}{12} \approx 2.9167$$

$$\rho(X, Y) = \frac{\frac{35}{12}}{\sqrt{\frac{2555}{1296}} \sqrt{\frac{35}{6}}} = \frac{630}{\sqrt{2555} \sqrt{210}} \approx 0.8601$$

□

Eksempel 4 fortsat. Udregning af kovarians og korrelation:

$$\begin{aligned} E[XY] &= \int_0^1 \int_0^{1-x} xy 12x^2 dy dx = \int_0^1 12x^3 \left[\frac{y^2}{2} \right]_0^{1-x} dx = 6 \int_0^1 x^3 (1 - 2x + x^2) dx \\ &= 6 \int_0^1 x^3 - 2x^4 + x^5 dx = 6 \left[\frac{x^4}{4} - 2 \frac{x^5}{5} + \frac{x^6}{6} \right]_0^1 = 6 \left(\frac{1}{4} - \frac{2}{5} + \frac{1}{6} \right) = 6 \frac{15 - 24 + 10}{60} = \frac{1}{10} \end{aligned}$$

$$\text{Cov}(X, Y) = \frac{1}{10} - \frac{3}{5} \cdot \frac{1}{5} = \frac{5 - 6}{50} = -\frac{1}{50}$$

$$\rho(X, Y) = \frac{-\frac{1}{50}}{\sqrt{\frac{1}{25}} \sqrt{\frac{2}{75}}} = -\frac{1}{2} \sqrt{\frac{3}{2}} = -\frac{\sqrt{6}}{4} \approx -0.6124$$

□

Regneregler

Regneregler for middelværdi

- $P(X = c) = 1 \Rightarrow E[X] = c$
- $E[aX + bY] = a E[X] + b E[Y]$
- $E[\sum_{i=1}^n a_i X_i] = \sum_{i=1}^n a_i E[X_i]$
- $X_1 \leq X_2 \Rightarrow E[X_1] \leq E[X_2].$
- $|E[X]| \leq E[|X|].$

Regneregler for varians

- $P(X = c) = 1 \Leftrightarrow \text{Var}(X) = 0.$
- $\text{Var}(aX + bY) = a^2 \text{Var}(X) + 2ab \text{Cov}(X, Y) + b^2 \text{Var}(Y)$
- $\text{Var}(\sum_{i=1}^n a_i X_i) = \sum_{i=1}^n a_i^2 \text{Var}(X_i) + 2 \sum_{i < j} a_i a_j \text{Cov}(X_i, X_j)$

Regneregler for kovarians

- X og Y uafhængige $\Rightarrow \text{Cov}(X, Y) = 0$
- $\text{Cov}(X, Y) = \text{Cov}(Y, X)$

- $\text{Cov}(X, X) = \text{Var}(X)$
- $\text{Cov}(aX, bY) = ab \text{Cov}(X, Y)$
- $\text{Cov}(X + Y, Z) = \text{Cov}(X, Z) + \text{Cov}(Y, Z)$
- $\text{Cov}(X, Y + Z) = \text{Cov}(X, Y) + \text{Cov}(X, Z)$
- $\text{Cov}(\sum_i a_i X_i, \sum_j b_j Y_j) = \sum_i \sum_j a_i b_j \text{Cov}(X_i, Y_j)$

Udregning af højere ordens momenter

- Det n 'te moment for en stokastisk variabel

$$\mathbb{E}[X^n] = \begin{cases} \sum_{x_k} x_k^n p(x_k) \\ \int_{-\infty}^{\infty} x^n f(x) dx \end{cases}$$

- Det n 'te centrale moment:

$$\mathbb{E}[(X - \mathbb{E}[X])^n] = \begin{cases} \sum_{x_k} (x_k - \mu)^n p(x_k) \\ \int_{-\infty}^{\infty} (x - \mu)^n f(x) dx \end{cases}$$

hvor $\mu = \mathbb{E}[X]$.

29.1.2010
Bo Rosbjerg